


INTEGRAÇÃO DE DADOS ESTATÍSTICOS NA CLASSIFICAÇÃO DE IMAGENS DE SATÉLITE

Jorge Rocha e Paulo Morgado Sousa



Estudos para o Planeamento Regional e Urbano n° 70
Centro de Estudos Geográficos

**INTEGRAÇÃO DE DADOS ESTATÍSTICOS
NA CLASSIFICAÇÃO DE IMAGENS DE SATÉLITE**

**Jorge Rocha
Paulo Morgado Sousa**

**Estudos para o Planeamento Regional e Urbano nº 70
Centro de Estudos Geográficos
Universidade de Lisboa
2007**

FICHA TÉCNICA

Título: Integração de Dados Estatísticos na Classificação de Imagens de Satélite

Autores: Jorge Rocha e Paulo Morgado Sousa

Unidade de Investigação: Centro de Estudos Geográficos da Universidade de Lisboa

Edição e Distribuição: Centro de Estudos Geográficos da Universidade de Lisboa

Impressão: SATELICOR, Estúdio Gráfico, Lda.

Tiragem: 150 Exemplares

ISBN: 978-972-636-176-3

ÍNDICE

| | |
|--|-----------|
| 1 INTRODUÇÃO | 1 |
| 2 CONCEITOS E FUNDAMENTOS DE TELEDETECÇÃO..... | 6 |
| 2.1 INTRODUÇÃO..... | 6 |
| 2.2 GRANDEZAS RADIOMÉTRICAS..... | 8 |
| 2.3 FUNDAMENTOS FÍSICOS DO COMPORTAMENTO ESPECTRAL DOS CORPOS | 10 |
| 2.4 EMISSÃO DE RADIAÇÃO ELECTROMAGNÉTICA..... | 13 |
| 2.5 INTERACÇÕES DA ENERGIA ELECTROMAGNÉTICA COM A MATÉRIA | 17 |
| 2.6 INTERACÇÃO DA ENERGIA ELECTROMAGNÉTICA COM OS ELEMENTOS TERRESTRES | 21 |
| 2.7 INTERACÇÃO DA ENERGIA ELECTROMAGNÉTICA COM A ATMOSFERA | 24 |
| 2.7.1 <i>Dispersão atmosférica</i> | 25 |
| 2.7.2 <i>Absorção</i> | 27 |
| 2.7.3 <i>Transmitância da atmosfera</i> | 29 |
| 2.8 ENERGIA CAPTADA PELO SENSOR..... | 30 |
| 2.9 INTERACÇÃO DA ENERGIA ELECTROMAGNÉTICA COM OS ELEMENTOS URBANOS.... | 34 |
| 3 SATÉLITES ARTIFICIAIS DA TERRA | 36 |
| 3.1 INTRODUÇÃO..... | 36 |
| 3.2 GEOMETRIA DA ÓRBITA | 37 |
| 3.3 PRINCIPAIS CARACTERÍSTICAS DOS SATÉLITES LANDSAT E SPOT | 41 |
| 3.3.1 <i>Os Satélites Landsat</i> | 42 |
| 3.3.2 <i>Programa SPOT</i> | 54 |
| 3.3.3 <i>Comparação entre os Programas Landsat e SPOT</i> | 66 |
| 4 CLASSIFICAÇÃO DE IMAGENS DE SATÉLITE | 68 |
| 4.1 INTRODUÇÃO..... | 68 |
| 4.2 CLASSIFICAÇÃO SUPERVISIONADA | 69 |
| 4.2.1 <i>A fase de treino</i> | 70 |
| 4.2.2 <i>A fase de classificação</i> | 74 |
| 4.3 CLASSIFICAÇÃO NÃO SUPERVISIONADA | 82 |
| 4.4 CLASSIFICAÇÃO SUPERVISIONADA <i>VERSUS</i> NÃO SUPERVISIONADA | 87 |
| 4.5 CLASSIFICAÇÃO COM RECURSO A INFORMAÇÃO AUXILIAR..... | 89 |

| | |
|--|------------|
| 5 CLASSIFICAÇÃO DE IMAGENS DE SATÉLITE COM RECURSO A INFORMAÇÃO NÃO ESPECTRAL | 96 |
| 5.1 INTRODUÇÃO..... | 96 |
| 5.2 SELECÇÃO DA INFORMAÇÃO | 99 |
| 5.3 PRÉ-PROCESSAMENTO DA INFORMAÇÃO | 101 |
| 5.3.1 <i>Melhoramento da Informação Espectral e Auxiliar</i> | 101 |
| 5.3.2 <i>Processamento da Informação Auxiliar</i> | 112 |
| 5.4 METODOLOGIA DE CLASSIFICAÇÃO | 123 |
| 5.4.1 <i>Estratificação de pré-classificação</i> | 123 |
| 5.4.2 <i>Aplicação dos classificadores de Máxima Verosimilhança e de Bayes</i> | 128 |
| 5.4.3 <i>Regras de pós-classificação</i> | 131 |
| 5.5 VALIDAÇÃO DOS RESULTADOS | 134 |
| 5.5.1 <i>Delimitação das áreas de teste</i> | 134 |
| 5.5.2 <i>Avaliação do erro</i> | 137 |
| 5.6 CONSIDERAÇÕES FINAIS | 146 |
| 6 CONCLUSÕES..... | 149 |
| 7 BIBLIOGRAFIA..... | 152 |
| A1 ANEXO 1 | |
| A2 ANEXO 2 | |
| A3 ANEXO 3 | |
| A4 ANEXO 4 | |

ÍNDICE DE FIGURAS

| | |
|--|----|
| Figura 2.1 - Ângulo sólido definido por um cone (a) e Geometria de uma fonte pontual (b)..... | 8 |
| Figura 2.2 – Onda electromagnética | 10 |
| Figura 2.3 - Espectro electromagnético | 11 |
| Figura 2.4 – Exitância espectral de um corpo negro | 15 |
| Figura 2.5 – Emissividade espectral (a) e exitância espectral (b) para um corpo negro, um corpo cinzento e um radiador selectivo | 17 |
| Figura 2.6 – Interação da radiação com a matéria..... | 18 |
| Figura 2.7 – Reflectância Especular <i>versus</i> Reflectância Difusa..... | 19 |
| Figura 2.8 – Possíveis interações entre a energia electromagnética e os elementos da superfície terrestre..... | 22 |
| Figura 2.9 – Distribuição Angular da Difusão de Mie..... | 27 |
| Figura 2.10 – Janelas atmosféricas e principais zonas de absorção | 28 |
| Figura 2.11 – Interação da radiação com a atmosfera e a superfície terrestre..... | 31 |
| Figura 2.12 – Curvas de reflectância espectral de tipos de coberto de solo urbano..... | 34 |
| Figura 2.13 – Medidas de reflectância das coberturas típicas do Sudoeste de França (Provença) | 35 |
| Figura 2.14 – Medidas de reflectância das coberturas típicas da Bretanha..... | 35 |
| Figura 3.1 – Parâmetros da elipse | 38 |
| Figura 3.2 – Grande (a), Média (b) e Baixa (c) resolução no solo..... | 42 |
| Figura 3.3 – Órbita heliosíncrona dos Landsat 4 e 5..... | 47 |
| Figura 3.4 – (a) Distância entre percursos sucessivos dos Landsat 4 e 5; (b) Cronograma dos percursos adjacentes | 48 |
| Figura 3.5 - Os Landsat 4 e 5 | 49 |
| Figura 3.6 – Sensor de varrimento mecânico..... | 52 |
| Figura 3.7 – Estações de recolha de dados e respectivos raios de acção | 53 |
| Figura 3.8 – Órbitas diurnas do programa SPOT..... | 56 |
| Figura 3.9 - Representação Esquemática dos Satélites SPOT 1, 2 e 3..... | 57 |
| Figura 3.10 – Sensor de matriz linear | 58 |
| Figura 3.11 – Corte esquemático do sistema de imagem do SPOT | 59 |
| Figura 3.12 – Área coberta pelo SPOT recorrendo ao funcionamento dos sensores HRV em modo adjacente..... | 60 |
| Figura 3.13 – Amplitude do ângulo de visada oblíqua (não nadiral) do SPOT | 61 |
| Figura 3.14 – Estações de recepção de dados do programa SPOT | 61 |

| | |
|---|-----|
| Figura 3.15 – Exemplo de captação de imagens estereoscópicas | 62 |
| Figura 3.16 – Capacidade de “revisita” do satélite SPOT: (a) a uma Latitude de 0° (Equador); (b) a uma Latitude de 45° | 63 |
| Figura 3.17 – Áreas cobertas pelo VGT depois de 3 órbitas..... | 64 |
| Figura 3.18 – Tamanho comparativo dos satélites SPOT | 65 |
| Figura 3.19 – Constelação de satélites SPOT | 65 |
| Figura 3.20 – Comparação entre a dimensão das imagens SPOT e Landsat | 66 |
| Figura 3.21 – Comparação entre a dimensão do pixel das imagens SPOT e Landsat | 67 |
| Figura 4.1 – Polígonos correspondentes às áreas de treino “água” e “agricultura” | 71 |
| Figura 4.2 – Exemplo de histogramas das áreas de treino respeitantes à classe “floresta”..... | 74 |
| Figura 4.3 – Histogramas de um conjunto bidimensional de dados de treino para uma classe espectral (a e b) e região de decisão da classe (c) | 75 |
| Figura 4.4 – Classificação de dados correlacionados usando o método do paralelepípedo e mostrando a região de inseparabilidade (as elipses representam os diagramas de dispersão para as classes 1, 2 e 3, nas bandas x_1 e x_2) | 76 |
| Figura 4.5 – Classificação de dados utilizando o método da mínima distância (as circunferências representam os diagramas de dispersão para as classes 1, 2 e 3, nas bandas x_1 e x_2) | 78 |
| Figura 4.6 – Duas hipóteses diferentes de agrupamento do mesmo conjunto de dados | 83 |
| Figura 4.7 – Exemplo de funcionamento do método ISODATA..... | 85 |
| Figura 4.8 - Processo de estratificação da informação espectral..... | 90 |
| Figura 4.9 – As três fases de processamento do DREU. (Adaptado de [10]) | 94 |
| Figura 4.10 – Metodologia utilizada na produção do RUMAP. (Adaptado de [10])..... | 95 |
| Figura 5.1 – Enquadramento das áreas de teste (A) e de verificação (B) | 97 |
| Figura 5.2 – Perspectiva aérea da área de estudo (exageração vertical 3x), com destaque para as zonas de habitação unifamiliar (A) e plurifamiliar (B) | 98 |
| Figura 5.3 – Esquema da metodologia desenvolvida para a classificação de imagens de satélite | 99 |
| Figura 5.4 – Integração da informação matricial e vectorial..... | 101 |
| Figura 5.5 – Banda SPOT Pan e respectivo histograma | 102 |
| Figura 5.6 – Banda SPOT Pan após a expansão linear do contraste e respectivo histograma.. | 103 |
| Figura 5.7 – Banda SPOT Pan após expansão linear do contraste com saturação a 5% e respectivo histograma..... | 104 |
| Figura 5.8 – Banda SPOT Pan após equalização do histograma e respectivo histograma..... | 104 |
| Figura 5.9 – Banda Landsat TM4 e respectivo histograma..... | 104 |
| Figura 5.10 – Transposição, da imagem inicial para a imagem rectificadas, de pixels com coordenadas centrais inteiras (a) e decimais (b)..... | 109 |

| | |
|--|-----|
| Figura 5.11 – Interpolação do valor do pixel pelo método do vizinho mais próximo | 110 |
| Figura 5.12 – Correção da base de georeferenciação espacial do INE: (a) ortofotomapa correspondente à área de estudo com a BGRÉ sobreposta; (b) ampliação de uma área urbana mostrando a BGRÉ original ; (c) ampliação de uma área urbana mostrando a BGRÉ corrigida..... | 111 |
| Figura 5.13 –Informação de entrada e saída correspondente ao processamento de informação auxiliar..... | 112 |
| Figura 5.14 – Utilização de uma máscara para isolar as áreas acima do nível do mar. (a) imagem original; (b) máscara binária “água”/“não água”; (c) imagem final..... | 113 |
| Figura 5.15 – Produção da máscara urb_1: (a) BGRÉ sem as subsecções não urbanas (ou rurais); (b) rede viária; (c) BGRÉ sem as subsecções não urbanas (ou rurais) e a sem rede viária (c = a x b) - Máscara urb_1 (a área presumivelmente urbana corresponde ao azul e a branco está o que de certeza é não urbano)..... | 116 |
| Figura 5.16 – Regressão linear e correlação entre os edifícios unifamiliares (a) e os edifícios plurifamiliares (b) com os edifícios anteriores a 1945. As ordenadas representam a probabilidade <i>a priori</i> da classe “Núcleo Urbano Antigo” e as abcissas as probabilidades <i>a priori</i> das classes “Habitação Unifamiliar” (a) e “Habitação Plurifamiliar” (b). Os pontos representam as subsecções. | 119 |
| Figura 5.17 – (a) Banda contextual urbana proveniente do processo de <i>clustering</i> (a) onde: vermelho - subsecções fortemente urbanizadas; laranja - subsecções pouco urbanizadas; verde - subsecções com pouca probabilidade de terem edifícios; (b) | 122 |
| Figura 5.18 – Diagrama esquemático dos processos efectuados na fase de estratificação pré-classificação | 124 |
| Figura 5.19 – Exemplos de classificações obtidas pelo ISODATA..... | 125 |
| Figura 5.20 – Máscaras binárias “urbano” / “não urbano”: urb_1 (a), urb_2 (b) e urb_fim (c): A cor azul em corresponde à classe ‘urbano’ | 126 |
| Figura 5.21 - Esquema metodológico dos processos de classificação recorrendo aos algoritmos de Máxima Verosimilhança (MV) e de <i>Bayes</i> | 128 |
| Figura 5.22 – Probabilidades <i>a priori</i> para quatro classes de uso urbano..... | 129 |
| Figura 5.23 – Programa IDECIS..... | 130 |
| Figura 5.24 – Exemplos de composições coloridas criadas para a delimitação de áreas treino (resolução espacial de 10 m) | 131 |
| Figura 5.25 - Exemplos de informação auxiliar: Planta de Ordenamento do PDM de Oeiras (a) e distâncias relativamente à rede viária (b). No mapa (b) a rede viária está representada a preto e as distâncias das cores frias (azul) para as cores quentes (encarnado)..... | 133 |

| | |
|---|-----|
| Figura 5.26 – Carta de uso e ocupação do solo resultante da aplicação do método proposto... | 134 |
| Figura 5.27 - Uso do solo para 1998 obtido por foto-interpretação | 137 |
| Figura 5.28 - Uso do solo obtido pelo classificador do paralelepípedo | 138 |
| Figura 5.29 - Uso do solo obtido pelo classificador da mínima distância | 138 |
| Figura 5.30 - Uso do solo obtido pelo classificador de máxima verosimilhança..... | 139 |
| Figura 5.31 – Exemplo de Tabela de contingências | 140 |
| Figura 5.32 – Aplicação da metodologia proposta à área de verificação: (a) composição colorida SPOT XS; (b) sobreposição da BGRE sobre o ortofotomapa; (c) extracção das áreas “urbanas; (d) probabilidades a priori; (f) PDM; (e) classificação final..... | 145 |

ÍNDICE DE TABELAS

| | |
|---|-----|
| Tabela 2.1 – Grandezas Radiométricas..... | 10 |
| Tabela 2.2 – Regiões do espectro electromagnético..... | 14 |
| Tabela 2.3 – Composição da atmosfera ao nível do mar | 29 |
| Tabela 3.1 – Período orbital real e calculado através de (3.9)..... | 50 |
| Tabela 3.2 – Principais características do programa Landsat..... | 63 |
| Tabela 3.3 – Características dos sensores a bordo dos Landsat 1 e 2..... | 69 |
| Tabela 3.4 - Características dos sensores a bordo do Landsat 3..... | 70 |
| Tabela 3.5 – Características dos sensores a bordo dos Landsat 4 e 5..... | 77 |
| Tabela 3.6 – Principais características e aplicações dos sensores TM | 79 |
| Tabela 3.7 – Características do sensor a bordo do Landsat 7 | 83 |
| Tabela 3.8 – Principais características do programa SPOT | 84 |
| Tabela 3.9 – Principais características dos sensores HRV | 87 |
| Tabela 3.10 – Principais características dos sensores HRVIR | 95 |
| Tabela 4.1 – Probabilidade de ocorrência das classes de espaço em Norwich. Adaptado de [50]..... | 133 |
| Tabela 4.2 – Comparação das performances dos classificadores de <i>Bayes</i> e de Máxima Verosimilhança. Adaptado de [50] | 134 |
| Tabela 4.3 – Exactidão dos mapas SATMAP, RUMAP e CENMAP. Adaptado de [10] | 137 |
| Tabela 5.1 – Informação estatística referenciada à subsecção e seleccionada em primeira instância | 143 |
| Tabela 5.2 – Parâmetros do processo de georeferenciação..... | 157 |
| Tabela 5.3 – Erros de omissão (EO), erros de comissão (EC), exactidão do produtor (EP), exactidão do utilizador (EU), KIA (<i>Kappa Index of Agreement</i>), índice <i>Kappa</i> e exactidão global (EG)..... | 170 |
| Tabela 5.4 – Índice <i>Kappa</i> relativo a cada um dos classificadores para a área teste.... | 187 |
| Tabela 5.5 – Erros de comissão (EC) e omissão (EO) apresentados pelos quatro | 187 |
| Tabela 5.6 – Índice <i>KIA</i> , exactidão global (EG), exactidão do produtor (EP) e exactidão do consumidor (EC) por classe | 188 |

| | |
|--|-----|
| Tabela 5.7 – Coeficiente <i>Kappa</i> e exactidão global relativos a cada um dos classificadores para a área de verificação | 189 |
| Tabela 5.8 – Índice <i>KIA</i> , exactidão global (EG), exactidão do produtor (EP) e exactidão do consumidor (EC) por classe | 190 |

1

INTRODUÇÃO

A procura de um conhecimento geográfico do mundo, cada vez mais vasto e abrangente, é um objectivo que tem acompanhado a evolução da Humanidade. A este facto, não será estranho o Homem procurar desde sempre os locais mais altos (montes, árvores, torres de fortalezas, etc.), para a partir daí poder vigiar a maior área geográfica possível e assim, aperceber-se antecipadamente dos perigos que se lhe podiam deparar. Hoje em dia, os objectivos continuam os mesmos só os pontos de observação foram modificados.

Na actualidade, as principais observações da superfície terrestre são obtidas por técnicas de teledeteccção, nomeadamente as fotografias aéreas e as imagens de satélite. As fotografias aéreas constituíram a primeira fonte de recolha de informação por teledeteccção. A primeira fotografia aérea conhecida foi tirada em 1858 por um fotógrafo parisiense de seu nome Gaspard Felix Tournachon, o qual utilizou um balão para ascender a uma altitude de 80 m e tirar uma fotografia sobre Bivre (França). A partir dessa data, multiplicaram-se os registos de imagens obtidas por balão, mas sempre numa base um pouco experimental. O grande incremento na difusão desta tecnologia só seria dado a partir de 1903 com a invenção do avião e

Integração de Dados Estatísticos na Classificação de Imagens de Satélite

principalmente com as duas grandes guerras mundiais. Com efeito, o propósito inicial das fotografias aéreas foi, à semelhança da grande maioria das tecnologias hoje disponíveis, o de servir políticas de estratégia militar. Posteriormente, com o desenvolvimento de toda a tecnologia inerente, a fotografia aérea passou a orientar-se para um maior número de destinatários: serviu propósitos ambientais - através da observação da paisagem o que permitiu uma maior e melhor inventariação dos recursos, assim como uma mais eficaz gestão dos mesmos - possibilitou a avaliação de desastres, contribuiu para o planeamento urbano e deu preciosa ajuda para a elaboração da cartografia geológica.

As imagens de satélite constituíram o passo seguinte no processo de observação vertical da Terra, sendo desde logo tidas como um poderoso meio de obter informação actualizada, a custos relativamente baixos. Também elas foram inicialmente utilizadas para fins meramente militares, mas divergiram muito rapidamente no respeitante a objectivos e fins a atingir.

Nos primeiros tempos de coexistência, estas duas fontes de informação em teledetecção evoluíram lado a lado, sem grandes fricções. Considerava-se que a fotografia aérea, nas suas diversas emulsões, estava vocacionada para o estudo das relações interactivas entre o meio e os elementos que o compõem, analisando pormenorizadamente (à escala local) a forma e textura destes últimos. A imagem de satélite era tida como de grande eficácia no tratamento de espaços de dimensão superior (escala regional, nacional e internacional), nomeadamente grandes unidades morfológicas, pedológicas, biogeográficas, geológicas, e de uso e ocupação do solo.

No entanto, com o grande desenvolvimento verificado ao nível dos sensores incorporados a bordo dos satélites, a utilização das imagens obtidas por estes últimos tem vindo a generalizar-se em campos da ciência onde até agora a utilização da fotografia aérea predominava. Mas, se para estudos em áreas agrícolas a classificação de imagens de satélite têm constituído uma mais valia, quando aplicada a áreas construídas os resultados por si obtidos já não são tão conseguidos. A fraca resolução espacial das imagens foi, numa fase inicial, apontada como justificação para a sua falta de adaptação ao contexto urbano. Contudo, rapidamente se chegou à conclusão que este factor, embora limitativo, não podia ser responsabilizado por todos os problemas, verificando-se paralelamente uma fraca prestação dos algoritmos utilizados na classificação das imagens. A questão fulcral reside exactamente neste ponto: os algoritmos tradicionais não se adaptam às particularidades destes casos, nomeadamente à frequência espacial dos objectos, na medida em que classificam cada pixel com base unicamente nas suas características espectrais.

Muitos cientistas, cientes desta limitação, têm tentado melhorar a precisão e qualidade da classificação de ocupação do solo, incorporando informação auxiliar no processo de

Introdução

classificação [10, 49, 50]. Entende-se por informação auxiliar qualquer tipo de informação, espacial ou não, que possa ser útil para o processo de classificação, incluindo altitude, declives, exposições, geologia, tipo de solo, hidrologia, redes de transporte, limites administrativos e mapas de vegetação. Contudo, a informação auxiliar não é isenta de erros. Os investigadores que desejem incorporá-la na classificação de imagens de satélite deverão ter em conta diversos aspectos.

Em primeiro lugar, a informação auxiliar foi produzida para outros usos específicos, e não para melhorar a precisão da classificação de imagens de satélite. Em segundo lugar, os atributos nominais, ordinais, ou a legenda dos mapas podem ser imprecisos ou incompletos. Por exemplo, limites poligonais entre os diferentes tipos de vegetação podem ou não existir realmente no terreno. É necessário proceder com muito cuidado ao procurar compatibilizar as classes dos mapas de informação auxiliar com as classes pretendidas na classificação da imagem de satélite.

Em terceiro lugar, a maior parte da informação auxiliar encontra-se armazenada em mapas de formato analógico. Os mapas têm de ser geo-referenciados e digitalizados, para se obterem dados que façam sentido quando projectados sobre a imagem de satélite. No decorrer deste processo, a posição da informação pode ser deslocada da sua localização planimétrica original. Por outro lado, muitos dados auxiliares nunca foram posicionados correctamente.

Podem ser utilizadas diversas abordagens de incorporação de dados auxiliares no processo de classificação da imagem, de modo a melhorar os resultados. Estas incluem a incorporação dos dados antes, durante, ou depois da classificação, através de estratificação geográfica, operações de classificação, e/ou regras de pós-classificação. O cruzamento destes métodos pode ser efectuado através de uma lógica de classificação por níveis (*layers*), opção esta que foi seleccionada para aplicação na presente dissertação. A classificação por níveis é, contrariamente aos algoritmos de classificação simples, que utilizam toda a informação disponível numa única operação, um processo hierárquico onde dois ou mais instrumentos de decisão são utilizados no processo de classificação. Esta classificação utiliza dados da imagem de satélite e/ou dados auxiliares, numa série de decisões autónomas normalmente incorporadas num Sistema de Informação Geográfica (SIG).

Neste trabalho, explora-se precisamente o facto dos SIG permitirem a fácil integração de informação proveniente de diversas fontes. Esta potencialidade pode ser explorada na classificação de imagens de satélite, através da utilização de informação não espectral (auxiliar ou colateral). Neste contexto, propõe-se o desenvolvimento e validação, por experimentação numa área teste (área envolvente do Estádio Nacional – Oeiras), de uma forma melhorada de classificação de imagens que integra, em ambiente SIG, dados provenientes dos censos e de

Integração de Dados Estatísticos na Classificação de Imagens de Satélite

detecção remota. A metodologia desenvolvida - Integração de Dados Estatísticos na Classificação de Imagens de Satélite (IDECIS) - utiliza dados matriciais (*raster*) e vectoriais, correspondendo os primeiros a imagens SPOT (P e XS) e Landsat TM e os segundos aos resultados do Recenseamento Geral da População e Habitação (Censos) e ao Plano Director Municipal (PDM) da região em estudo.

Na persecução destes objectivos o texto foi dividido em seis capítulos. Após o capítulo introdutório que teve como objectivo enquadrar o leitor na temática subjacente expõem-se, no capítulo 2, alguns conceitos ligados à radiação electromagnética, bem como dos factores que explicam as interacções desta energia com a matéria. Neste capítulo, após uma breve introdução onde se apresenta a génese do termo teledetecção, seguem-se nove secções. A primeira trata da descrição das grandezas radiométricas que estarão presentes ao longo de todo o trabalho; as sete seguintes centram-se, essencialmente, na explicação do comportamento da energia electromagnética: no vácuo, no seu percurso pela atmosfera em direcção à superfície terrestre, no contacto com os elementos que compõem essa mesma superfície e por fim no percurso ascendente em direcção ao satélite, fazendo-se referência aos principais fenómenos que ocorrem durante estes percursos. Por fim, faz-se uma análise do comportamento espectral de alguns dos elementos da superfície terrestre respeitantes ao uso urbano, procedendo-se a uma primeira análise dos problemas que sua classificação e interpretação acarreta.

No terceiro capítulo, faz-se menção aos satélites artificiais que vão estar na base desta metodologia de classificação referindo-se as suas principais características, bem como as dos sensores que se encontram a bordo de cada um.

No quarto capítulo, revêm-se os métodos mais usados para a classificação de imagens de satélite e apresentam-se os desenvolvimentos mais recentes em matéria de classificação de imagens com recurso a informação não espectral (mais precisamente informação proveniente do Recenseamento Geral da População – Censos).

No quinto capítulo exploram-se as potencialidades desta vertente da teledetecção, a classificação de imagens de satélites com recurso a informação dita auxiliar. O objectivo principal consiste em elaborar uma carta de uso e ocupação do solo, que posteriormente será confrontada com resultados obtidos através de algumas das técnicas descritas no capítulo 4, de forma a aquilatar a viabilidade da metodologia desenvolvida.

Para elaborar a referida carta de uso e ocupação do solo é necessário, numa primeira fase, compatibilizar a informação disponível, surgindo como principal problema a tradicional dicotomia matricial/vectorial. Neste caso, considerando as imagens de satélite como a base de

Introdução

todo o processo, optou-se por converter toda a informação para formato matricial. Após a fase de compatibilização dos dados, foi iniciado o processo de classificação.

Até o presente, somente alguns trabalhos integraram dados dos Censos na classificação das imagens de satélite. Um dos mais recentes foi realizado em Portugal pelo Centro Nacional de Informação Geográfica (CNIG) em parceria com o Instituto Nacional de Estatística (INE). Este estudo [10] visava avaliar a dinâmica do crescimento da área da grande Lisboa, usando dados espectrais (imagens SPOT) e auxiliares (Rede viária - RV, Modelos Digitais do Terreno - MDT e os Censos). A metodologia seguida utilizou o MDT para a correcção dos efeitos topográficos nas imagens, a Rede Viária para, numa fase de pré-classificação, estratificar a imagem (filtro urbano / não urbano) e os dados dos Censos para o desenvolvimento de regras de pós-classificação. Em 1998, foi apresentado outro trabalho [49] de relevo, que utilizou os dados dos Censos para definir *a priori* a probabilidade de ocorrência de determinadas classes de uso de solo, recorrendo a um classificador de *Bayes*, e cruzando essas probabilidades com a classificação de imagens de satélite (Landsat TM).

A metodologia apresentada nesta tese pode considerar-se um desenvolvimento destes dois trabalhos. Com efeito, estas duas abordagens (hierárquicas) [10, 50], recorrem à informação auxiliar antes, durante ou após o processo de classificação. A metodologia desenvolvida nesta dissertação faz uso da informação não espectral nas três fases, constituindo este facto uma das principais contribuições da tese. Os procedimentos adoptados seguiram uma abordagem hierárquica, compreendendo três fases: *i*) Estratificação de pré-classificação; *ii*) Classificação de *Bayes* e de Máxima Verosimilhança (MV); *iii*) Correcção de pós-classificação.

Na primeira fase, e recorrendo unicamente à informação auxiliar, produz-se uma máscara binária. A segunda fase compreende quatro passos: O primeiro utiliza o classificador ISODATA [36] para criar uma máscara de uso “urbano”/“não urbano”; o segundo recorre à intersecção da informação auxiliar com os resultados obtidos na fase anterior, resultando numa nova base que liga a informação estatística às áreas construídas); o terceiro passo estima as probabilidades *a priori*, necessárias no classificador de *Bayes*; finalmente, no quarto passo aplicam-se os classificadores de *Bayes* e MV. Na terceira fase, e de forma a melhorar os resultados da classificação, recorre-se a regras de pós-classificação, as quais visam a correcção de classificações anómalas nas áreas residenciais.

No último capítulo, o sexto, apresentam-se as conclusões decorrentes de todo o trabalho, fazendo-se uma reflexão sobre os defeitos e as virtudes do método desenvolvido, apontando-se paralelamente alguns caminhos a seguir em projectos futuros.

2

CONCEITOS E FUNDAMENTOS DE TELEDETECÇÃO

2.1 INTRODUÇÃO

Numa primeira instância e numa perspectiva restrita, entende-se por **teledeteccção** todo um encadeamento de processos, composto essencialmente pela aquisição, transmissão, armazenamento, processamento e visualização de dados geográficos. Num sentido mais lato, pode afirmar-se que a Teledeteccção é a ciência, o conjunto das tecnologias e a arte, que permite obter informação sobre objectos, áreas ou fenómenos, através da análise de informação adquirida por aparelhos de observação (sensores) sem contacto com o objecto, área, ou fenómeno em estudo.

Podem encontrar-se usualmente duas expressões para designar o conceito: **detecção remota** (*remote sensing*) e **teledeteccção** (*téledétection*). O termo *remote sensing* é o mais antigo; foi empregue pela primeira vez nos Estados Unidos na década de sessenta e englobava campos como a fotogrametria e a foto-interpretação, tendo-se disseminado a sua utilização aquando do

lançamento do primeiro satélite de observação da Terra, em 1972 - o Landsat 1. O termo teledeteção é de origem francófona e é o que usualmente se utiliza na língua portuguesa.

A génese do termo assenta primordialmente no facto dos objectos à superfície terrestre poderem ser caracterizados e distinguidos pela forma como reflectem ou emitem a energia electromagnética, o que constitui a condição fundamental para que exista teledeteção. De uma forma genérica, supõe-se a coexistência de uma fonte emissora de energia, um objecto e um sensor (receptor) como constituintes duma trilogia necessária à recolha de informação por meios remotos, constituindo um meio para adquirir dados geográficos e para avaliar a sua dinâmica espacial.

O tipo de emissor permite diferenciar duas formas de teledeteção. Na primeira, designada de **teledeteção passiva**, os sistemas de detecção limitam-se a captar a radiação reflectida ou emitida pelos corpos/elementos naturais; na segunda, designada de **teledeteção activa**, a fonte de energia e os sensores coabitam a bordo do satélite (ex. radar). No entanto, a maioria dos satélites, nomeadamente aqueles que forneceram informação para o trabalho desenvolvido nesta tese (Landsat e SPOT), recolhem informação por teledeteção passiva.

Uma imagem de satélite resulta do registo, obtido por um sensor (aparelho de observação instalado na plataforma de um satélite), dos valores da radiação electromagnética reflectida ou emitida pelos objectos da superfície terrestre, ou pela atmosfera, em diferentes domínios do espectro electromagnético.

Neste capítulo, e após a introdução de noções de teledeteção, apresentam-se alguns conceitos e fenómenos relacionados com a energia electromagnética, e que se devem conhecer para uma compreensão do processo de aquisição de dados através de teledeteção. Em síntese, começa-se pela definição das grandezas radiométricas, que estão presentes ao longo de todo o texto. Prossegue-se com a descrição do conceito de energia electromagnética e do comportamento desta energia na interacção com a matéria. Por fim, faz-se uma breve análise do comportamento espectral de alguns dos elementos da superfície terrestre respeitante ao uso urbano, procedendo-se a uma primeira análise dos problemas colocados na classificação automática destes elementos.

2.2 GRANDEZAS RADIOMÉTRICAS

Designa-se por **radiometria**, a medição do fluxo de energia electromagnética radiante emitida por uma superfície ou incidente sobre ela. Embora a radiometria não seja um assunto complexo, as grandezas a ela associadas são muitas vezes utilizadas de forma distinta e até mesmo incorrecta. Por este motivo e porque estas grandezas vão estar presentes ao longo de todo o texto, considerou-se importante serem claramente definidas.

Antes de se passar à definição das **grandezas** (ou quantidades) **radiométricas**, deverá ser introduzido o conceito de **ângulo sólido**. Para tal, considere-se uma fonte pontual, situada no centro de uma esfera de raio R , emitindo radiação num volume cónico (figura 2.1 a). Os limites do cone, projectados sobre a esfera, delimitam uma área A . O ângulo sólido (ω) definido pelo cone, medido em estereoradianos (sr do inglês *steradians*), corresponde ao quociente entre a área A e o quadrado do raio da esfera ($\omega = A/R^2$). O ângulo sólido de uma esfera ou de um hemisfério é, respectivamente, $4\pi sr$ e $2\pi sr$.




Figura 2.1 - Ângulo sólido definido por um cone (a) e Geometria de uma fonte pontual (b)

As grandezas radiométricas mais utilizadas para caracterizar a radiação electromagnética e a sua interacção com a matéria encontram-se sintetizadas na tabela 2.1.

A **energia radiante** (Q) é definida como a quantidade de energia radiada por uma fonte num determinado instante (t), ou seja, é a radiação própria, comum a todos os corpos, cujas características dependem fundamentalmente da sua temperatura absoluta.

| Grandeza | Símbolo | Unidade |
|--------------------------------|---------|-----------------------------------|
| Energia Radiante | Q | Ws = J |
| Fluxo Radiante | Φ | Js ⁻¹ = W |
| Irradiância | E | Wm ⁻² |
| Exitância Radiante (Emitância) | M | Wm ⁻² |
| Intensidade Radiante | I | Wsr ⁻¹ |
| Radiância | L | Wm ⁻² sr ⁻¹ |

Tabela 2.1 – Grandezas radiométricas

A taxa de variação da energia radiante corresponde à emissão de energia radiante por unidade de tempo e é designada por **fluxo radiante** (Φ):

$$\Phi = \frac{dQ}{dt}. \quad (2.1)$$

Se a fonte de energia for pontual, então o fluxo radiante pode ser entendido como o fluxo de energia através de uma esfera hipotética envolvendo a fonte. Neste caso, o fluxo radiante emitido toma a designação de **intensidade radiante** (I). Formalmente:

$$I = \frac{d\Phi}{d\omega}. \quad (2.2)$$

Se a fonte for uma superfície, o quociente entre o fluxo radiante e a área da superfície emissora é designado por **exitância radiante**, ou **emitância** (M). Caso se esteja perante uma superfície irradiada por uma fonte externa de energia, o fluxo por unidade de área passa a ser designado por **irradiância** (E):

$$E = \frac{d\Phi}{dA_0} \text{ e } M = \frac{d\Phi}{dA_0}, \quad (2.3)$$

onde $dA_0 = \frac{dA}{\cos\psi}$ (figura 2.1 b).

Recorrendo à noção de exitância, pode-se exprimir o **fluxo radiante** como:

$$\Phi = \iint M dA. \quad (2.4)$$

O fluxo radiante, por unidade de ângulo sólido e por unidade de área projectada numa determinada direcção, é designado por **radiância** (L):

$$L = \frac{d^2\Phi}{dAd\omega} = \frac{d^2\Phi}{dA_0 \cos\psi d\omega}. \quad (2.5)$$

A radiância depende dos ângulos de incidência (ψ) e azimutal (φ) (figura 2.1 b). Para uma superfície plana, ψ e φ estão contidos nos intervalos $[0, \pi/2]$ e $[0, 2\pi]$, respectivamente.

Quando as grandezas descritas se reportam a uma determinada região do espectro, ou seja, quando são dependentes do comprimento de onda, passam a ser designadas de **grandezas espectrais**¹. Como exemplo, a radiância simboliza-se por L , enquanto que a **radiância espectral** por $L(\lambda)$.

A informação adquirida pelos sensores dos satélites em diferentes bandas do espectro electromagnético, e registada sob a forma numérica segundo matrizes de pixels (ou imagens digitais), resulta da radiância dos corpos à superfície da Terra. O valor de cada elemento de imagem (pixel) depende da quantidade de energia electromagnética reflectida e/ou emitida, pela área da superfície terrestre correspondente a esse pixel. Em teledetecção esses valores são designados por **intensidade radiométrica**, **nível radiométrico** (NR) ou **número digital** (ND).

2.3 FUNDAMENTOS FÍSICOS DO COMPORTAMENTO ESPECTRAL DOS CORPOS

A energia electromagnética, também designada por **radiação electromagnética**, é o suporte de toda a informação em teledetecção. A propagação da energia electromagnética (figura 2.2) processa-se de acordo com a teoria geral das ondas, efectuando-se à “velocidade da luz”, com evolução de amplitude sinusoidal, no tempo e no espaço e sem necessitar de suporte material. A onda é composta por um campo eléctrico e por um campo magnético, ortogonais entre si e normais à direcção de propagação.




Figura 2.2 – Onda electromagnética

¹ As grandezas radiométricas correspondem à integração das grandezas espectrais ao longo de todo o espectro electromagnético.

As ondas electromagnéticas podem ser definidas através de três características fundamentais: velocidade, comprimento de onda e frequência. A **velocidade** de uma onda que se desloca no vácuo é normalmente considerada idêntica à da luz, ela própria uma forma de energia electromagnética. O **comprimento de onda** expressa a distância entre dois máximos adjacentes, enquanto que a **frequência** é definida como o número de máximos de onda a passar num ponto fixo do espaço, por unidade de tempo. Estas grandezas relacionam-se através de:

$$c = \lambda f, \quad (2.6)$$

onde

c - velocidade da luz no vácuo $\approx 3 \times 10^8$ m/s⁻¹;

λ - comprimento de onda (m);

f - frequência (s⁻¹ ou Hz).

A importância da energia electromagnética em teledeteção reside no facto de os objectos que existem à superfície terrestre se comportarem de forma diferenciada e selectiva face à energia electromagnética que sobre eles incide. Esta pode provir de fontes naturais ou artificiais. A principal fonte natural de energia electromagnética é o Sol, o qual emite energia em comprimentos de onda compreendidos entre os 0,1 nm e as centenas de metros. Contudo, cerca de 99% da energia solar concentra-se entre os 0,15 μ m e os 5 μ m, e desta, apenas uma pequena percentagem (1/5 do total incidente sobre a Terra) atinge directamente a superfície. Do total de energia que incide sobre a superfície terrestre uma parte é absorvida, sendo posteriormente emitida em comprimentos de onda que variam entre os 4 μ m e os 14 μ m. A principal fonte artificial de energia electromagnética utilizada na área da teledeteção activa é o radar, que emite energia em comprimentos de onda situados entre os 1 nm e 1 m.

Em teledeteção, é usual classificar as ondas electromagnéticas pela localização do comprimento de onda respectivo no espectro electromagnético (figura 2.3).




Figura 2.3 - Espectro electromagnético

Conceitos e Fundamentos de Teledetecção

Dentro do espectro destacam-se regiões essenciais em teledetecção - correspondendo de uma maneira geral aos comprimentos de onda do principal fluxo de radiação solar incidente, da radiação terrestre emitida e da radiação emitida pelos sistemas de radar - intercaladas com outras de menor importância para esta área. Na tabela 2.2 apresentam-se sinteticamente as diferentes regiões segundo as quais é usual dividir o espectro electromagnético, indicando-se a sua utilidade para a recolha de informação através de sensores remotos orbitais.

| Região | Comprimento de Onda | Características |
|---------------------------------|-----------------------|--|
| Raios Gama | < 0,03 nm | Toda a radiação incidente é absorvida pela alta atmosfera, não se encontrando disponível para a Teledetecção. |
| Raios X | 0,03 a 30 nm | Completamente absorvida pela atmosfera. Não é utilizada em Teledetecção. |
| Ultravioleta | 0,03 a 0,4 µm | A radiação com um comprimento de onda inferior a 0,3 µm é completamente absorvida pela camada de Ozono na alta atmosfera. |
| Ultravioleta Fotográfico | 0,3 a 0,4 µm | Transmitida através da atmosfera. Pode ser detectada com câmaras fotográficas, mas é fortemente influenciada pela dispersão atmosférica. |
| Visível | 0,4 a 0,7 µm | Compreende as bandas do azul (0,4 µm - 0,5 µm), verde (0,5 µm - 0,6 µm) e vermelho (0,6 µm - 0,7 µm). A sua designação reside no facto de abranger as únicas regiões do espectro perceptíveis ao olho humano; permite a obtenção de fotografias e inclui o pico de energia emitida pelo Sol. |
| Infravermelho Reflectido | 0,7 a 3,0 µm | Radiação solar reflectida que não possui qualquer informação acerca das características térmicas dos materiais. O intervalo de 0,7 a 0,9 µm é detectável com película fotográfica e conseqüentemente designado por banda do infravermelho fotográfico. |
| Infravermelho Térmico | 3 a 5 µm 8 a 14 µm | Principal janela atmosférica na região do térmico. As imagens caracterizadas por estes comprimentos de onda são adquiridas com sensores optico-mecânicos e sistemas especiais de vídeo, mas não através de película fotográfica. |
| Microondas (radar) | 0,1 a 100 cm | Longos comprimentos de onda, podendo penetrar nuvens, nevoeiro e chuva. Usada em teledetecção através de um sistema activo. |
| Rádio | > 100 cm | Não utilizado em Teledetecção. |

Tabela 2.2 – Regiões do espectro electromagnético

Muito embora algumas das características da radiação electromagnética sejam mais facilmente entendidas com base na teoria das ondas, a teoria das partículas¹ é mais adequada para explicar a interacção da energia com a matéria. A energia radiante de um *quantum* (também designado de fóton) é dada por:

$$Q_W = h f, \quad (2.7)$$

onde

¹ Segundo esta teoria, a radiação electromagnética é composta por entidades discretas designadas por fótons ou quantas.

Q_W - energia radiante de um *quantum* (J);

h - constante de Plank, $6,626 \times 10^{-34}$ Js.

As equações da onda e do modelo quântico podem ser relacionadas substituindo (2.6) em (2.7), obtendo-se

$$Q_W = \frac{h c}{\lambda}. \quad (2.8)$$

De (2.8) conclui-se que a energia de um fóton é inversamente proporcional ao seu comprimento de onda - quanto maior for o comprimento de onda, menor será o conteúdo energético do fóton. Este facto tem implicações importantes em teledeteção, justificando que a radiação emitida naturalmente e de grande comprimento de onda (como a emissão, por parte dos objectos à superfície da Terra, na gama do infravermelho térmico), seja mais difícil de registar do que a de pequeno comprimento de onda. O baixo conteúdo energético da radiação com longos comprimentos de onda, implica que, regra geral, os sistemas remotos que operam com esses comprimentos de onda tenham a necessidade de registar, a cada momento, informação sobre uma grande área, por forma a obter um sinal com energia suficiente para ser detectado.

2.4 EMISSÃO DE RADIAÇÃO ELECTROMAGNÉTICA

Todos os corpos que apresentam uma temperatura superior ao zero absoluto (0 K ou -273 °C) emitem radiação electromagnética, designada de radiação térmica visto ser essencialmente dependente da temperatura. As características desta emissão podem ser explicadas com recurso à **teoria dos corpos negros**.

Segundo esta teoria, um **corpo negro** (CN) é uma entidade física hipotética definida como um corpo em equilíbrio térmico com o ambiente que o rodeia e que absorve e reemite toda a energia que sobre ele incide. A Lei de Planck (1900), permite exprimir a radiância espectral $L(\lambda)$ do corpo negro, em função da sua temperatura e do comprimento de onda, de acordo com:

$$L(\lambda) = \frac{2hc^2 \lambda^{-5}}{e^{\frac{hc}{\lambda kT}} - 1}, \quad (2.9)$$

onde

k - constante de Boltzmann, $1,38 \times 10^{-23}$ J/K;

T - temperatura em K.

Segundo (2.3) e (2.5), a emitância (ou exitância radiante) pode ser obtida integrando a radiância ao longo do ângulo sólido. Uma vez que a radiação do corpo negro não depende do ângulo de observação (Radiador *Lambertiano*), a sua exitância espectral - $M(\lambda)$ - é π vezes superior à radiância espectral, vindo:

$$M(\lambda) = \frac{2\pi hc^2 \lambda^{-5}}{e^{\frac{hc}{\lambda kT}} - 1}. \quad (2.10)$$

Embora a lei de Planck permita explicar observações experimentais em todos os comprimentos de onda há, para determinadas regiões do espectro, outras formas de calcular a radiância dos corpos negros. No caso específico de o comprimento de onda ser maior que 3 nm e a temperatura ser superior a 200 K, pode-se aplicar uma simplificação da Lei de Planck, conhecida como **Lei de Rayleigh-Jeans**. Neste caso:

$$M(\lambda) = \frac{2kT}{\lambda^2}. \quad (2.11)$$

Como já foi referido, os corpos negros detêm características Lambertianas, ou seja a sua exitância não depende da direcção de emissão. Esta é unicamente dependente da temperatura e do comprimento de onda sendo possível, para uma temperatura constante, estabelecer a sua curva de exitância espectral, que se apresenta na figura 2.4. Nesta figura, é facilmente perceptível a diminuição do valor do comprimento de onda correspondente ao máximo de exitância à medida que a temperatura do corpo negro varia entre os 200 K e os 6 000 K. Este fenómeno é perfeitamente identificável ao aquecer-se um objecto ferroso, em que a sua coloração transita, à medida que a temperatura aumenta, do vermelho para o laranja, deste para o amarelo, e eventualmente para o branco[42].

As curvas de radiação à temperatura do Sol e da Terra encontram-se destacadas porque representam as duas principais fontes de energia electromagnética, no que à teledetecção diz respeito. O primeiro assemelha-se a um corpo negro à temperatura de 6000 K, com o pico de emissão situado na banda do visível (0,48 μm), enquanto que o nosso planeta é caracterizado por picos de emissão localizados na banda térmica (12,4 μm , 9,18 μm e 9,66 μm) e temperaturas que oscilam entre os 240 K e 315 K, correspondentes a uma média de 300 K (27 °C).

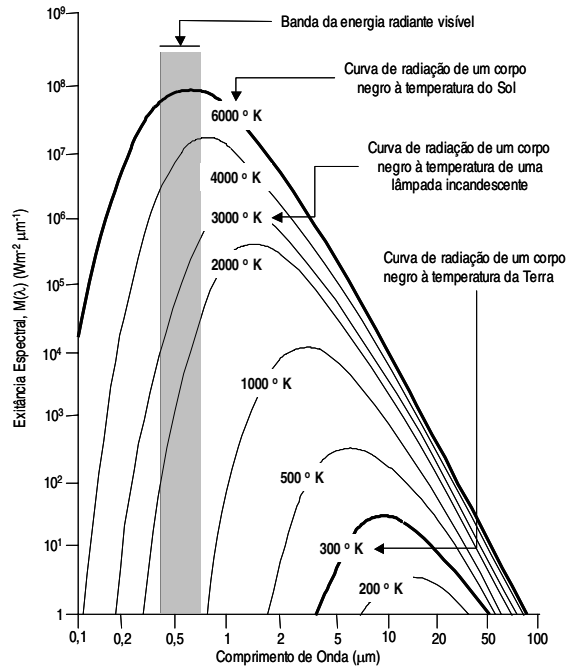


Figura 2.4 – Emitância espectral de um corpo negro

A **emitância total** dos corpos negros (correspondendo à área do interior de cada curva representada na figura 2.4) é calculada através da integração da lei de Plank ao longo do espectro, verificando-se ser proporcional à quarta potência da temperatura absoluta (T^4) do corpo:

$$M = \int_0^{\infty} M(\lambda) d\lambda = \frac{2}{15} \frac{k^4 \pi^5}{c^2 h^3} T^4 = \sigma T^4, \quad (2.12)$$

onde

M - emitância total do material (Wm^{-2});

σ - constante de Stefan-Boltzmann ($5,6693 \cdot 10^{-8} Wm^{-2}K^{-4}$).

A relação (2.12), conhecida como lei de **Stefan-Boltzman**, permite inferir a temperatura de um corpo, uma vez conhecida a sua emitância. A intensidade e composição espectral da emitância estão directamente relacionadas com o material em questão e com a temperatura do corpo considerado. À medida que esta última varia, o comprimento de onda da **radiação máxima (ou dominante)** evolui de acordo com a relação:

$$\lambda_m = \frac{A}{T}, \quad (2.13)$$

onde

λ_m - comprimento de onda da exitância espectral máxima (μm);

A - constante (2898 $\mu\text{m K}$).

A relação (2.13) exprime a **lei de deslocamento de Wien** e obtém-se maximizando a Lei de Plank em ordem ao comprimento de onda. Esta lei é útil no sentido em que, considerando a temperatura ambiente terrestre (temperatura de elementos como edifícios, vegetação e água) de 300 K (27 °C), permite determinar que, a máxima radiância espectral excitante proveniente dos elementos terrestres, ocorre num comprimento de onda situado próximo dos 9,7 μm . Como esta radiação está correlacionada com o “calor” terrestre, é designada de energia infravermelha térmica e o seu longo comprimento de onda faz com que não seja perceptível à vista humana, podendo apenas ser observada através de sistemas não fotográficos como os radiómetros e os sensores térmicos situados a bordo de alguns satélites. A dificuldade de registar informação emitida nestes comprimentos de onda faz com que, mais do que relativamente aos sensores que recolhem dados na região do visível, os sensores térmicos operem nas regiões do espectro onde se situa o pico de exitância espectral radiante. Assim, um sensor térmico situado a bordo de um satélite que tivesse por missão captar a energia emitida pelos elementos terrestres (300 K) deveria operar entre os 9,5 e os 10 μm .

Os materiais reais da superfície terrestre emitem apenas uma fracção da energia que um corpo negro, à mesma temperatura, emitiria. Este défice relativamente ao óptimo, o qual traduz o grau de eficiência com que um corpo irradia energia, é designado por **emissividade** $\varepsilon(\lambda)$, traduzindo-se numericamente por:

$$\varepsilon(\lambda) = \frac{M_{CR}(\lambda)}{M(\lambda)}, \quad (2.14)$$

onde $M_{CR}(\lambda)$ corresponde à exitância espectral de um objecto a uma determinada temperatura e $M(\lambda)$ à exitância espectral de um corpo negro nas mesmas condições.

A emissividade varia entre 0 (não é emitida nenhuma da energia absorvida) e 1 (toda a energia absorvida é emitida), sendo dependente do comprimento de onda, do ângulo de incidência da radiação e, para alguns materiais, da temperatura.

Um corpo negro apresenta um índice de radiação superior aos materiais reais o que, aliado ao facto de emitir toda a energia que é absorvida, lhe vale a designação de emissor perfeito. Para

estender os princípios postulados pela lei de Stefan-Boltzmann a situações reais é necessário considerar o factor de emissividade - ε - podendo-se escrever [42]:

$$M_{CR} = \varepsilon \sigma T^4 . \quad (2.15)$$

Muito embora na natureza não exista nenhum corpo negro, há no entanto elementos que se comportam aproximadamente como tal em regiões específicas do espectro. Por exemplo, a água apresenta entre os 6 e os 14 μm , valores de emissividade muito próximos do ideal (entre 0,98 e 0,99). Um corpo que apresente uma emissividade inferior a 1 (figura 2.5) mas constante ao longo de todos os comprimentos de onda designa-se por **corpo cinzento**. Se, a emissividade for dependente de λ , então está-se perante um **radiador selectivo**.

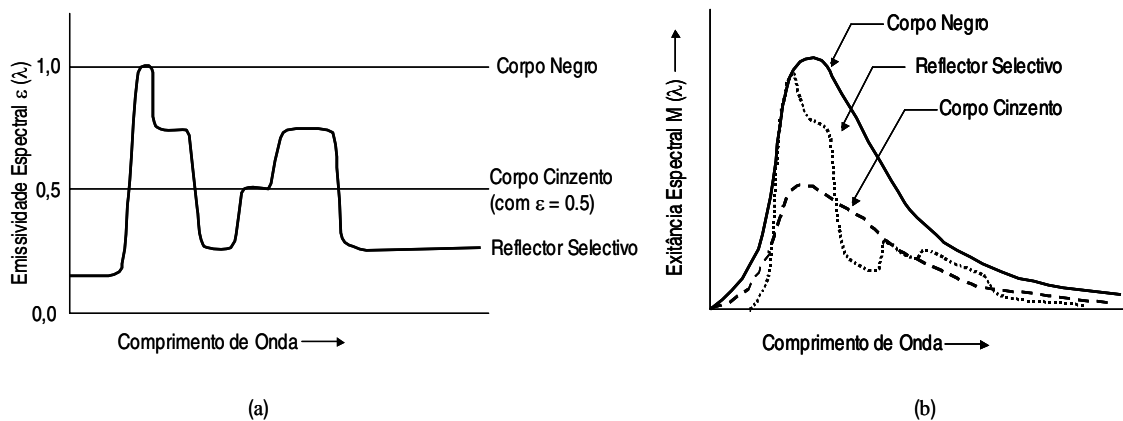


Figura 2.5 – Emissividade espectral (a) e exitância espectral (b) para um corpo negro, um corpo cinzento e um radiador selectivo

2.5 INTERACÇÕES DA ENERGIA ELECTROMAGNÉTICA COM A MATÉRIA

Quando a energia electromagnética incide sobre a matéria, podem ocorrer essencialmente três tipos de interacções: **reflexão**, **transmissão** e **absorção** (figura 2.6):

1. Reflexão – Quando a radiação incide, segundo a direcção θ_1 , sobre superfícies consideradas lisas relativamente ao seu comprimento de onda, é reflectida novamente com o ângulo θ_1 mas no lado oposto da normal, o que significa que o ângulo de reflexão é igual ao ângulo de incidência (figura 2.6). Se isto não se verificar, a forma como a energia electromagnética é reflectida depende da rugosidade da superfície. A quantidade de energia reflectida pelo objecto, e que alcança o sensor, depende da energia total incidente, da estrutura da superfície, do ângulo de incidência e do comprimento de onda.

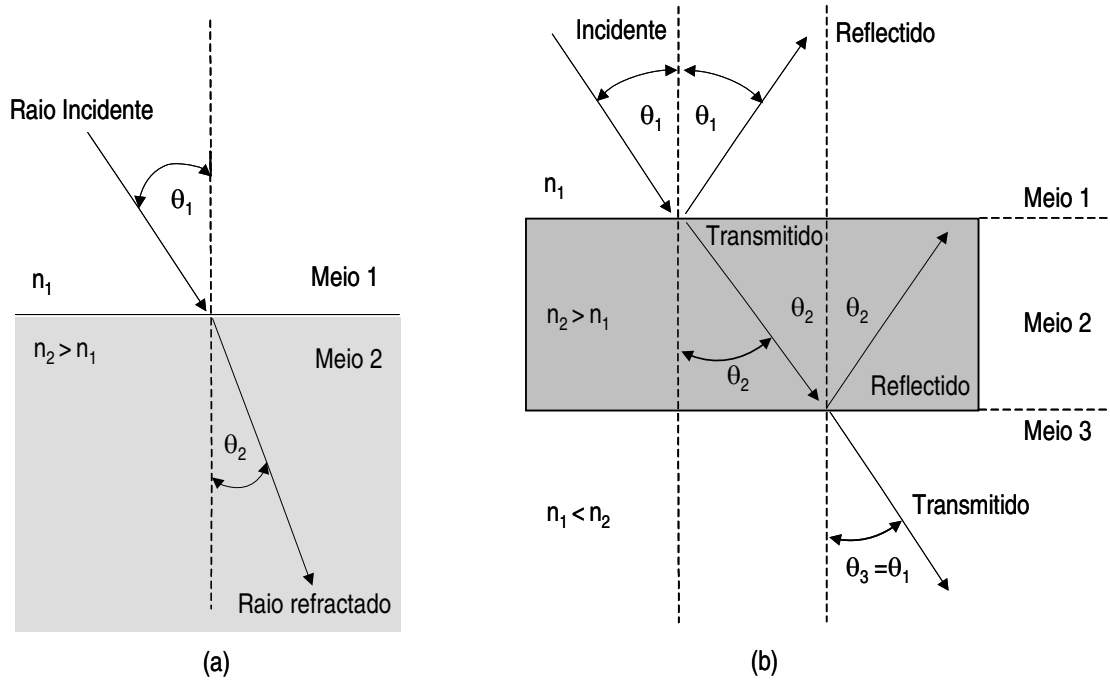


Figura 2.6 – Interação da radiação com a matéria

Considerando a forma geométrica como os objectos reflectem a energia incidente, pode dividir-se a reflexão em três grandes grupos:

A. Reflexão Especular (figura 2.7-a) - quando está presente uma superfície perfeitamente lisa, cujo comportamento se assemelha a um espelho, no qual a energia é reflectida com ângulo igual ao de incidência. É o exemplo da superfície de águas calmas, alguns tipos de rocha, telhados de instalações industriais, materiais de muito fraca rugosidade e com taxas de absorção e transmissão quase nulas.

B. Reflexão Difusa ou Lambertiana (figura 2.7-b) - quando a energia incidente sobre uma dada superfície é reflectida uniformemente em todas as direcções, independentemente do ângulo de incidência. As superfícies deste tipo são designadas de **Radiadores Lambertianos** ou **Reflectores Lambertianos** e a sua radiância é independente do ângulo de observação.

C. Reflexão Mista (figura 2.7-c e d) – a maioria dos objectos à superfície terrestre não se comporta como um reflector (especular ou difuso) ideal, por isso a reflexão mista, situada algures entre estes dois extremos, é o tipo de reflexão mais comum, no que se refere ao comportamento das superfícies face à energia incidente.




Figura 2.7 – Reflectância Especular versus Reflectância Difusa

A reflexão imprevisível da radiação, provocada pelas partículas existentes na atmosfera, dá origem ao fenómeno designado de **dispersão** (ou **difusão**) **atmosférica**. O total de radiação dispersa está relacionado com as características ópticas do meio difusor (ex. densidade). Consequentemente, pode-se afirmar que a dispersão resulta da heterogeneidade óptica do meio.

A atenuação da radiação pela dispersão pode ser quantificada através do **coeficiente de dispersão** $\beta(\lambda)$, comprimento recíproco, expresso em m^{-1} , que traduz a fracção da área total das partículas existentes na atmosfera, que remove o fluxo incidente, sendo definido por:

$$\beta(\lambda) = -\frac{1}{I} \frac{dI(\lambda)}{dx} \quad (2.16)$$

com

$$\frac{dI(\lambda)}{dx} = -\alpha(\lambda, x)I(x), \quad (2.17)$$

onde $I(x)$ é a intensidade radiante à profundidade x , $\alpha(\lambda, x)$ o coeficiente de absorção do meio e x a distância percorrida pela onda.

O **coeficiente de absorção** é característico do meio e depende do comprimento de onda. Tal como o próprio nome indica, corresponde à intensidade radiante que é absorvida por unidade de comprimento e expressa-se em m^{-1} . A intensidade da radiação ao longo do percurso pode ser calculada integrando (2.17):

$$I(x) = I(0)e^{\left(-\int_0^x \alpha(\lambda, x') dx'\right)}, \quad (2.18)$$

onde I_0 é a intensidade radiante à superfície (incidente).

Se o meio for homogéneo (α não depende de x) resulta, de (2.18) que:

$$I(x) = I(0)e^{(-\alpha(\lambda)x)}, \quad (2.19)$$

relação conhecida por **lei de Beer** (ou também **lei de Bourguer** ou **lei de Lambert-Beer**). Neste caso, após percorrida a distância $1/\alpha$, a radiação é atenuada de $1/e$ do seu valor inicial.

O integral do coeficiente de absorção ao longo do percurso x_1, x_2 resulta numa grandeza adimensional - $\tau(x_1, x_2)$ - conhecida como **espessura óptica** ou **profundidade óptica**:

$$\tau(x_1, x_2) = \int_{x_1}^{x_2} \alpha(x') dx'. \quad (2.20)$$

2. Absorção – O fenómeno da absorção deve-se à existência de trocas de energia entre a onda e os átomos de um determinado corpo, tendo como principal consequência o aumento da temperatura do corpo. Para uma camada de espessura infinitesimal (dx), a absorção processa-se de forma proporcional à intensidade radiante, dando origem a uma redução desta intensidade que se pode representar pela equação diferencial (2.17)[35].

Se num determinado meio a radiação é atenuada tanto pela absorção como pela dispersão, os dois efeitos podem ser combinados através do designado coeficiente de extinção $K(\lambda)$:

$$K(\lambda) = \alpha(\lambda) + \beta(\lambda) . \quad (2.21)$$

3. Transmissão –Este processo ocorre, quando, meios de densidades diferentes (figura 2.6-b), provocam alterações na velocidade e direcção de propagação do feixe electromagnético. Neste caso a energia incidente no ângulo θ_1 ao encontrar um meio de densidade diferente, vai ser transmitida ao longo desse meio numa direcção θ_2 . A relação entre a velocidade de propagação da energia electromagnética no vácuo (c) e na substância (c_s) é definida por **índice de refração** do material (n) e expressa-se através da equação:

$$n = \frac{c}{c_s} . \quad (2.22)$$

Quando o feixe transita entre dois meios de índice de refração diferente ocorre, na superfície de separação dos meios, o processo conhecido como refração (figura 2.6). De acordo com a **lei de Snell** a relação entre o ângulo de incidência (θ_1) e o ângulo de refração (θ_2) é dada por:

$$\frac{\text{sen}\theta_1}{\text{sen}\theta_2} = \frac{n_2}{n_1}, \quad (2.23)$$

onde n_1 e n_2 são respectivamente os índices de refração dos meios 1 e 2.

A Emissão, a Reflexão e a Dispersão são designadas de fenómenos de superfície, na medida em que dependem principalmente das características exteriores dos objectos (como por exemplo a rugosidade), podendo ser medidas externamente. A Transmissão e a Absorção dependem essencialmente das características internas dos objectos (tais como a densidade e condutividade, a composição geoquímica ou a estrutura biológica interna) não podendo ser medidas externamente e sendo por estas mesmas razões designadas de fenómenos de volume.

2.6 INTERACÇÃO DA ENERGIA ELECTROMAGNÉTICA COM OS ELEMENTOS TERRESTRES

Quando a energia electromagnética incide sobre os objectos situados à superfície terrestre, são criadas as condições para que ocorram três fenómenos: Reflexão, Absorção e Transmissão. Esses três fenómenos (figura 2.8) dependem das características físicas do objecto, do comprimento de onda, do ângulo de incidência da radiação electromagnética e, em menor escala, da matéria constituinte do corpo e podem ser relacionados de acordo com o princípio de conservação de energia:

$$E_I(\lambda) = E_R(\lambda) + E_A(\lambda) + E_T(\lambda) \quad (2.24)$$

onde

$E_I(\lambda)$ - energia incidente;

$E_R(\lambda)$ - energia reflectida;

$E_A(\lambda)$ - energia absorvida;

$E_T(\lambda)$ - energia transmitida.




Figura 2.8 – Possíveis interações entre a energia eletromagnética e os elementos da superfície terrestre

Relativamente a (2.24) devem-se fazer duas chamadas de atenção: em primeiro lugar, a proporção de energia reflectida, absorvida e transmitida, varia consoante o objecto sobre o qual a energia incide. São estas diferenças que permitem distinguir os diversos objectos registados na imagem. Em segundo lugar, o facto de estas três grandezas serem dependentes do comprimento de onda, significa que, mesmo para o mesmo objecto, as suas proporções alteram-se face a variações do comprimento de onda da energia incidente. Mais, dois objectos podem ser indiferenciáveis numa determinada região do espectro e aparecerem como bastante diferentes noutra.

Como a maioria dos sistemas de teledetecção (com excepção das bandas térmicas) funcionam em regiões do espectro em que predomina a energia reflectida, a reflectância dos objectos assume particular importância. Assim, é usual escrever (2.24) como:

$$E_R(\lambda) = E_I(\lambda) - [E_A(\lambda) + E_T(\lambda)], \quad (2.25)$$

Por outro lado, também é importante ter em consideração a forma geométrica como os objectos reflectem a energia incidente. Este factor varia primordialmente em função da rugosidade da superfície do objecto.

A superfície dos objectos existentes na superfície terrestre, é classificada como especular, difusa ou mista em função da sua rugosidade face ao comprimento de onda da energia incidente. Por exemplo, enquanto que para um comprimento de onda superior a 10 cm (rádio) um terreno

rochoso pode parecer liso, para um comprimento de onda situado entre os 0,4 e 0,7 μm (visível) até a areia da praia é rugosa [42]. Resumindo, quando o comprimento de onda da energia incidente é bastante mais pequeno que as variações de altitude da superfície ou que a dimensão das partículas que a compõem, então essa superfície é considerada rugosa. Como a reflexão especular não contém informação espectral sobre a “cor” da superfície reflectora (não reflecte energia na direcção do sensor) e a reflexão difusa contém, esta última é a que detém principal importância em termos de teledeteccção.

No caso específico da energia térmica, o interesse centra-se em medir a radiação emitida pelos objectos. No entanto, a energia emitida pelos objectos, depende usualmente da energia que sobre eles incide. Recordando o princípio da conservação da energia (2.24) e dividindo todos os seus termos pela energia incidente, pode rescrever-se a equação (2.24) como:

$$1 = \frac{E_R(\lambda)}{E_I(\lambda)} + \frac{E_A(\lambda)}{E_I(\lambda)} + \frac{E_T(\lambda)}{E_I(\lambda)}. \quad (2.26)$$

Os termos situados no lado direito de (2.27) correspondem a grandezas com especial importância na descrição das interacções da energia térmica com a matéria. Assim, definem-se:

$$\rho(\lambda) = \frac{E_R(\lambda)}{E_I(\lambda)}, \quad \delta(\lambda) = \frac{E_A(\lambda)}{E_I(\lambda)}, \quad \mathcal{G}(\lambda) = \frac{E_T(\lambda)}{E_I(\lambda)}, \quad (2.27)$$

onde

$\delta(\lambda)$ - absorção espectral do elemento de terreno;

$\rho(\lambda)$ - reflexão espectral do elemento de terreno;

$\mathcal{G}(\lambda)$ - transmissão espectral do elemento de terreno.

Considerando (2.27) pode-se apresentar (2.24) como:

$$\delta(\lambda) + \rho(\lambda) + \mathcal{G}(\lambda) = 1, \quad (2.28)$$

onde se tem a relação entre as propriedades de absorção, reflexão e transmissão dos elementos de terreno. A **Lei de Radiação de Kirchoff** diz que, em condições de equilíbrio térmico, a emissividade espectral de um objecto é igual à sua absorção espectral:

$$\varepsilon(\lambda) = \delta(\lambda). \quad (2.29)$$

Como esta equação se baseia numa condição de equilíbrio térmico pode ser aplicada (em teledetecção) em quase todos os casos, o que permite substituir $\alpha(\lambda)$ por $\varepsilon(\lambda)$ em (2.28), resultando em:

$$\varepsilon(\lambda) + \rho(\lambda) + \vartheta(\lambda) = 1, \quad (2.30)$$

Na maioria das aplicações em teledetecção os corpos em observação são tidos como opacos face à radiação térmica ($\vartheta(\lambda) = 0$), tornando possível simplificar a equação anterior para:

$$\varepsilon(\lambda) + \rho(\lambda) = 1. \quad (2.30a)$$

Assim, na região do térmico, observa-se uma relação directa entre a emissividade e a reflectância, traduzindo-se um aumento da primeira na diminuição da segunda e vice-versa.

2.7 INTERACÇÃO DA ENERGIA ELECTROMAGNÉTICA COM A ATMOSFERA

A atmosfera é, ao nível do solo, composta essencialmente por Nitrogénio e Oxigénio, mas existem outros elementos (tabela 2.3), ao mesmo nível ou já na alta atmosfera, que detêm um papel assaz importante no desenrolar do processo de aquisição de imagens. Estão nesta situação o Vapor de Água (H₂O) e o Dióxido de Carbono e, com o aumento da altitude, o Ozono e o Hélio.

Para além dos gases e da água são ainda parte constituinte da atmosfera os aerossóis. Estes, apresentam uma dimensão situada entre os 10⁻⁴ e os 10 µm, e mais não são do que partículas em suspensão, no estado sólido ou líquido, geradas da interacção de gases enviados para a atmosfera através de processos de índole natural (actividade vulcânica, incêndios florestais, etc.), ou artificial (incineração de lixos, combustões automóveis, etc.), da erosão eólica e da libertação de partículas de sal pelo *white clapping* (“corte” da crista das ondas pelo vento) e pela rebentação das ondas [22].

A atmosfera tem, como uma das suas principais características, o papel de “filtro” perante determinados comprimentos de onda (como é o caso dos raios gama, raios X e uma grande parte dos raios ultravioletas). Em virtude da interacção entre a radiação electromagnética e as partículas em suspensão na atmosfera (gases permanentes, partículas sólidas, aerossóis, etc.), ocorrem dois tipos de fenómenos que podem mesmo impossibilitar a obtenção de informação por satélite: difusão (*scattering*) e absorção, cujos efeitos variam consoante a região do espectro

electromagnético. As regiões que lhes são “ímmunes” são designadas por “janelas atmosféricas”, na medida em que permitem a passagem da radiação electromagnética através da atmosfera sem grandes alterações da sua intensidade.

| Gás Constituinte | Símbolo | Quantidade (%) |
|---------------------------|------------------|--|
| Nitrogénio | N ₂ | 78,084 |
| Oxigénio | O ₂ | 20,9476 |
| Árgon | Ar | 0,934 |
| Dióxido Carbono | CO ₂ | 0,0314 |
| Néon | Ne | 0,001818 |
| Hélio | He | 0,0000524 |
| Krypton | Kr | 0,0000114 |
| Xénon | Xe | 0,0000087 |
| Hidrogénio | H ₂ | 0,000005 |
| Metano | CH ₄ | 0,0002 |
| Óxido Nítrico | N ₂ O | 0,00005 |
| Ozono | O ₃ | Verão: 0 a 0,000007 Inverno: 0 a 0,000002 |
| Dióxido Sulfúrico | SO ₂ | 0 a 0,0001 |
| Dióxido Nitrogénio | NO ₂ | 0 a 0,000002 |
| Amónia | NH ₃ | 0 ao detectado |
| Monóxido Carbono | CO | 0 ao detectado |
| Iodo | I ₂ | 0 a 0,000001 |

Tabela 2.3 – Composição da atmosfera ao nível do mar

Assim, da energia que entra na atmosfera, uma parte é difundida e outra absorvida, chegando a restante ao solo. Esta última não provém, na sua totalidade, directamente do Sol (22%) mas também da dispersão e reflexão provocadas pelos constituintes atmosféricos (78%). A Terra reflecte uma parte dessa energia (4%), absorvendo 47% (22% de energia directa e 25% de energia difusa) do total de energia incidente na superfície [55].

2.7.1 Dispersão atmosférica

A **dispersão (ou difusão)** atmosférica resulta da interacção entre a radiação electromagnética e as partículas e/ou moléculas de gás presentes na atmosfera, tais como o vapor de água e aerossóis, provocando a redistribuição da energia em torno das partículas difusoras. O seu efeito

está dependente das condições meteorológicas e da altura do Sol, que por sua vez está condicionada pela estação do ano e pela hora do dia.

Embora a dispersão pareça ser um fenómeno similar à absorção é, no entanto, bastante mais complexa. De facto, a radiação dispersa (considerando que não existe absorção posterior) nunca se perde, podendo ser dispersa mais do que uma vez, e até voltar a integrar o feixe de radiação inicial. A probabilidade da radiação ser dispersa mais do que uma vez está directamente relacionada com a atenuação total que esta sofre, devido à dispersão, ao longo do caminho percorrido.

Existem várias formas de difusão. No entanto, os principais tipos dividem-se entre **difusão selectiva** e **não selectiva**. A difusão selectiva afecta comprimentos de onda específicos da radiação electromagnética, enquanto que a difusão não selectiva é independente destes, ocorrendo em situações em que a dimensão das partículas é de tal ordem que afecta de forma homogénea todos os comprimentos de onda. Posto isto, pode-se definir difusão não selectiva como aquela que é independente do comprimento de onda da radiação, sendo provocada por partículas com um diâmetro muito elevado ($> 10 \mu m$), de que são exemplo as partículas de gelo presentes nas nuvens. Todos os comprimentos de onda do visível são difundidos por estas partículas, facto que explica a cor branca das nuvens e do nevoeiro.

Por outro lado, a dispersão provocada pelas pequenas partículas está directamente dependente do seu raio (R) e do o comprimento de onda, sendo estes dois factores relacionados pela medida (adimensional) q :

$$q = \frac{2\pi R}{\lambda} . \quad (2.31)$$

No âmbito da difusão selectiva, deverão ser consideradas:

1. A difusão de Rayleigh, que ocorre quando a radiação interage com partículas cujo diâmetro é inferior ao comprimento de onda da radiação. Neste caso, $q \ll 1$, pelo que a dispersão é muito fraca e proporcional a λ^{-4} . Dentro da região do visível, os pequenos comprimentos de onda (azul, violeta) são difundidos em mais larga escala que os mais longos (vermelho). A difusão de *Rayleigh* é a que mais influência exerce na teledetecção, sobretudo na banda azul da região visível, sendo responsável pela cor azul do céu e pela sua tonalidade avermelhada do entardecer. Esta difusão provoca numa imagem obtida por teledetecção um efeito designado *haze* (névoa) que, na prática, corresponde a uma diminuição do contraste dessa mesma imagem. Se a imagem

for colorida então o efeito da difusão detecta-se por uma tonalidade cinzento-azulada, a qual é tanto maior quanto maior for a altitude a que é captada a imagem (o que originou o fim da utilização da banda azul na região do visível em teledeteccção).

2. A difusão de Mie, apresenta uma complexidade bastante superior ao caso precedente e constitui uma situação intermédia entre este e a difusão não selectiva, ocorrendo quando as partículas atmosféricas possuem diâmetros semelhantes aos comprimentos de onda da radiação ($q \approx 1$). A sua complexidade deriva da refacção e da interferência causada pela luz dispersa de diferentes partes da superfície da partícula. Esta forma de difusão é anisotrópica (contrariamente à difusão de *Rayleigh*) e a distribuição angular dos fotões difundidos varia principalmente em função da dimensão das partículas e do comprimento de onda (embora não de forma tão acentuada como na difusão de *Rayleigh*). A figura 2.9 representa-a em três situações distintas, mais propriamente para um comprimento de onda de $0,05 \mu\text{m}$ e para três dimensões de raio (R) das partículas ($0,05 \mu\text{m}$, $0,1 \mu\text{m}$ e $0,5 \mu\text{m}$), verificando-se grandes variações no ângulo de dispersão.




Figura 2.9 – Distribuição Angular da Difusão de Mie

2.7.2 Absorção

A **absorção** contrasta com a dispersão, na medida em que resulta na perda efectiva de energia para os elementos constituintes da atmosfera (a energia radiante é transformada nouro tipo de energia), em função do comprimento de onda da radiação. Existem gases constituintes da atmosfera com grande responsabilidade nesta acção, actuando em zonas específicas do espectro electromagnético, por isso designadas de “zonas de absorção” (figura 2.10).

Na perspectiva da teledeteccção, o Dióxido de Carbono, o Ozono e o Vapor de Água são os principais intervenientes no fenómeno da absorção, merecendo pois uma análise mais detalhada:

O Dióxido de Carbono absorve energia com comprimentos de onda correspondentes à região do infravermelho próximo, principalmente a dos 4,3 μm e toda a radiação superior a 14 μm (infravermelho térmico). O ozono, impede que os raios ultravioleta (0,3 μm) atinjam o solo. Apesar da sua acção se fazer sentir abaixo dos 0,3 μm , e nas bandas dos 0,5 μm , 9,6 μm e 14 μm , a concentração deste gás junto à superfície é diminuta, traduzindo-se numa absorção insignificante de radiação. Por fim, a quantidade de vapor de água (expressa em g/m^3) – não confundir com a água já condensada que dá origem ao orvalho e ao nevoeiro – varia bastante no tempo e no espaço o que levou à sua exclusão da tabela 1.3. A sua acção faz-se normalmente notar nos comprimentos de onda 1,4 μm , 2,66 μm , 2,74 μm e 6,25 μm .

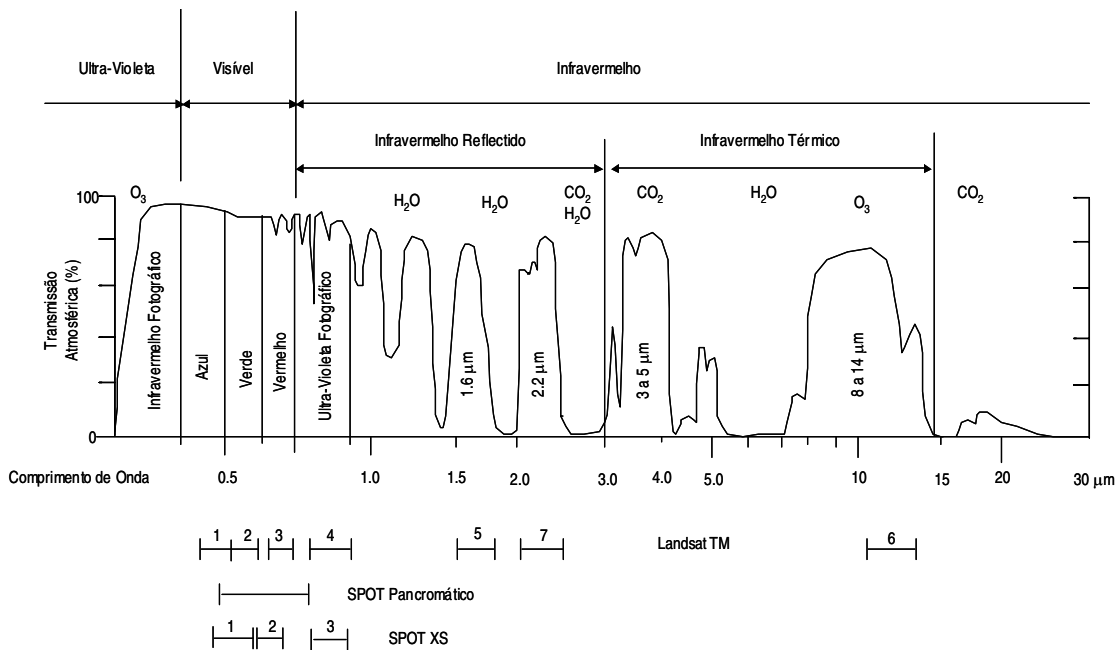


Figura 2.10 – Janelas atmosféricas e principais zonas de absorção

Importa ainda referir a absorção levada a efeito pelas partículas, líquidas ou sólidas, em suspensão na atmosfera, cujo diâmetro varia entre $10^{-4} \mu\text{m}$ e $10 \mu\text{m}$ são conhecidas como aerossóis. A absorção pelos aerossóis é conhecida como albedo de dispersão singular e corresponde à razão entre a radiação reflectida e incidente no aerossol (varia entre 0 = totalmente absorvente e 1 = totalmente difusor).

Exposta, a interacção entre a radiação electromagnética e a atmosfera, pode-se concluir que só as regiões espectrais onde os efeitos anteriormente descritos se fazem sentir de forma bastante moderada é que permitem a obtenção de imagens da Terra sendo por isso designadas de “janelas atmosféricas”. Fora destas regiões, as imagens de satélite obtidas provêm unicamente dos sensores activos. As principais janelas atmosféricas são o visível e o infravermelho próximo

(0,5 μm a 1,4 μm) e o infravermelho térmico (4,4 μm a 5,5 μm e 8 μm a 14 μm). A região entre os 8 μm e os 14 μm é de extrema importância pois corresponde ao máximo de energia emitida pela Terra. A importância das “janelas atmosféricas” está bem patente na figura 1.9, onde se pode observar que as bandas espectrais dos sensores a bordo dos satélites SPOT e Landsat coincidem, grosso modo, com as ditas janelas.

2.7.3 Transmitância da atmosfera

A **transmitância da atmosfera** $TR(\lambda)$, é uma medida da “transparência” da atmosfera à propagação da radiação electromagnética, estando relacionada com os fenómenos da absorção e da dispersão. Para definir a espessura óptica da atmosfera recorre-se à noção de espessura óptica (2.21), que corresponde ao integral do coeficiente de absorção num determinado percurso. Como na atmosfera a radiação incidente é não apenas absorvida, mas também dispersa, substitui-se, em (2.17), $\alpha(\lambda)$ por $K(\lambda)$ que conjuga os efeitos provocados pela dispersão e pela absorção (2.18). A espessura óptica da atmosfera $\tau_a(\lambda)$ fica então determinada por:

$$\tau_a(\lambda) = \int_0^{\infty} K(\lambda) dz, \quad (2.32)$$

onde

$K(\lambda)$ - coeficiente de extinção da atmosfera;

z - altitude (varia entre 0 e $+\infty$, correspondendo o valor nulo à superfície terrestre).

Em termos práticos quanto mais elevada for a espessura óptica, maior será a quantidade de energia emitida, por exemplo pelo Sol, a atingir a superfície terrestre. Nem toda a radiação atravessa a atmosfera, o que não representa nenhum dado novo, na medida em que é do conhecimento comum que esta serve como de filtro de protecção do planeta. O que é premente saber neste caso é o grau com que a radiação electromagnética é filtrada à medida que se propaga através da camada atmosférica, o que nos é facultado pela sua espessura óptica. Considerando um percurso perpendicular à superfície terrestre é possível relacionar a transmitância com a espessura óptica através da expressão [22]:

$$TR(\lambda) = \exp(-\tau_a(\lambda)). \quad (2.33)$$

À semelhança do que se verifica no caso da difusão também a espessura óptica da atmosfera é fruto de vários factores, traduzindo-se pela conjugação de três tipos de espessura: a que está

relacionada com a dispersão originada por aerossóis e por isso designada de espessura óptica de *Mie* (τ_{Mie}), a que decorre em função da dispersão por moléculas de gases e por isso denominada de espessura óptica de *Rayleigh* (τ_{Ray}) e por fim a espessura óptica resultante da absorção selectiva originada pelos gases (O_2 - CO_2 que actuam conjuntamente, e O_3 cujo comportamento se faz sentir de forma independente dos outros dois) e vapor de água (H_2O) que compõem a atmosfera (τ_{Abs}).

2.8 ENERGIA CAPTADA PELO SENSOR

Apesar de ser pouco afectada durante o seu percurso através do vácuo, a radiação solar é absorvida e dispersa de forma selectiva ao entrar na atmosfera. Estes dois efeitos atmosféricos incidem sobre a radiância detectada pelo sensor de duas formas contraditórias, mas que actuam simultaneamente. O primeiro processo consiste na atenuação da radiação que chega realmente ao solo e o segundo em a própria atmosfera funcionar como difusor e introduzir, na radiação captada pelo sensor energia “extra”. Desta forma o sinal captado por um sensor (figura 2.11) é o resultado das alterações sofridas pela irradiância solar incidente (na vertical) no topo da atmosfera ao longo de todo o percurso descendente até ao solo, da sua interacção com a superfície terrestre e do seu percurso ascendente em direcção ao satélite. O somatório destas duas “perdas” de energia (dispersão e absorção) é designado de **atenuação da atmosfera**.

Quando se regista em grande escala, esta atenuação pode:

1. tornar difícil a correspondência entre a radiância medida sobre o objecto, com a ajuda de um radiómetro, e a radiância registada pelo sensor a bordo do satélite;
2. tornar difícil a comparação de locais e/ou datas diferentes;
3. ter um impacto negativo na exactidão da classificação de imagens, se a atenuação atmosférica variam significativamente nessa imagem.

Apesar destas três condicionantes é incorrecto afirmar que na informação obtida por teledeteccção existe um erro induzido pela atmosfera. A energia registada pelo sensor é um sinal verdadeiro, mesmo quando inviabiliza a medição dos padrões de reflectância dos elementos da superfície terrestre. Para os cientistas que investigam a atmosfera, por exemplo, a energia dispersa e absorvida é por vezes encarada como o sinal e a reflectida como o ruído. No entanto, a grande maioria dos que estudam os recursos terrestres considera a absorção e a dispersão como fontes de erro, capazes de minimizar a sua capacidade para extrair informação útil sobre os objectos e/ou fenómenos em estudo, a partir de dados provenientes de sensores remotos.




Figura 2.11 – Interação da radiação com a atmosfera e a superfície terrestre

Numa perspectiva idealista, a energia radiante registada pelo sensor deve corresponder unicamente à quantidade de fluxo radiante proveniente do objecto em estudo. Infelizmente, pode acontecer que outros tipos de energia radiante se venham imiscuir no fluxo principal durante o seu percurso pela atmosfera. A figura 2.11 esquematiza os vários factores e percursos da radiação, que determinam a radiância que chega até ao sensor, verificando-se a existência de 5 percursos:

1. contém energia electromagnética proveniente do Sol e que foi muito pouco atenuada no seu percurso até à superfície terrestre;
2. contém energia electromagnética que, devido à dispersão, poderá nunca atingir a superfície. Infelizmente esta energia é frequentemente dispersa na direcção do campo de observação do sensor;
3. contém energia proveniente do Sol sobre a qual incidiram fenómenos como a dispersão de *Rayleigh*, *Mie* e/ou não selectiva, e possivelmente a absorção e a reemissão. A sua composição espectral e polarização podem ser de algum modo diferentes da energia associada ao percurso 1;

4. o percurso 4 contém radiação que foi reflectida ou dispersa pelos elementos que se encontram na vizinhança da área em estudo (água, betão, telha, etc.) e que se vai imiscuir no sinal registado pelo sensor. Esta energia não incide sobre a área de estudo;
5. corresponde à energia que foi reflectida para a atmosfera pelos elementos adjacentes à área em observação e que posteriormente foi dispersa ou reflectida na direcção da área de estudo, constituindo um fenómeno designado de **efeito de adjacência**.

Para um determinado intervalo espectral (λ_1, λ_2) a irradiância solar que atinge a superfície terrestre (E_g) obtém-se de referência:

$$E_g = \int_{\lambda_1}^{\lambda_2} (E_0(\lambda)TR(\theta_0, \lambda)\cos\theta_0 + E_D(\lambda))d\lambda, \quad (2.34)$$

onde

$E_0(\lambda)$ - irradiância solar espectral no topo da atmosfera;

θ_0 - ângulo solar zenital;

$TR(\theta_0, \lambda)$ - transmitância da atmosfera no ângulo solar zenital. A transmitância da atmosfera é uma medida de “transparência” da atmosfera à propagação da radiação electromagnética, estando relacionada com os fenómenos de absorção e de dispersão. Para uma análise deste fenómeno consultar [22];

$E_D(\lambda)$ - irradiância espectral difusa.

No entanto, apenas uma pequena quantidade desta irradiância é reflectida na direcção do sensor. Assumindo que a Terra é um reflector difuso, a quantidade de fluxo radiante que deixa a Terra em direcção ao sensor (L_T) é dada por

$$L_T = \frac{1}{\pi} \int_{\lambda_1}^{\lambda_2} \rho(\lambda)TR(\theta_s)(E_0(\lambda)TR(\theta_0)\cos\theta_0 + E_D(\lambda))d\lambda, \quad (2.35)$$

onde

$\rho(\lambda)$ - reflectância média do objecto em estudo;

θ_s - ângulo de observação do sensor a bordo do satélite.

Numa situação ideal, a radiância registada pelo sensor (L_S) seria igual à que é reflectida pela área em estudo. Infelizmente tal não acontece sendo, L_S diferente de L_T devido à existência de radiação com origem noutros percursos atmosféricos que se vai adicionar a L_T e,

consequentemente, alterar os seus valores. Esta energia extra é designada por **radiação do percurso atmosférico** (L_P). A radiância total registada pelo sensor pode ser agora descrita como:

$$L_S = L_T + L_P. \quad (2.36)$$

O valor de cada pixel de uma imagem de satélite (ou **nível radiométrico** (NR) do pixel), resulta da conversão analógico-digital da radiância captada pelo sensor, perdendo-se nesta opção o valor absoluto da radiância. Para se recuperar o valor absoluto da radiância (L_S), procede-se à **calibração** da imagem. O objectivo desta operação é garantir uma correspondência, o mais perfeita possível, entre os valores de NR e L_S , para toda a imagem. Normalmente, os sensores são desenhados para produzir uma resposta linear à radiância espectral incidente. Esta resposta varia de banda para banda e as suas características são monitorizadas através de lâmpadas de calibração existentes a bordo do satélite. A radiância espectral absoluta emitida pelas lâmpadas é conhecida em virtude destas terem sido calibradas antes do lançamento do satélite e é considerada estável ao longo do período de actividade do sensor. As lâmpadas de calibração são a base da função que permite relacionar a radiância com o NR , através da expressão

$$NR = GL_S - D, \quad (2.37)$$

onde

G - ganho¹ (*gain*) do sensor (fornecido pelo fabricante);

D - desvio² (*offset*) do sensor (fornecido pelo fabricante).

Esta forma de calibração não corrige os erros induzidos pela dispersão e pela absorção. Como se referiu atrás, estes efeitos podem diminuir a capacidade de interpretação e/ou extracção da informação obtida por teledeteccção, na medida em que ou provocam um aumento no NR registado pelo sensor (dispersão) ou conduzem a uma diminuição desse valor (absorção).

Os efeitos da dispersão podem ser atenuados através da aplicação de algumas técnicas estatísticas, como é o caso do “ajuste dos histogramas”[42]. Relativamente à absorção, a resolução do problema não é tão simples, envolvendo o conhecimento das condições atmosféricas na altura em que foi captada a imagem.

¹ Corresponde ao declive da recta de regressão entre os níveis radiométricos e a radiância registada pelo sensor.

² A recta de regressão acima referida não intersecta o eixo do XX no origem, pois existe um valor mínimo de radiância que vai corresponder a um NR de zero. A este desfazamento, que corresponde à origem da recta de regressão, dá-se o nome de desvio do sensor.

2.9 INTERACÇÃO DA ENERGIA ELECTROMAGNÉTICA COM OS ELEMENTOS URBANOS

Em meio urbano verifica-se uma grande heterogeneidade de usos, traduzida numa dificuldade acrescida em classificar os elementos apenas com base na sua resposta espectral. A figura 2.12, apresenta os **coeficientes de reflexão** ou **curvas de reflectância espectral** - $\rho(\lambda)$ - para diversos elementos existentes em meio urbano [21].

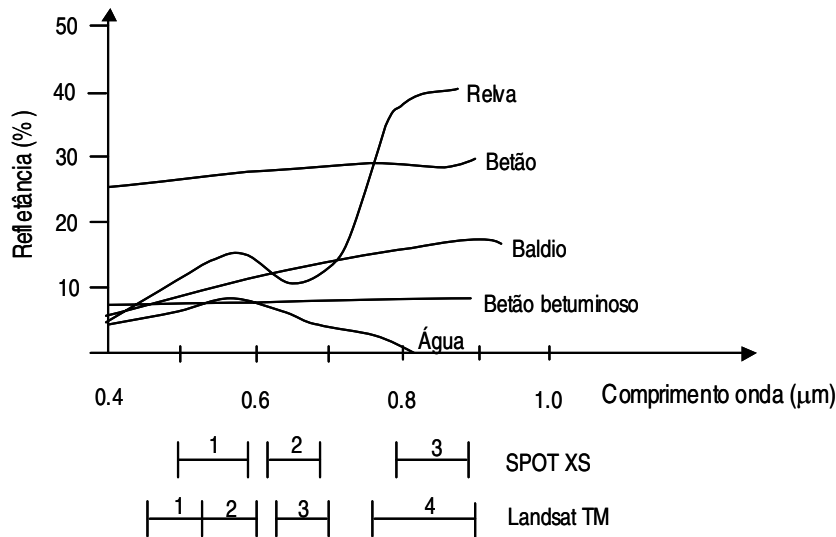


Figura 2.12 – Curvas de reflectância espectral de tipos de coberto de solo urbano

A configuração destas curvas fornece informação sobre as bandas em que a assinatura espectral do coberto em questão é suficiente que o diferencie dos restantes, podendo verificar-se duas situações distintas: a primeira, observada entre os 0,4 μm e os 0,7 μm (englobando as bandas SPOT XS1 e XS2 e Landsat TM 1, 2 e 3), evidencia um dos principais problemas da classificação espectral, ou seja, o facto de objectos diferentes serem registados com o mesmo NR, enquanto que na segunda observada entre os 0,7 μm e o 1,0 μm, já é viável uma certa diferenciação entre os elementos. No primeiro caso, chega a existir uma certa “confusão” entre dois elementos tão distintos como a água e o betão betuminoso (asfalto), devido a ambos se comportarem como reflectores especulares.

Nas figuras 2.13 e 2.14 apresentam-se curvas de reflectância espectral para diversas coberturas existentes em França [75]. Observando a figura 2.13, verifica-se que materiais diferentes, como as telhas de cano e as de fibro-cimento, apresentam reflectâncias semelhantes, o que complica a tarefa de classificação das imagens, na medida em que as primeiras estão conectadas com o uso residencial, enquanto que as segundas são características de actividades industriais e de armazenagem.

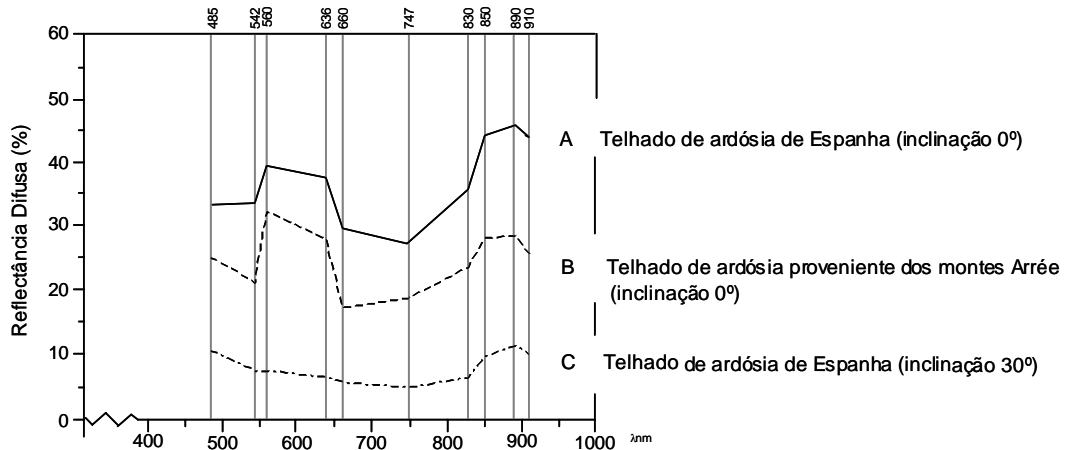


Figura 2.13 – Medidas de reflectância das coberturas típicas do Sudoeste de França (Provença)

Paradoxalmente (figura 2.14), três tipos de telhado utilizados nos edifícios de habitação, reflectem a energia incidente em quantidades diferentes, dependendo da proveniência do material, e no caso desta ser a mesma, do ângulo de inclinação dos telhados. Esta situação introduz complicações na análise estatística dos dados, pois o mesmo tipo de uso, ao ter respostas espectrais diferentes, vai alterar os parâmetros estatísticos da classe (média, desvio padrão, variância, etc.).

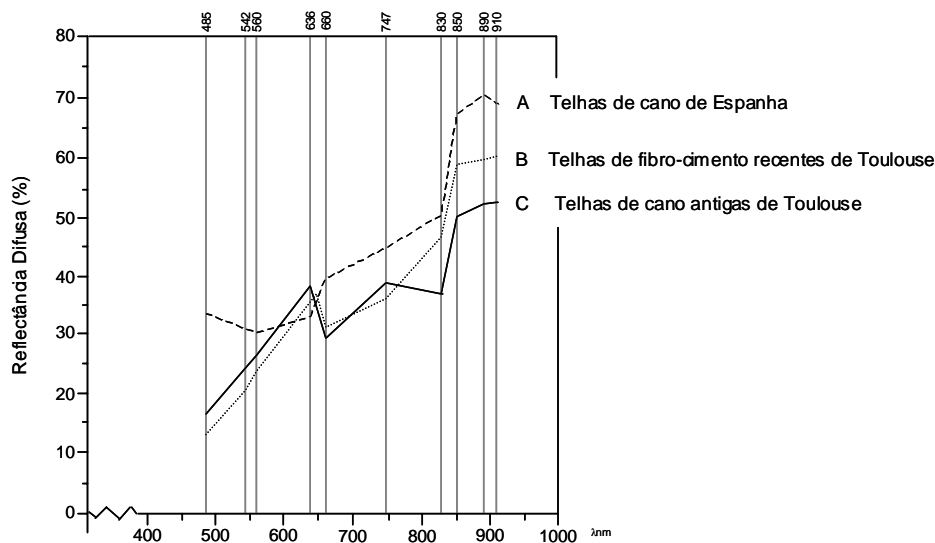


Figura 2.14 – Medidas de reflectância das coberturas típicas da Bretanha

Outro problema pertinente em áreas urbanas está relacionado com a dimensão do pixel de cada imagem e da sua capacidade para representar os objectos urbanos. O que se verifica actualmente é que essa dimensão não se ajusta à realidade das áreas construídas o que se traduz no aparecimento de muitos pixéis que não são “puros”, ou seja, cuja reflectância é consequência de mais do que um uso. Esta problemática será, no entanto, tratada com mais detalhe no capítulo 4.

3

SATÉLITES ARTIFICIAIS DA TERRA

3.1 INTRODUÇÃO

Actualmente, é possível encontrar diversos tipos de satélites artificiais da Terra. De acordo com o fim a que se destinam, os satélites artificiais têm características que influenciam as prestações dos sensores que se encontram a bordo e permitem diferenciá-los. São exemplos destas características o tipo de sensor, a velocidade e perturbação do movimento orbital e a geometria da órbita. Neste último caso, existem três situações distintas: os satélites de **órbitas quase polares** (inclinação próxima dos 90°) e **heliosíncronas**¹, os satélites com **órbitas geossíncronas**² e por fim os satélites com órbitas gerais. O primeiro grupo de satélites é o mais utilizado no campo das ciências da Terra, visto a órbita polar (de excentricidade pequena) ser a que viabiliza uma melhor cobertura do planeta e a heliosincronidade garantir, para a mesma zona e para diferentes passagens do satélite, índices de luminosidade equivalentes. Os satélites

¹ Órbita síncrona com o movimento aparente do Sol, o que significa que o satélite passa num dado ponto sempre à mesma hora solar.

² Órbita com um período orbital igual ao período de rotação da Terra (correspondente a um dia sideral).

de órbita geossíncrona são mais utilizados no âmbito da recolha de informação sobre fenómenos meteorológicos. Se um satélite possuir uma órbita geossíncrona e equatorial (inclinação orbital nula), então permanece na vertical sobre um ponto fixo na Terra, sendo por isso designado de **geostacionário**.

Neste capítulo, discriminam-se os parâmetros que caracterizam a órbita de um satélite. Descrevem-se também os satélites artificiais que vão estar na base desta tese, referindo-se as suas principais características, bem como as dos sensores que se encontram a bordo de cada um.

3.2 GEOMETRIA DA ÓRBITA

O movimento de qualquer plataforma (satélite artificial) em torno da Terra¹, processa-se segundo as três leis enunciadas em 1609 (primeira e segunda) e 1619 (terceira) pelo astrónomo de nacionalidade alemã, Joahann Kepler. Estas leis tiveram por base a análise de diversas observações sobre Marte levadas a efeito pelo dinamarquês Tycho Brahe sendo demonstradas em 1687 por Issac Newton, que as extrapolou da sua teoria da **Gravitação Universal** e lhes deu (à segunda e terceira) expressão matemática.

Segundo Newton, os corpos sobre os quais não está a ser exercida qualquer força estão em repouso, ou deslocam-se em linha recta e sem mudanças de direcção. Assim, pode concluir-se que os planetas e os satélites artificiais são alvo de forças. Como foi demonstrado por Newton, estas forças são atractivas e centrais, inversamente proporcionais à distância entre os corpos e directamente proporcionais às suas massas. Deste modo, considerando dois corpos em presença um do outro, estes atrair-se-ão mutuamente com uma força (F) que, segundo a Lei da Gravitação Universal, é descrita por

$$F = \frac{Gm_1m_2}{r^2} \text{ (kg m s}^{-2}\text{)}, \quad (3.1)$$

com

m_1 e m_2 - massa do corpo 1 e do corpo 2, respectivamente (kg);

G - constante de gravitação universal ($6,872 \times 10^{-11} \text{ m}^3 \text{ s}^{-2} \text{ Kg}^{-1}$);

r - distância entre os centros de massa dos dois corpos (m).

¹ Considerando a Terra uma esfera com uma massa homogénea e uniforme e o satélite como um objecto de massa negligenciável.

Segundo a **primeira lei de Kepler**, a órbita de um satélite é uma elipse (figura 3.1) na qual o centro de massa da Terra ocupa um dos seus focos. Neste contexto, designam-se por ápsides da órbita os pontos de intersecção da elipse orbital com o seu eixo maior. Considerando a órbita da Terra em torno do Sol, a ápside mais próxima do foco (Sol) designa-se por **periélio** (a ápside mais próxima é a **periápside**) e a mais afastada por **afélio**. Para o caso particular da órbita de um satélite artificial em torno da Terra, a ápside mais próxima designa-se de **perigeu** e a mais afastada de **apogeu**.




Figura 3.1 – Parâmetros da elipse

De acordo com a **segunda lei de Kepler**, existe uma proporcionalidade directa entre a área do sector elíptico plano definido pelo raio vector do satélite e o intervalo de tempo que lhe é necessário para a percorrer. Ao considerar-se que o satélite percorre distâncias iguais em intervalos de tempo iguais está-se a admitir, face às características elípticas da órbita, que a sua velocidade não é constante, apresentando-se no seu máximo aquando da passagem pelo perigeu e atingindo o mínimo no apogeu.

Pela **terceira lei de Kepler** o cubo do **semi-eixo maior** da órbita (a) é directamente proporcional ao quadrado do **período orbital** - $T(s)$ (intervalo de tempo que decorre entre duas passagens sucessivas do satélite no perigeu), traduzindo-se em:

$$\frac{a^3}{T^2} = G. \quad (3.2)$$

A equação da elipse (figura 3.1) na sua forma polar, é expressa por:

$$r(t) = \frac{a(1 - e^2)}{1 + e \cos A(t)}, \quad (3.3)$$

onde

Integração de Dados Estatísticos na Classificação de Imagens de Satélite

$r(t)$ - módulo do raio vector do satélite (**ou distância geocêntrica**) – distância entre os centros de massa do satélite e da Terra (m), no instante t ;

a - **semi-eixo maior** da elipse orbital (m);

e - **primeira excentricidade** da elipse orbital (m);

$A(t)$ - **Anomalia verdadeira** - ângulo entre o raio vector e o perigeu, medido no instante t , sobre o plano orbital (rad).

A primeira excentricidade é calculada a partir de:

$$e = \sqrt{1 - \left(\frac{b}{a}\right)^2}, \quad (3.4)$$

onde b corresponde ao **semi-eixo menor** da elipse. Para órbitas circulares tem-se $a = b$, pelo que $e = 0$.

Newton demonstrou que a segunda e terceira leis de Kepler podem ser descritas matematicamente por:

$$\mathbf{2^a Lei:} \quad r(t)^2 \left(\frac{dA}{dt} \right) = \left(\sqrt{a(1-e^2)} G(M+m) \right), \quad (3.5)$$

onde

dA/dt - velocidade orbital angular do satélite (rad/s);

M - massa da Terra ($5,9736 \times 10^{24}$ kg);

m - massa do satélite (kg).

$$\mathbf{3^a Lei:} \quad a^3 = \frac{G(M+m)}{4\pi^2} T^2, \quad (3.6)$$

ou

$$a = \left(\frac{G(M+m)}{4\pi^2} \right)^{\frac{1}{3}} T^{\frac{2}{3}}. \quad (3.7)$$

Satélites Artificiais da Terra

Considerando negligenciável a massa do satélite, tem-se $M + m \approx M$. Atendendo ao valor de GM ($3,98600434 \pm 0,00000002 \cdot 10^{14} \text{ m}^3 \text{ s}^{-2}$), a equação (3.7) simplifica-se para:

$$a = 21613,546468750 \times T^{\frac{2}{3}}. \quad (3.8)$$

Admitindo mais uma vez que $M + m \approx M$ e $a = r$ (órbitas circulares), pode-se reescrever (3.7) como:

$$T = \frac{2\pi}{\sqrt{GM}} a^{\frac{3}{2}} = \frac{2\pi}{\sqrt{3,986 \times 10^{14}}} a^{\frac{3}{2}} = 3,147 \times 10^{-7} a^{\frac{3}{2}}. \quad (3.9)$$

Na tabela 2.1 encontram-se representados os períodos de órbita dos satélites utilizados no presente estudo (SPOT e Landsat), calculados a partir de (3.9) (i.e., admitindo órbitas circulares) e os valores reais desses períodos.

| Plataformas | Altitude* (km) | Período Real (minutos) | Período Calculado (minutos) |
|-------------|-------------------|---------------------------|--------------------------------|
| Landsat – 5 | 705 | 98,94 | 99,0 |
| SPOT – 3 | 832 | 101,4 | 101,5 |

* à qual, para efeitos de cálculo, tem de ser somado o raio da Terra ($\approx 6350 \text{ km}$)

Tabela 3.1 – Período orbital real e calculado através de (3.9)

Os valores calculados diferem um pouco dos reais, porque o planeta Terra não apresenta uma esfericidade perfeita, assemelhando-se mais a um elipsóide de revolução com diferenças de potencial no seu campo gravítico. Para além disto os satélites são objecto de inúmeras perturbações as quais, embora devidas principalmente ao potencial gravitacional terrestre, podem também ser originadas por outros factores [12]:

- a força exercida pelos campos gravitacionais da Lua, do Sol e dos outros planetas do sistema solar;
- a pressão intrínseca à radiação solar;
- a interacção do campo magnético terrestre com a carga eléctrica adquirida pelo satélite no percurso que o leva a atravessar a ionosfera;
- a força exercida pelos propulsores do satélite nas correcções de atitude ou trajectória;
- o efeito relativista em virtude da elevada velocidade orbital dos satélites.

No anexo 1 pode ser consultada informação complementar sobre a posição do satélite na órbita.

3.3 PRINCIPAIS CARACTERÍSTICAS DOS SATÉLITES LANDSAT E SPOT

De uma forma simples, pode considerar-se o satélite como um objecto em órbita, composto por uma plataforma, um sistema de baterias e o respectivo conjunto de painéis solares que lhes fornecem energia, um sistema de antenas que permite receber comandos das estações terrestres e transmitir informação para estas estações, e um radiómetro.

O **radiómetro** é constituído por um sistema de lentes, espelhos e **sensores**. Estes últimos captam, em determinadas bandas do espectro electromagnético, a energia electromagnética reflectida e emitida pelos objectos existentes à superfície da Terra. Uma imagem de satélite não é mais do que um conjunto de matrizes de valores numéricos, que correspondem aos níveis radiométricos registados pelo sensor em cada uma das bandas espectrais. Devido a este facto, as imagens de satélite são também designadas por imagens **multiespectrais**. A forma mais comum de analisar visualmente esta informação multiespectral é combinando as bandas em conjuntos de três, fazendo corresponder cada banda a uma componente do sistema RGB (*Red – Green – Blue*), obtendo-se o que se designa por **composição colorida**. Quando uma imagem representa a informação registada na região do visível designa-se por **pancromática**.

As características das imagens de satélite dependem essencialmente das propriedades do sensor, o qual é caracterizado pela sua resolução espacial, espectral, radiométrica e temporal. A **resolução espacial ou geométrica** de um sensor costuma ser definida, na sua forma mais simples, como a unidade de menores dimensões geométricas que pode ser identificada na imagem adquirida por esse sensor (dimensão esta que corresponde à área mínima, no terreno, representada na imagem – figura 3.2). O poder de resolução espacial de um sensor é um aspecto importante nos sistemas de detecção à distância, na medida em que quanto maior for a resolução espacial, maior será a capacidade do sensor discriminar objectos próximos. Como regra geral, o tipo de sensor a usar deverá ter uma resolução espacial que não exceda metade do tamanho do objecto a observar, medido nas suas mais pequenas dimensões.

Não obstante a definição mais simplista de resolução espacial, apresentada no parágrafo anterior, ao efectuar-se uma abordagem mais aprofundada do tema, chega-se à conclusão que (co)existem diversas formas entender este conceito. De todas essas formas, a mais comum é mediante a utilização do termo **campo de visão instantâneo** (*Instantaneous Field of View - IFOV*), que depende apenas das propriedades geométricas do sensor. O IFOV pode ser dado pelo ângulo de visão instantâneo ou pelo diâmetro do círculo por ele definido na superfície (terrestre neste caso).

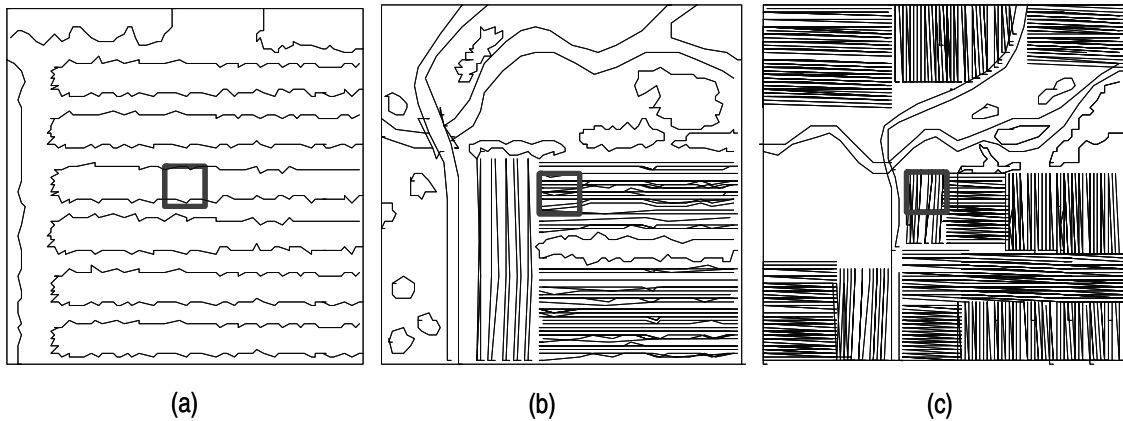


Figura 3.2 – Grande (a), Média (b) e Baixa (c) resolução no solo

Por **resolução espectral** entende-se o número e a largura dos intervalos do espectro electromagnético em que é feita a aquisição de imagens pelo sensor. Quanto mais estreitos e numerosos os intervalos, maior é a resolução espectral e mais fácil é distinguir os diferentes objectos ou fenómenos registados na imagem. As bandas espectrais são normalmente seleccionadas de modo a estar adaptadas ao tipo de fenómeno/objecto que se pretende detectar, conduzindo a um aumento da probabilidade de identificação desse mesmo fenómeno/objecto.

A **resolução radiométrica** reconhece-se no número de níveis de quantificação utilizados na conversão analógico/digital das variações contínuas de intensidade de radiação que chegam ao sensor (níveis radiométricos). Quanto maior for o número de níveis, menor será a perda de informação. A resolução radiométrica dos sensores Spot e Landsat actuais é de 256 níveis (8 bits/pixel).

Considera-se **resolução temporal**, a periodicidade, ou frequência, com que um determinado sensor adquire imagens de uma mesma área.

3.3.1 Os Satélites Landsat

Face aos excelentes – e prometedores – resultados apresentados pelos primeiros satélites artificiais da Terra, do tipo meteorológico, e pelas missões espaciais, a *National Aeronautics and Space Administration* (NASA) com a colaboração do Departamento do Interior do Governo dos Estados Unidos, iniciou em 1967 um estudo de viabilidade e conceptualização de uma nova geração de satélites designados *Earth Resources Technology Satellites* (ERTS). Tudo começou numa conferência de imprensa, a 20 de Setembro de 1966, quando *William Pecora*, director do *United States Geological Survey* (USGS) e *Stewart Udall*, Secretário do Interior, anunciaram os

Integração de Dados Estatísticos na Classificação de Imagens de Satélite

planos do departamento do interior para a criação do programa *Earth Resources Observation Satellites* (EROS). Segundo o director do USGS, o programa EROS foi concebido devido às potencialidades que as fotografias orbitais obtidas pelas missões *Gemini* e *Mercúrio*, demonstraram ter para o estudo dos recursos terrestres.

O programa EROS resultou num conjunto de seis satélites que, numa fase de pré-lançamento, foram baptizados com a sigla ERTS precedida da letra A até F. Sempre que um lançamento fosse efectuado com sucesso a letra seria substituída por um número de 1 a 6. No início, o Departamento do Interior e a NASA planeavam utilizar como instrumentos de captação de imagem, um tipo especial de câmaras de televisão designadas *Return Beam Vidicon* (RBV). Cada uma destas câmaras era composta por um sensor de placa (*frame sensor*), composto por detectores (equivalentes a lentes ópticas de grande abertura) ligados a tubos fotossensíveis, os quais por sua vez se encontravam agrupados numa grelha bidimensional e eram percorridos por feixes de electrões.

Em 1968, a companhia de aeronáutica *Hughes Aircraft* submeteu à NASA uma proposta para colocar um novo sistema de captação de imagens no satélite: este sistema era um *scanner* multiespectral. Os *scanners* eram vistos com grande cepticismo pela maioria dos cientistas, devido essencialmente a dois factores: (i) o *scanner* tinha uma parte móvel - um espelho oscilatório - que era considerado pouco fiável e (ii) não criava uma imagem única; as imagens eram criadas através da junção de diversas linhas e os cartógrafos desconfiavam da integridade geométrica desta informação.

Contudo o *scanner* detinha uma importante vantagem; a sua capacidade multiespectral. A investigação agrícola já tinha demonstrado o valor desta informação descobrindo por exemplo, que a banda dos 0,63 aos 0,68 μm indica a quantidade de água existente nas folhas, a banda dos 0,79 aos 0,9 μm mede a absorção da clorofila e a banda dos 1,55 aos 1,75 μm traduz a mistura do solo. Inicialmente, a equipa da *Hughes Aircraft* desenhou um *scanner* de seis bandas com o propósito de o instalar a bordo do satélite. Mais tarde verificou-se que as suas dimensões eram demasiado grandes para o tipo de satélite que a NASA estava a projectar, sendo redimensionado e dando origem a um novo sensor (*Multispectral Scanner* - MSS) com quatro bandas. Estas bandas foram escolhidas de modo a que fosse possível simular o resultado obtido pelas fotografias infravermelhas de falsa cor. Em 1969, a missão *Apollo 9* incluiu uma experiência fotográfica, na qual quatro câmaras montadas de forma coaxial foram utilizadas para simular as imagens multibanda do MSS; os resultados foram favoráveis e serviram para aprovar a tecnologia.

Satélites Artificiais da Terra

O debate acerca da utilização das câmaras RBV ou do *scanner* foi intenso, acabando finalmente a NASA por se comprometer a incluir ambos no satélite. Assim, o primeiro satélite da série (ver tabela 3.2), o ERTS1, foi colocado em órbita a 23 de Julho de 1972, tendo permanecido operacional até 6 de Janeiro de 1978. Este satélite constituiu o primeiro satélite desenhado especificamente para a aquisição, adquirir de forma sistemática, de dados sobre os recursos terrestres. A sua missão principal era, no entanto, a criação de um sistema experimental que permitisse avaliar a viabilidade deste tipo de satélites. Todos os dados recolhidos durante a missão foram adquiridos segundo uma premissa, designada pela NASA por *open skies*, que permitia a qualquer pessoa, de qualquer país, o acesso à informação recolhida.

Para avaliar este novo satélite foi lançado um repto a todas as nações para que avaliassem as suas capacidades, traduzido em cerca de 300 experiências levadas a cabo nos Estados Unidos (43 estados) e mais 36 países e que se saldou num resultado bastante favorável, que extravasou por completo as expectativas mais optimistas da comunidade científica mundial. Com efeito, poucas horas depois de entrar em funcionamento, as primeiras imagens MSS fizeram furor, devido à sua extraordinária clareza e vistas sinópticas da paisagem, e levaram à criação, em 1975 e 1978, de mais dois satélites praticamente idênticos ao ERS 1 designados por ERTS 2 e ERTS 3.

| | Landsat 1 (ERTS 1) | Landsat 2 (ERTS 2) | Landsat 3 (ERTS 3) | Landsat 4 | Landsat 5 | Landsat 6 | Landsat 7 |
|---------------------------------------|---|-----------------------|-----------------------|---------------------|---------------------|---------------------|---------------------|
| Entidade Responsável | NOAA (National Oceans and Atmospheric Administration) | | | | | | |
| Data de Lançamento | 23.JUL.72 | 22.JAN.75 | 05.MAR.78 | 16.JUL.82 | 01.MAR.84 | 05.OUT.93 | 15.ABR.99 |
| Data de Fim de Vida | 1978 | 1982 | 1983 | 1987 | 1988 | 05.OUT.93 | Não Disponível |
| Situação Actual | Desactivado | Desactivado | Desactivado | Desactivado | Activo | Desactivado | Activo |
| Tipo de Órbita | Circular, quase polar, sincronizada com o Sol | | | | | | |
| Altitude Média | 907 km | 908 km | 915 km | 705.3 km | 705.3 km | - | 705 km |
| Inclinação | 99,9° | 99,2° | 99,1° | 98,3° | 98,3° | - | |
| Período | 103,14 min | 103,16 min | 103,15 min | 98,94 min | 98,94 min | - | 99 min |
| Peso | 816 kg | 953 kg | 960 kg | 1942 kg | 1938 kg | 1740 kg | 2000 kg |
| Hora Local no Nodo Descendente | 8:50 | 9:08 | 9:31 | 9:39 | 9:39 | - | 10:00 |
| Finalidade | Observação da Terra | Observação da Terra | Observação da Terra | Observação da Terra | Observação da Terra | Observação da Terra | Observação da Terra |
| Sensores | RBV e MSS | RBV e MSS | RBV e MSS | TM e MSS | TM e MSS | ETM | ETM+ |

Tabela 3.2 – Principais características do programa Landsat

Integração de Dados Estatísticos na Classificação de Imagens de Satélite

Pouco tempo antes do lançamento do ERTS-B, em 22 de Janeiro de 1975, a NASA atribuiu uma nova designação ao programa, para evitar que este se confundisse com o programa oceanográfico previsto, o Seasat. Deste modo, todo o programa ERTS foi renomeado de Landsat, incluindo o satélite já lançado que passou a ser referido como Landsat 1. No entanto, durante o desenvolvimento do Landsat 1, começaram a surgir problemas dentro da organização que geria o programa.

Apesar do período conturbado pelo qual o programa passou, a *Hughes Aircraft* continuou a trabalhar no projecto e, seguindo o sucesso do MSS, construiu uma segunda geração de *scanners*, os *Thematic Mapper* (TM) que, face aos anteriores (RBV e MSS), proporcionam uma maior resolução espectral e espacial. Este sensor foi utilizado pela primeira vez no Landsat 4, acontecimento que marcou o início da segunda geração desta família de satélites (a primeira foi constituída pelos satélites Landsat 1, 2 e 3 lançados, respectivamente, em 1972, 1975 e 1978). Os sensores RBV e MSS foram sendo progressivamente abandonados em virtude dos problemas técnicos apresentados e da fraca qualidade das imagens captadas (RBV), e da baixa resolução espacial (MSS). A segunda geração de satélites Landsat entrou em funções com os lançamentos das versões 4 e 5, enviadas para órbita a 16 de Julho de 1982 e 1 de Março de 1984, respectivamente. Em virtude de alguns problemas de comunicação e de fornecimento de energia com o Landsat 4, o Landsat 5 foi lançado mais cedo do que o previsto.

O programa Landsat obteve um estrondoso sucesso enquanto foi desenvolvido pela NASA; no entanto, o seu papel institucional foi drasticamente alterado em 1982, quando a sua operacionalidade foi transferida para a *United States National Oceanographic and Atmospheric Administration* (NOOA), a qual não se mostrou satisfeita com a situação. Assim, o programa Landsat foi envolvido no processo de privatização de programas governamentais levado a efeito pela administração Reagan, passando a ser gerido pela *Earth Observation Satellite Company* (EOSAT) a partir de 1986 (Lei Pública 98-365). A EOSAT, contrariamente à NASA, é uma organização comercial civil e portanto as imagens obtidas através dos seus satélites têm de ser comercializadas com lucro para a empresa.

Sobre a alçada da EOSAT, o programa Landsat foi direccionado para utilizadores que pudessem adquirir informação onerosa. Os clientes principais eram os militares e as grandes companhias petrolíferas, ao passo que os utilizadores académicos e governamentais foram praticamente excluídos, em virtude da política de preços seguida pela empresa. Mais grave foi ter sido interrompido, para algumas regiões do globo, o constante arquivo de dados digitais perdendo-se dados que poderiam ser bastante valiosos.

O Landsat 6 foi o primeiro satélite deste programa a ser desenhado e construído sobre a alçada da EOSAT. Contudo, a estreia não foi auspiciosa e o satélite, enviado para o espaço em 1993, sofreu uma falha no lançamento e nunca chegou a enviar nenhuma imagem, estando presumivelmente algures no fundo do Oceano Pacífico Sul. Em 1992, o Congresso dos Estados Unidos e o presidente *Bush* aprovaram legislação que apontava no sentido de devolver a operacionalização do Landsat ao domínio público, começando pelo Landsat 7, que seria enviado para o espaço no fim dos anos noventa. Em 1994, o Landsat tornou-se parte do programa da NASA, *Mission to Planet Earth*, e o presidente *Clinton* estabeleceu o Landsat 7 como um programa conjunto da NASA, NOAA (mais tarde retirada) e o *United States Geological Survey's EROS Data Center* (EDC). A NASA construiu o referido satélite e lançou-o a 15 de Abril de 1999, continuando a gerir o seu funcionamento até Outubro de 2000, data em que a operacionalidade do programa foi transferida para o EDC.

O Landsat 7 (nome de protótipo AM-1) transporta como sensor um *Enhanced Thematic Mapper Plus* (ETM+), que garante a continuidade dos dados Landsat TM, mas com melhores resoluções espaciais e espectrais. O EDC planeia recolher cerca de 250 imagens por dia, de forma a construir um arquivo global de dados sazonais. Esta será a primeira tentativa de recolher e arquivar dados obtidos por teledeteção, com o intuito de criar uma base de dados global que cubra elementos ambientais fundamentais. As imagens recolhidas pelas outras estações internacionais vão aumentar para mais do dobro a informação contida nesta base de dados, visto que o Landsat 7 recolhe quase dois *terabytes* de dados por dia.

Neste momento, já se encontra em curso o planeamento das futuras missões Landsat. O satélite AM-2 do programa *Mission to Planet Earth*, com lançamento previsto para 2004, irá transportar, conjuntamente com outros sensores, um sistema experimental designado por *Landsat Advanced Technology Instrument* (LATI). Esta combinação de sensores é possível em virtude das novas tecnologias permitirem a construção de instrumentos muito mais pequenos, mais leves e que requerem menos energia.

a) Características de Órbita dos Landsat 4 e 5¹

Tal como os seus antecessores, os Landsat 4 e 5 foram lançados em órbitas repetitivas, circulares, heliosíncronas e quase polares. Contudo, as suas altitudes desceram de 900 para 705 km. Estas órbitas mais baixas foram escolhidas para possibilitar que os satélites fossem

¹ No anexo 2 descrevem-se as características orbitais e sensores dos satélites Landsat 1, 2 e 3.

recolhidos pelas naves espaciais e para ajudar na melhoria da resolução no solo dos sensores instalados a bordo.

As órbitas dos Landsat 4 e 5 (figura 3.3) têm um ângulo de inclinação de $98,2^\circ$ em relação ao Equador. O satélite atravessa o Equador no movimento Norte \rightarrow Sul de cada órbita às 9h 45min (hora solar local). Cada órbita demora cerca de 99 minutos, sendo completadas por dia 14,5 órbitas. Devido à rotação da Terra, a distância entre o percurso no solo (*ground tracks*) de órbitas consecutivas é de aproximadamente 2752 km no Equador (figura 3.4-a).






Figura 3.3 – Órbita heliosíncrona dos Landsat 4 e 5

A órbita acima descrita resulta num ciclo repetitivo de 16 dias para cada satélite. As órbitas dos Landsat 4 e 5 foram estabelecidas de modo a que, quando os dois satélites estivessem operacionais, houvesse um ciclo de 8 dias de cobertura repetido que pudesse ser mantido pela cobertura alternada de cada satélite. Tal como representadas na figura 3.4-b), o intervalo de tempo entre percursos adjacentes do mesmo satélite é de 7 dias. Este padrão de cobertura é bastante diferente do dos três satélites anteriores, que tinham ciclos orbitais de 18 dias e um dia de intervalo entre órbitas em percursos adjacentes. A órbita dos Landsat 4 e 5 é constituída por 233 percursos, numerados de 001 a 233 de Este para Oeste, com o percurso 001 a atravessar o Equador à longitude de $64^\circ 36'$ Oeste. É utilizado o mesmo número de linhas que nos três satélites anteriores. A linha 1 de cada percurso inicia-se à latitude de $80^\circ 47'$ N.



(a)



(b)

Figura 3.4 – (a) Distância entre percursos sucessivos dos Landsat 4 e 5; (b) Cronograma dos percursos adjacentes

Na figura 3.5 apresenta-se a configuração dos satélites Landsat 4 e 5, que incluem os sensores MSS e TM. Estes engenhos espaciais pesam aproximadamente 2000 kg e incluem quatro painéis solares de 1,5 x 2,3 m, que estão montados num dos lados. A transmissão directa da informação do MSS e do TM para as estações receptoras no solo é efectuada através de antenas parabólicas instaladas no satélite, a funcionar nas bandas X e S. As taxas de transmissão de informação envolvidas são de 15 Mbit/s para o MSS e de 85Mbit/s para o TM (o MSS foi introduzido nestas missões para assegurar a continuidade de informação para as estações receptoras indisponíveis para receber e processar a informação do TM).




Figura 3.5 - Os Landsat 4 e 5

O sensor MSS instalado nos Landsat 4 e 5 é essencialmente idêntico aos sensores MSS nos satélites Landsat anteriores (tabela 3.3). A área de abrangência de 185 km² foi mantida, mesmo com uma órbita de menor altitude, por acréscimo do campo total de visão para 14,92° (de 11,56° nos sistemas anteriores). O sistema óptico do sensor MSS foi modificado de forma a diminuir a célula de resolução no solo de 82 m, para os 79 m do sistema actual. As mesmas quatro bandas espectrais são utilizadas para recolher informação, mas foram renomeadas, ou seja, as bandas MSS 1 a 4 do Landsat 4 e 5, correspondem directamente às bandas 4 a 7 do anterior sistema MSS.

| Sensor | Resolução Espectral | Resolução Espacial | Faixa de Varrimento | Resolução Radiométrica | Resolução Temporal |
|--|---------------------|--------------------|---------------------|------------------------|--------------------|
| MSS <i>Multispectral Scanner</i> | 0,5 – 0,6 μm | 75 m | 185 km | 8 bits (256 níveis) | 16 dias |
| | 0,6 – 0,7 μm | 75 m | 185 km | 8 bits (256 níveis) | 16 dias |
| | 0,7 – 0,8 μm | 75 m | 185 km | 8 bits (256 níveis) | 16 dias |
| | 0,8 – 1,1 μm | 75 m | 185 km | 8 bits (256 níveis) | 16 dias |
| TM <i>Thematic Mapper</i> | 0,45 – 0,52 μm | 30 m | 185 km | 8 bits (256 níveis) | 16 dias |
| | 0,52 – 0,60 μm | 30 m | 185 km | 8 bits (256 níveis) | 16 dias |
| | 0,63 – 0,69 μm | 30 m | 185 km | 8 bits (256 níveis) | 16 dias |
| | 0,76 – 0,90 μm | 30 m | 185 km | 8 bits (256 níveis) | 16 dias |
| | 1,55 – 1,75 μm | 30 m | 185 km | 8 bits (256 níveis) | 16 dias |
| | 10,4 – 12,50 μm | 120 m | 185 km | 8 bits (256 níveis) | 16 dias |
| | 2,08 – 2,35 μm | 30 m | 185 km | 8 bits (256 níveis) | 16 dias |

Tabela 3.3 – Características dos sensores a bordo dos Landsat 4 e 5

O TM é um sensor extremamente avançado, que incorpora numerosas melhorias espectrais, radiométricas, e de desenho geométrico, relativamente ao MSS. As melhorias espectrais incluem a aquisição de informação em sete bandas, ao contrário de quatro, com novas bandas no visível (azul), infravermelho médio, e infravermelho térmico do espectro. Também baseado na experiência com informação do MSS e com os resultados de investigação em campos

Satélites Artificiais da Terra

radiométricos, a amplitude do comprimento de onda e a localização das bandas TM (tabela 3.3) foi escolhida para melhorar a diferenciação espectral da maioria das características da superfície da Terra.

Radiometricamente, o TM efectua a conversão analógico-digital, utilizando 256 níveis de amplitude (8 bits), o que corresponde a um aumento relativamente aos 64 níveis de amplitude (6 bits) utilizados pelo MSS.

Geometricamente, a informação TM é recolhida utilizando uma célula (ou pixel) de resolução no solo de 30 m (excepto para a banda térmica, que tem uma resolução de 120 m). Isto representa um decréscimo nas dimensões lineares das células de resolução no solo de aproximadamente 2,6 vezes, ou uma redução na área da célula de resolução no solo de aproximadamente 7 vezes.

A tabela 3.4 lista as sete bandas espectrais do TM, juntamente com um breve resumo das principais aplicações de cada uma. As bandas TM estão, por várias razões, mais finamente vocacionadas para a discriminação da vegetação do que as do MSS. A adicionar às melhorias significativas na discriminação da vegetação, o TM foi desenhado para suportar um uso acrescido e melhorado da informação do satélite em outras inúmeras áreas de aplicação. Entre essas, encontra-se a utilização de informação TM (particularmente da banda 1) no campo da batimetria. Tal como as bandas do infravermelho médio (5 e 7), têm provado ser extremamente valiosas na discriminação de tipos de rochas. A banda 5 também é apropriada para fazer a distinção entre áreas cobertas por neve ou por nuvens. Finalmente, a banda 6 é potencialmente útil em várias aplicações de cartografia térmica

| | |
|---|---|
| TM 1 (0,45 – 0,52 µm, azul) | Utilizado para o estudo da superfície da água, tornando-se útil na caracterização da hidrologia costeira. A sua utilidade passa ainda pela capacidade de discriminação do solo/vegetação, e da identificação das características dos níveis de poluição aquática. |
| TM 2 (0,52 – 0,60 µm, verde) | Fornecer informação relativa ao estado de desenvolvimento da vegetação, na medida que permite observar o pico de reflectância da vegetação no existente nos comprimentos de onda correspondentes ao verde. Também é útil para a identificação das características das culturas. Este canal, ao operar na banda verde, realça na imagem, as áreas cobertas de vegetação, relativamente aos espaços construídos e às rochas e solos desnudados. |
| TM 3 (0,63 – 0,69 µm, vermelho) | Banda de grande utilidade na determinação da região de absorção de clorofila, sendo o mais sensível à diferenciação entre as várias espécies de plantas na região visível, assim como à discriminação entre vegetação e “não vegetação”. Tal como os canais anteriores é importante na identificação das características das plantas. |
| TM 4 (0,76 – 0,90 µm, infravermelho próximo) | A mais adequada para a determinação dos tipos de vegetação, para quantificação da biomassa, na discriminação solo/vegetação e terra/água, e na avaliação do teor de humidade do solo. |
| TM 5 (1,55 – 1,75 µm, infravermelho médio) | Adequada na quantificação do teor de humidade presente na vegetação e nos solos, permitindo diferenciar as plantas consoante o seu estado fenológico ¹ . É também útil quando é necessário diferenciar neve e nuvens. A imagem fornecida por este canal melhora o contraste da linha de costa, pela absorção quase total desta radiação pela água. |
| TM 6 (10,4 – 12,5 µm, infravermelho térmico) | Reconhecido pela sua eficácia na análise do <i>stress</i> ² da vegetação, na disseminação do teor da humidade do solo e, sobretudo, no estudo da termicidade dos objectos, na localização de fontes de calor em meio urbano, na determinação dos níveis de poluição atmosférica. |
| TM 7 (2,08 – 2,35 µm, infravermelho médio) | Permite a discriminação dos minerais, tipos de rochas e, aplica-se em estudos de solos. É igualmente sensível ao teor de humidade presente na vegetação. Este canal, é aquele que oferece a melhor imagem do contorno da linha de costa. Todavia, apresenta um inconveniente: a elevada sensibilidade denotada por esta banda à humidade, leva a que lugares mais húmidos apareçam como superfícies aquáticas. |

Tabela 3.4 – Principais características e aplicações dos sensores TM

O sensor TM é composto por um *scanner cross-track*, de varrimento (figura 3.6), que incorpora um espelho oscilatório e um conjunto de 36 detectores. Enquanto o MSS recolhe informação somente quando o varrimento evolui na direcção Oeste-Este ao longo de uma linha de visualização, o TM adquire informação quer durante o percurso para a frente (Oeste para Este) quer durante o retorno (Este para Oeste) das passagens do espelho de varrimento. O TM opera sobre um campo total de visão de 15,4° (+ ou – 7,7° em torno do nadir). Completa aproximadamente sete ciclos combinados de visualização (para a frente e para trás) por segundo. Esta taxa relativamente baixa limita a aceleração do espelho de varrimento, melhorando a integridade geométrica do processo de recolha de informação e também a relação sinal/ruído do sistema.

¹ Fenómenos periódicos que se verificam nas plantas, como a floração e a maturação dos frutos.

² Quando uma planta tem, armazenada nas suas folhas, uma quantidade de água inferior ao normal, perde capacidade fotossintética. Nestes casos diz-se que a planta tem *stress*.




Figura 3.6 – Sensor de varrimento mecânico

Outra grande diferença entre o TM e o MSS é o número de detectores utilizados. Enquanto o MSS emprega 6 detectores para detectar informação em cada uma das suas quatro bandas (um total de 24 detectores), o TM utiliza 16 detectores para todas as bandas não térmicas e quatro detectores para a banda térmica (total de 100 detectores). Ou seja, em cada oscilação do espelho são obtidas 16 linhas de cada banda não térmica e quatro linhas da banda térmica.

Os sensores de varrimento mecânico são pois compostos por um espelho de varrimento cuja rotação é accionada por um motor eléctrico, processando-se sobre um eixo horizontal, alinhado paralelamente à direcção do voo. Este espelho percorre o terreno delineando faixas de recolha de dados, normalmente orientadas perpendicularmente ao eixo da órbita e, através de um sistema óptico de espelhos secundários oscilantes, designados de correctores da linha de varrimento, foca a radiação irradiada ou reflectida pelo solo no detector.

A qualquer momento, todos os 100 detectores visionam uma diferente área no solo devido à separação espacial dos detectores individuais, devido à existência de dois planos de focagem.

A informação captada pelo sensor TM é, desde que o satélite se encontre no raio de acção de uma estação terrestre (figura 3.7), adquirida e transmitida simultaneamente para essa estação pela antena do satélite. Caso não se esteja na área de recepção das estações de Terra, os dados são então enviados para satélites geoestacionários designados por TDRS, que por sua vez os reenviam para uma estação de Terra em Norman-Oklahoma.

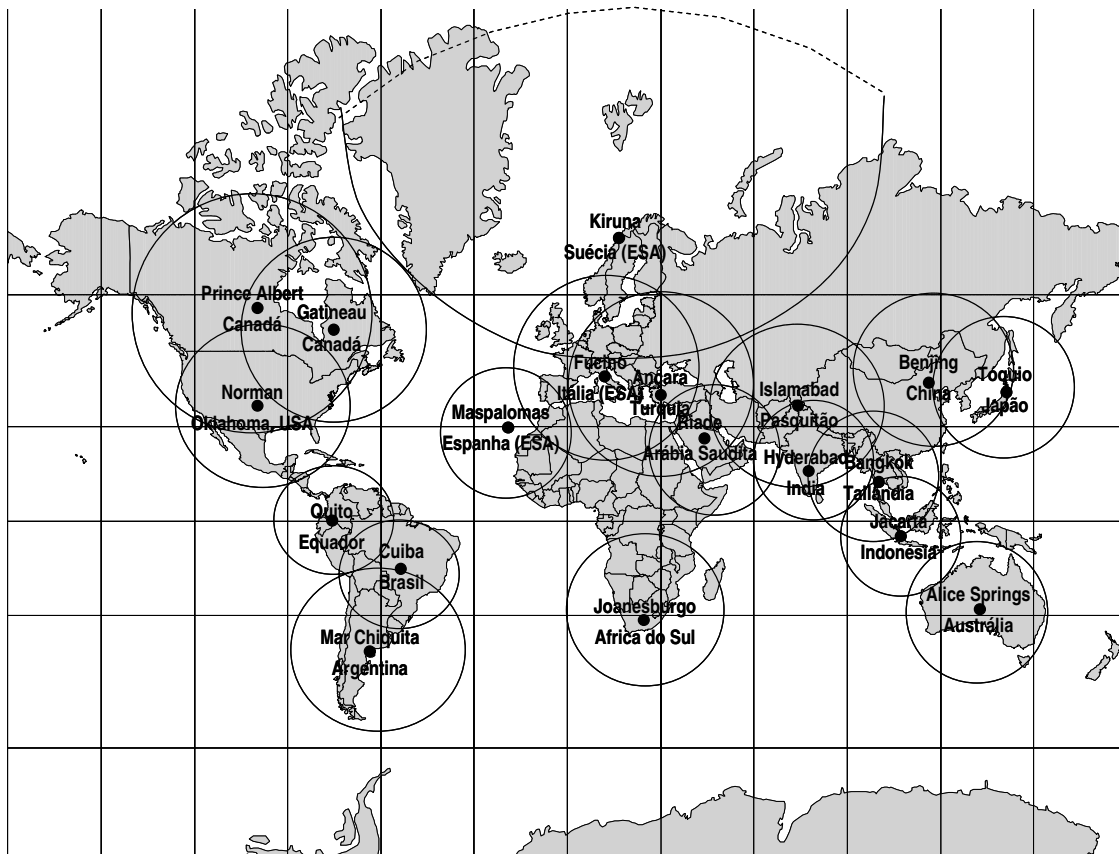


Figura 3.7 – Estações de recolha de dados e respectivos raios de acção

b) Os Landsat 6 e 7

Como já foi referido o Landsat 6 sofreu uma falha técnica logo após o lançamento. Actualmente, encontra-se em actividade o Landsat 7, enviado para o espaço a 15 de Abril de 1999 e que, relativamente ao Landsat 6, não possui alterações significativas em termos de estrutura e de características da órbita. Possui no entanto algumas inovações importantes relativamente aos seus predecessores, nomeadamente um novo sensor (tabela 3.5) designado por *Enhanced Thematic Mapper Plus* (ETM+). Este sensor, para além das sete bandas TM tradicionais (onde a resolução espacial do canal térmico foi aumentada para 60 m), apresenta um canal pancromático (0,5 – 0,9 μm) com uma resolução espacial de 15 m.

| Sensor | Resolução Espectral | Resolução Espacial | Faixa de Varrimento | Resolução Radiométrica | Resolução Temporal |
|--|------------------------------|--------------------|---------------------|------------------------|--------------------|
| ETM + Enhanced Thematic Mapper Plus | 0,45 – 0,52 μm | 30 m | 185 km | 8 bits (256 níveis) | 16 dias |
| | 0,53 – 0,61 μm | 30 m | 185 km | 8 bits (256 níveis) | 16 dias |
| | 0,63 – 0,69 μm | 30 m | 185 km | 8 bits (256 níveis) | 16 dias |
| | 0,78 – 0,90 μm | 30 m | 185 km | 8 bits (256 níveis) | 16 dias |
| | 1,55 – 1,75 μm | 30 m | 185 km | 8 bits (256 níveis) | 16 dias |
| | 10,4 – 12,5 μm | 60 m | 185 km | 8 bits (256 níveis) | 16 dias |
| | 2,09 – 2,35 | 30 m | 185 km | 8 bits (256 níveis) | 16 dias |
| | 0,52 – 0,9 (pancromático) | 15 m | 185 km | 8 bits (256 níveis) | 16 dias |

Tabela 3.5 – Características do sensor a bordo do Landsat 7

3.3.2 Programa SPOT

Nos princípios de 1978, o governo Francês decidiu dar início ao desenvolvimento do programa *Systeme Pour l'Observation de la Terre – SPOT*, ao qual se juntaram, pouco depois, a Suécia e a Bélgica. Desde os primórdios da sua existência que o SPOT foi conceptualizado tendo em vista uma essência comercial e operacional (foi o primeiro a ser concebido para esse fim), ao invés de experimental, tendo marcado o início de um programa que viria a mostrar-se capaz de rivalizar com o americano. Desenhado e concebido pelo *Centre National d'Etudes Spatiales* (CNES), este programa rapidamente adquiriu dimensão internacional, com a implementação de estações de recepção de dados e centros de distribuição de informação em mais de 30 países.

De capital exclusivamente europeu, e por intermédio da Agência Espacial Europeia (*European Spatial Agency – ESA*), foi lançado a 21 de Fevereiro de 1986 o primeiro satélite deste programa (tabela 3.6), o SPOT 1. Para o efeito, foi utilizado um foguetão do tipo *Ariane*, o qual partiu da rampa de lançamento de *Korou*, na Guiana Francesa. Este satélite iniciou uma nova era na teledetecção espacial, na medida em que foi o primeiro a possuir uma matriz de sensores. Este foi também o primeiro sistema a integrar ópticas direccionáveis, que lhe auferem uma capacidade de captação de imagens para ambos os lados do nadir¹ (designadas por imagens não nadirais), assim como a obtenção de imagens estereoscópicas de toda a imagem, em virtude de existirem dois sensores que podem recolher informação sobre a mesma área e ao mesmo tempo.

¹ Nadir simboliza exactamente o inverso de zénite, ou seja, enquanto este último é o ponto exactamente acima do observador o nadir será o ponto exactamente abaixo do observador (neste caso do satélite). Assim uma imagem nadiral será uma imagem de visada perpendicular e uma imagem não nadiral será de visada oblíqua.

| | SPOT 1 | SPOT 2 | SPOT 3 | SPOT 4 | SPOT 5 |
|---------------------------------------|---|---------------|---------------|---------------|----------------|
| Entidade Responsável | CNES (Centre National d'Études Spatiales) | | | | |
| Data de Lançamento | 22.Fev.86 | 22.Jan.90 | 26.Set.93 | 24.Mar.98 | 04.Mai.02 |
| Período de Vida | 3 Anos | 3 Anos | 3 Anos | 5 Anos | 5 Anos |
| Situação Actual | Activo | Activo | Inactivo | Activo | Activo |
| Tipo de Órbita | Quase polar, circular, sincronizada com o Sol | | | | |
| Altitude Média | 832 km | 832 km | 832 km | 832 km | 822 km |
| Inclinação | 98,7° | 98,7° | 98,7° | 98,7° | 98,7° |
| Período | 101,4 min | 101,4 min | 101,4 min | 101,4 min | 101,4 min |
| Peso | 1830 kg | 1870 kg | 1907 kg | 2760 kg | 3000 kg |
| Hora Local no Nodo Descendente | 10:30 | 10:30 | 10:30 | 10:30 | 10:30 |
| Finalidade | Várias | Várias | Várias | Várias* | Várias* |
| Sensores | HRV | HRV | HRV | HRVIR e VGT | HRG, HRS e VGT |

* com destaque para os fins agrícolas

Tabela 3.6 – Principais características do programa SPOT

O SPOT 1 foi retirado do serviço activo em 31 de Dezembro de 1990, passando a funcionar apenas em modo de prevenção. O seu sucessor, SPOT 2, e o seguinte da série, SPOT 3, foram lançados, respectivamente, a 21 de Janeiro de 1990 e a 25 de Setembro de 1993. Entretanto, em 1992, foi novamente activado o SPOT 1, respondendo a diversas solicitações de entidades comerciais. Quanto ao SPOT 3, perdeu-se o contacto com ele logo a seguir ao lançamento, encontrando-se inactivo.

Representando um pequeno corte relativamente à linha até então seguida, o SPOT 4 está em órbita desde 24 de Março de 1998 e apresenta algumas novidades relativamente aos seus predecessores, possuindo um sensor especialmente vocacionado para a vegetação, que regista quatro imagens (cada uma com 200 km de largura) com uma resolução espacial de 1 km e uma nova banda dirigida para aplicações marítimas (0,43 – 0,47 μm). A banda pancromática foi substituída por uma outra designada por B2 (0,61 – 0,68 μm). Apesar da operacionalidade do SPOT 4 não ter sofrido qualquer tipo de alteração, já em 2002 foi posto em órbita o SPOT 5, o qual apresenta grandes melhorias no que diz respeito à resolução espacial dos sensores.

a) Características Orbitais do Programa SPOT

À imagem do que se verifica no programa Landsat, os SPOT têm uma órbita quase circular (excentricidade $e = 0,0011$), quase polar e heliosíncrona. A órbita caracteriza-se por uma altitude de 832 km, um semi-eixo maior com 7200,55 km e uma inclinação (i) de 98,7°. Todos os SPOT cruzam o Equador (nodo descendente) às 10h 30m, hora local, passando ligeiramente mais tarde nas latitudes a Norte, e um pouco mais cedo nas latitudes a Sul. Por exemplo, estes

satélites passam sobre o paralelo dos 40° Norte aproximadamente às 11h 00 min e sobre o paralelo dos 40° Sul, aproximadamente às 10h 00 min.

O período orbital é de 101,4 minutos, percorrendo 14 e 5/26 órbitas em 24 horas (figura 3.8). Estas características, aliadas ao facto de em cada período da órbita a Terra girar 2823,6 km para Este, traduzem-se num padrão orbital com um ciclo repetitivo de 26 dias (resolução temporal), o que significa que é possível recolher, com esta frequência, imagens de qualquer local à superfície terrestre mantendo o ângulo de aquisição. No entanto, fazendo uso das características direccionáveis do sistema óptico, podem obter-se imagens não nadirais em passagens alternadas do satélite separadas por 1, 4 e, ocasionalmente, 5 dias, dependendo da latitude da área em observação. Esta característica dos SPOT, várias vezes referenciada como a capacidade de “revisitar” os locais, é de grande importância devido a um aspecto primordial: permite uma recolha sucessiva de imagens sobre um determinado local, aumentando a frequência potencial de cobertura das áreas onde a existência de nuvens é um problema e viabiliza a monitorização de áreas agrícolas (ex. regantes ilegais) e florestais (ex. fogos).




Figura 3.8 – Órbitas diurnas do programa SPOT

b) Sensores a Bordo dos SPOT 1, 2 e 3

A figura 3.9 representa esquematicamente os satélites SPOT 1, 2 e 3. Os seus sistemas pesam cerca de 1750 kg, o corpo principal tem as dimensões aproximadas de 2 x 2 x 3,5 m e o painel

solar tem 15,6 m de comprimento. A plataforma SPOT apresenta um desenho modular de forma a ser compatível com os pré-requisitos de uma grande variedade de sensores. Assim, as missões subsequentes podem adoptar sensores com estruturas diferentes sem que isso implique grandes modificações na plataforma. Os sensores a bordo do SPOT 1, 2 e 3 consistem em dois sistemas de imagem idênticos, designados de *haute résolution dans le visible* (HRV), acoplados a gravadores auxiliares de fita magnética.




Figura 3.9 - Representação Esquemática dos Satélites SPOT 1, 2 e 3

Cada HRV (tabela 3.7) foi concebido para operar num de dois modos de aquisição: um modo pancromático (a preto e branco - Pan) com uma resolução espacial de 10 m e com uma resolução espectral dos 0,51 aos 0,73 μm (região do visível exceptuando o azul), e um modo multiespectral (XS) com resolução espacial de 20 m e abrangendo três regiões do espectro correspondentes aos comprimentos de onda situados entre os 0,50 e os 0,59 μm , entre os 0,61 e os 0,68 μm e entre os 0,79 e os 0,89 μm .

| Sensor | Banda | Resolução Espectral | Resolução Espacial | Resolução Radiométrica |
|---|-------|-------------------------|--------------------|------------------------|
| HRV <i>Haute Résolution Visible</i> | XS1 | 0,50-0,59 μm | 20 m | 8 bits (256 níveis) |
| | XS2 | 0,61-0,68 μm | 20 m | 8 bits (256 níveis) |
| | XS3 | 0,79-0,89 μm | 20 m | 8 bits (256 níveis) |
| | Pan | 0,51-0,73 μm | 10 m | 6 bits (256 níveis) |

Tabela 3.7 – Principais características dos sensores HRV

Os sistemas HRV (figura 3.10) são constituídos por uma matriz linear de sensores, os quais representavam, na altura da sua apresentação, uma concepção totalmente inovadora relativamente ao que havia sido feito até então. Este sistema surgiu face à necessidade de alcançar maiores resoluções espectrais e espaciais, o que só se consegue aumentando o tempo de aquisição de cada pixel. Ao contrário do sistema utilizado pelos satélites Landsat, o utilizado

nos SPOT não faz uso dum espelho de varrimento (que é eliminado), utilizando em sua substituição um conjunto de sensores CCD's (*Charge Coupled Devive*) alinhados lado a lado, ao longo de uma linha perpendicular à órbita do satélite. Cada sensor CCD é responsável pela aquisição de uma unidade de resolução mínima no terreno (pixel). Cada linha de dados da imagem é obtida por amostragem da resposta dos detectores ao longo da matriz, e linhas sucessivas são obtidas através de amostras repetidas da matriz, à medida que o satélite percorre a sua órbita em torno da Terra. Deste modo, surge um detector responsável por cada coluna de pixels da imagem.

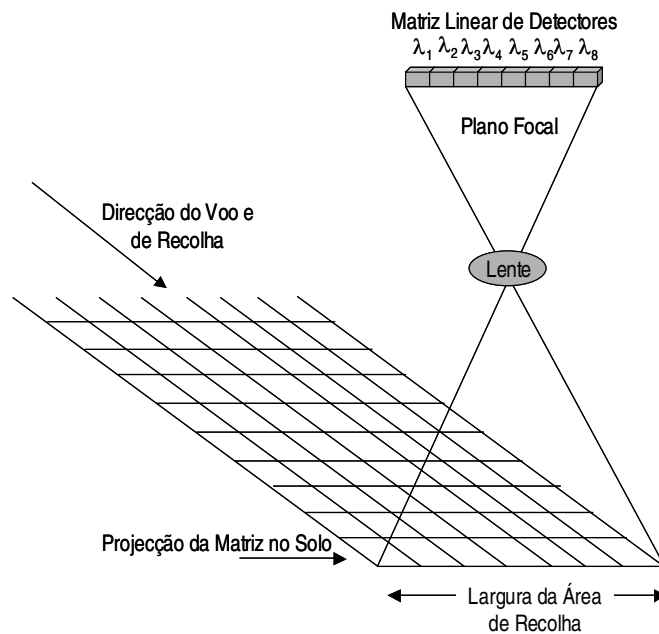


Figura 3.10 – Sensor de matriz linear

A matriz linear tem, relativamente ao espelho de varrimento, a vantagem de não possuir partes móveis, o que não só aumenta a durabilidade do equipamento, como elimina os erros geométricos introduzidos nos dados durante o processo de aquisição, devido às variações de velocidade do espelho. Além disso, os sensores móveis, devido ao seu próprio movimento, produzem mais ruído do que os fixos, o que vai influenciar negativamente a qualidade dos dados captados (alterando em maior percentagem a diferença entre a radiação que chega ao sensor e o valor registado na imagem).

Refira-se que a grande dificuldade na criação de sensores com uma grande resolução espacial é a necessidade de maior criação de sensores com uma grande resolução espacial é a necessidade de maior ganho. Terem mais ganhos, produzem também mais ruído na sua saída, degradando a qualidade da informação captada. As acções desenvolvidas para tentar proteger o sensor do seu

próprio ruído, normalmente tornam-no mais “insensível”, reduzindo a sua resolução espectral. Assim, pode-se afirmar que o acréscimo da resolução espacial está associado ao decréscimo da resolução espectral e vice-versa. A quebra desta correlação inversa entre os dois valores de resolução, espacial e espectral, é objectivo de todos os construtores de sensores.

Cada HRV contém quatro matrizes CCD; uma com 6000 elementos, utilizada para captar os dados em modo pancromático, e três com 3000 elementos que captam as três bandas multiespectrais. Tendo em consideração que uma imagem SPOT tem, em modo multiespectral, 3000 linhas por 3000 colunas, e em pancromático 6000 por 6000 (10 metros de resolução espacial em oposição aos 20 metros das outras bandas), ter-se-á uma matriz linear de detectores composta por 3 e 6 mil sensores, respectivamente. No caso multiespectral (XS), como são adquiridas três bandas, o sistema de aquisição é constituído por um trio de matrizes.

Analisando de uma forma mais pormenorizada este sistema (figura 3.11), vê-se que ele possui um espelho plano, que pode orientar o seu campo de visão para qualquer dos lados da vista nadiral. Não se trata de um espelho de varrimento, simplesmente reflecte a energia electromagnética reflectida ou emitida pela superfície terrestre dentro da sua área de influência para o sistema óptico que, por sua vez, foca a imagem nos dois conjuntos de detectores.




Figura 3.11 – Corte esquemático do sistema de imagem do SPOT

O campo de visão de cada HRV é de $4,13^\circ$ o que, na prática, faz com que cada imagem HRV, obtida em posição nadiral, tenha uma largura de 60 km. Neste caso, existe uma sobreposição lateral de 3 km entre as duas imagens (obtidas pelos dois instrumentos HRV), permitindo a cobertura de uma faixa com 117 km de largura (figura 3.12).




Figura 3.12 – Área coberta pelo SPOT recorrendo ao funcionamento dos sensores HRV em modo adjacente

Uma das principais potencialidades do SPOT é permitir, através de uma solicitação por parte da estação terrestre, orientar o espelho oscilatório num máximo de 27° (utilizando para o efeito 45 movimentos de $0,6^\circ$ cada) para cada um dos lados (figura 3.13), relativamente ao percurso do satélite, viabilizando a aquisição de imagens até 475 km para Oeste ou Este da trajetória (950 km de largura centrados no satélite). Naturalmente que a largura da área coberta varia de acordo com o ângulo de aquisição (orientação do espelho) sendo, por exemplo, de 80 km quando o espelho se encontra rodado ao máximo de 27° .

Cada sensor HRV é capaz de recolher simultaneamente dados pancromáticos e multiespectrais, resultando em quatro linhas de aquisição de dados. No entanto, apenas duas linhas de dados podem ser transmitidas para as estações terrestres ao mesmo tempo. Além do mais, muito embora possam ser transmitidos dados pancromáticos e multiespectrais relativos a uma largura de 117 km, tal situação não se pode verificar simultaneamente. Os dados são normalmente transmitidos para Terra quando o satélite está dentro do alcance de uma estação (figura 3.14) de recepção (aproximadamente um raio de 2600 km em torno da estação). Quando o satélite não está dentro da área de influência de nenhuma estação, os dados são armazenados nos gravadores existentes a bordo e posteriormente transmitidos (quando o satélite reentra para as estações de *Toulouse* (França) e *Kiruna* (Suécia)).




Figura 3.13 – Amplitude do ângulo de visada oblíqua (não nadiral) do SPOT

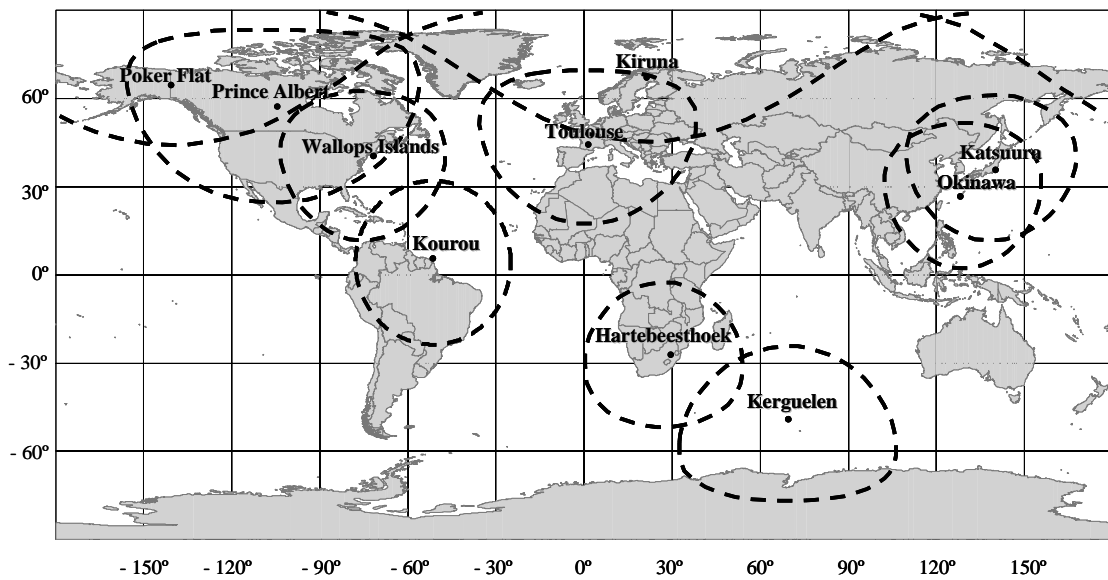


Figura 3.14 – Estações de recepção de dados do programa SPOT

Uma outra funcionalidade deste sistema é a de produzir imagens estereoscópicas (figura 3.15), permitindo posteriormente elaborar modelos digitais de elevação do terreno. Para aceder a esta propriedade torna-se necessário recorrer às capacidades de aquisição de imagens de posição não nadiral. O efeito de estereoscopia pode ser obtido através da combinação de: (i) duas imagens da mesma área obtidas a partir de órbitas diferentes e portanto com perspectivas diferentes, (ii) uma imagem vertical (nadiral) com uma adquirida de Este ou Oeste (não nadiral) obtidas pelos dois HRV na mesma órbita (iii) duas imagens obtidas por dois satélites. No caso de (i) e (iii) a frequência com que as imagens estereoscópicas podem ser adquiridas está ligada à já referida capacidade de “revisita” do satélite, variando portanto com a latitude (ver figura 3.16-a e b).




Figura 3.15 – Exemplo de captura de imagens estereoscópicas

Como exemplo, durante o desfasamento temporal de 26 dias que separa duas passagens sucessivas do satélite sobre um ponto situado no equador (figura 3.16-a), existem sete oportunidades de aquisição de imagens: O dia D (vista nadiral) e os dias D + 5, + 10, + 11, + 15, + 16 e + 21. Numa situação idêntica, mas que ocorra a uma latitude de 45° (figura 3.16-b), existirão 11 possibilidades de captura de imagens (dia D e os dias D + 1, + 5, + 6, + 10, + 11, + 15, + 16, + 20, + 21 e + 25).

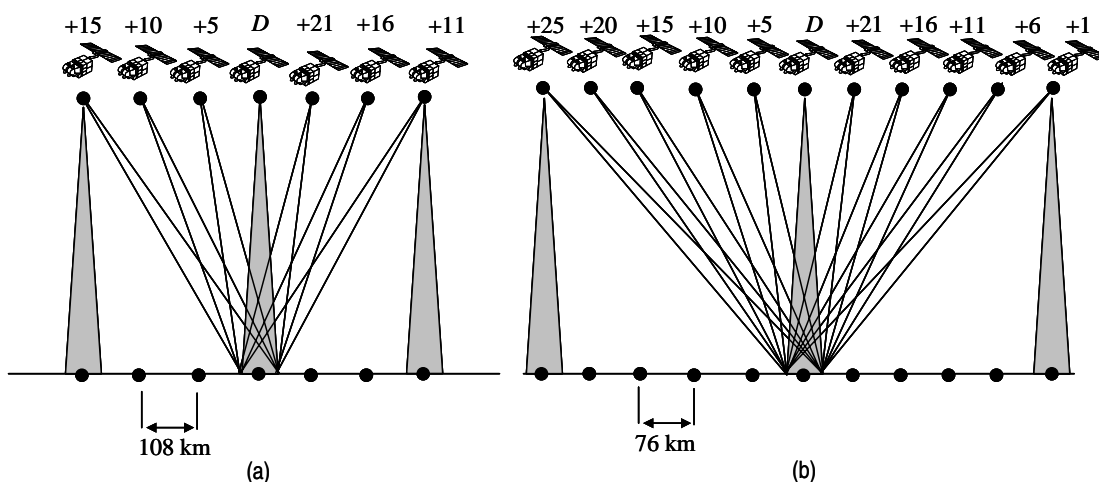


Figura 3.16 – Capacidade de “revisita” do satélite SPOT: (a) a uma Latitude de 0° (Equador); (b) a uma Latitude de 45°

c) Sensores a Bordo dos SPOT 4 e 5

Lançado em 1998, o SPOT 4 veio trazer algumas inovações relativamente aos seus antecessores. Efectivamente, para além de possuir dimensões diferentes (2x2x5,4 m), o SPOT 4 apresentou dois novos sensores baptizados como *Haute Résolution Visible – Infrared* (HRVIR) e *Vegetation* (VGT); o primeiro (tabela 3.8) corresponde a uma pequena evolução relativamente ao HRV, passando a existir uma nova banda no infravermelho médio com uma resolução espacial de 20 m e designada de *shortwave infrared* (SWIR). As bandas multiespectrais existentes no HRV – XS1, XS2 e XS3 – mantiveram, à semelhança da pancromática, todas as suas características, vendo apenas a sua designação alterada para B1, B2 e B3, respectivamente; o segundo é um sensor completamente novo que usa quatro bandas espectrais, das quais três (B2, B3 e SWIR) possuem a mesma resolução espectral que as suas congéneres do HRVIR sendo utilizadas para identificar os tipos de vegetação e de culturas, e uma, a banda B0 (0,43-0,47 μm), utilizada apenas para correcções atmosféricas. Todas estas bandas têm um IFOV de $1,4 \times 10^{-3}$ rad, ou seja, cerca de 1,15 km no solo, podendo no entanto ser fornecidas com um pixel reamostrado de 4 ou 8 km, configuração bastante útil quando se procede ao estudo de fenómenos que se verificam a uma grande escala.

| Sensor | Banda | Resolução Espectral | Resolução Espacial | Resolução Radiométrica |
|---|-------|-------------------------|--------------------|------------------------|
| HRVIR <i>Haute Résolution Visible – Infrared</i> | B1 | 0,50-0,59 μm | 20 m | 8 bits (256 níveis) |
| | B2 | 0,61-0,68 μm | 20 m | 8 bits (256 níveis) |
| | B3 | 0,79-0,89 μm | 20 m | 8 bits (256 níveis) |
| | SWIR | 1,58-1,75 μm | 20 m | 8 bits (256 níveis) |
| | Pan | 0,51-0,73 μm | 10 m | 6 bits (256 níveis) |

Tabela 3.8 – Principais características dos sensores HRVIR

O VGT consegue discriminar ocupações do solo com pequenas diferenças de reflectância o que lhe permite detectar mudanças subtis no coberto vegetal. Além disso, o seu campo de visão (2250 km) permite uma cobertura diária de 100% das áreas situadas numa latitude superior a 35°, e de 90% das regiões equatoriais, sendo possível obter uma cobertura integral do planeta cada dois dias (figura 3.17).

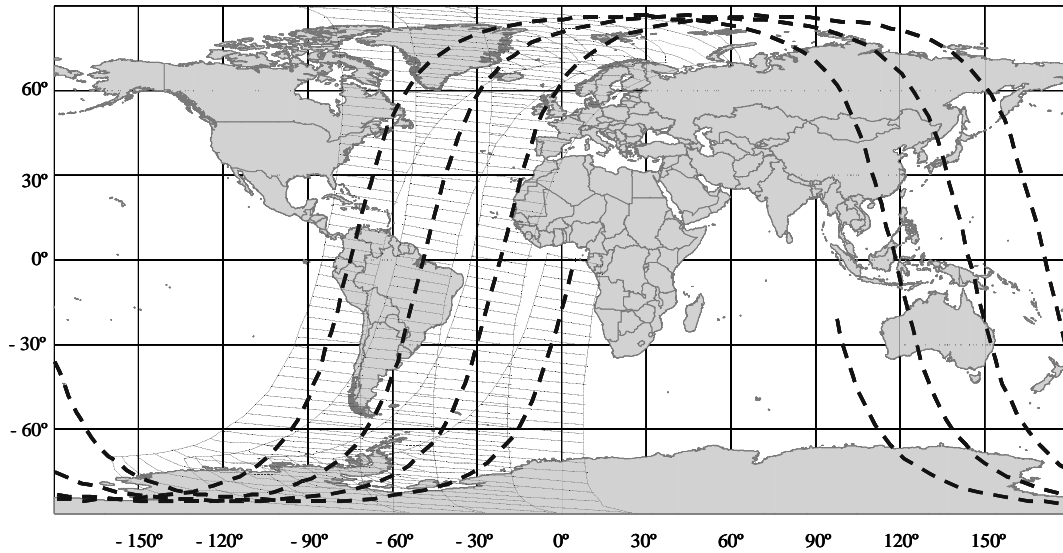


Figura 3.17 – Áreas cobertas pelo VGT depois de 3 órbitas

O programa VGT, iniciado pelo CNES, foi desenvolvido em parceria com o a Bélgica (14% do orçamento total), Itália (1%), Suécia (8%) e União Europeia (35%), ficando 34% a cargo do governo Francês. Os custos de desenvolvimento cifraram-se em cerca de 110 milhões de Euros e as despesas de operacionalidade estão estimadas em 37 milhões de Euros nos primeiros cinco anos, prevendo-se que este encargo seja em parte suprido pelas vendas. A participação da União Europeia no projecto é justificada pela utilidade deste tipo de informação num grande conjunto de políticas sectoriais como a agricultura, floresta e ambiente, e marca uma mudança na forma como os sistemas de detecção espacial são desenvolvidos e geridos.

Por fim, o SPOT 5, apresenta um novo aumento de dimensões (figura 3.18), agora para 3,1x3,1x5,7 m. Relativamente a aspectos mais técnicos, o VGT mantém-se inalterado, enquanto que o HRVIR é renomeado de HRG, o qual mantém todas as características da banda SWIR e apresenta melhoramentos na resolução da banda pancromática (5 m – 12000 pixels por 12000 linhas) e das bandas multiespectrais B1, B2 e B3 (10 m – 6000 pixels por 6000 linhas). Além destas características, o SPOT 5 apresenta ainda um novo sistema, denominado de HRS, que permite a obtenção quase simultânea (diferença de 1,5 min) de duas imagens pancromáticas numa única passagem. Este instrumento (HRS) não possui a capacidade de obter imagens não nadirais, observando apenas uma área de 120 km centrados na linha de passagem do satélite, o que permite uma maior correlação entre as duas imagens e, conseqüentemente, um modelo de

elevação do terreno com maior qualidade. A resolução espacial destas imagens estereoscópicas é de 10 m e a exactidão do modelo do terreno originado a partir delas é de cerca de 15 m.




Figura 3.18 – Tamanho comparativo dos satélites SPOT

Outra vantagem retirada da possibilidade de combinar duas imagens pancromáticas é a de obter uma imagem com uma resolução espacial de 2,5 m (funcionalidade designada de “super modo”). Em termos de telemetria, esta versão do SPOT consegue processar 5 imagens de cada vez enquanto que os anteriores apenas o podiam fazer com duas. Esta particularidade, associada ao facto de todos os satélites estarem ainda activos e formarem uma autêntica constelação (figura 3.19) em torno da Terra, permite a obtenção de informação sobre qualquer ponto da terra numa base praticamente diária.




Figura 3.19 – Constelação de satélites SPOT

3.3.3 Comparação entre os Programas Landsat e SPOT

Os satélites SPOT e Landsat são, actualmente, os únicos sistemas que, de uma forma continuada, fornecem imagens da superfície da Terra nas bandas do visível e do infravermelho reflectido. Usando como base de comparação a área coberta, observa-se (figura 3.20) que o Landsat tem uma abrangência mais regional que o SPOT, sendo precisas, depois de preparadas para sobreposição, cerca de 12 imagens SPOT para cobrir a área de apenas uma imagem do Landsat.




Figura 3.20 – Comparação entre a dimensão das imagens SPOT e Landsat

Relativamente à resolução espacial, o SPOT apresenta características mais aliciantes (figura 3.21) pois permite uma identificação mais detalhada dos objectos que pontificam na superfície terrestre. Com efeito, se a uma escala 1:100 000 (largamente utilizada na interpretação de imagens) as diferenças entre as duas imagens são negligenciáveis, ao aumentar-se a escala para 1:10 000, ou mesmo 1:25 000, as limitações do Landsat começam a ser evidentes, principalmente quando se trata de identificar o complexo rendilhado de usos existente em áreas urbanas.

Em termos de resolução espectral, o Landsat destaca-se facilmente como a melhor opção, na medida em que possui 7 bandas multiespectrais contra 4 do SPOT. Além disso, este último não cobre a importante região espectral do infravermelho reflectido, ao contrário do que se verifica para o Landsat, onde existem duas bandas (TM 5 e 7) a operar nessa região do espectro. Contudo, o satélite SPOT também tem uma capacidade única, que é a de providenciar imagens em estereoscopia, as quais se revelam valiosas para diversas interpretações e para a geração de mapas topográficos.




Figura 3.21 – Comparação entre a dimensão do pixel das imagens SPOT e Landsat

Em termos de custo por km², uma imagem SPOT é cerca de cinco vezes mais cara que uma imagem Landsat. No entanto, para muitos projectos o custo da informação é considerado insignificante face às quantias envolvidas. A eficiência, resposta rápida e conteúdo temático das imagens de satélite são, regra geral, considerados mais importantes que os seus custos. Em síntese, as maiores vantagens das imagens SPOT prendem-se com a sua maior resolução espacial e a cobertura estereoscópica; nas imagens Landsat, são a cobertura regional e uma importante selecção de bandas espectrais.

4

CLASSIFICAÇÃO DE IMAGENS DE SATÉLITE

4.1 INTRODUÇÃO

As imagens de satélite são consideradas, desde o seu aparecimento, como um poderoso meio de obter informação actualizada, a custos relativamente baixos, sobre as actividades que decorrem em meio urbano, incluindo aquelas que se processam na franja urbano-rural [18]. Neste contexto, assumem papel fundamental as técnicas de classificação de imagens. O objectivo principal destas técnicas é, de uma forma (semi)automática, atribuir a cada um dos pixels que compõem uma determinada imagem um tema ou uma classe de uso e ocupação do solo. Normalmente, esta classificação é efectuada com recurso a dados multispectrais, tendo por base o facto de os vários objectos reflectirem (ou emitirem) de forma diferente em bandas diferentes.

Os algoritmos tradicionais de classificação de imagens de satélite não se adaptam às particularidades do meio urbano, nomeadamente à frequência espacial dos objectos, na medida em que classificam cada pixel com base unicamente nas suas características espectrais sem

explorar qualquer tipo de relação de vizinhança (**classificadores espectrais**) [5, 6]. Para tentar ultrapassar este problema foram propostos os métodos de **reconhecimento de padrões espaciais** (ou **classificadores contextuais**), que envolvem a classificação dos pixels de uma imagem com base no seu relacionamento espacial com os pixels vizinhos [13, 17]. Estes classificadores recorrem a informação como a textura de uma imagem, proximidade dos pixels, e dimensão dos elementos existentes na superfície terrestre, bem como a sua forma, orientação, frequência e contexto, almejando replicar a análise espacial efectuada por um ser humano aquando da interpretação visual de imagens. Em consequência estes métodos tendem a ser mais complexos e computacionalmente mais pesados do que os **classificadores espectrais**.

Na classificação de imagens de satélite, independentemente das características particulares do classificador utilizado, podem ser seguidas duas abordagens distintas: **classificação supervisionada** e **classificação não supervisionada**. A principal diferença entre os dois tipos de métodos reside no facto de no primeiro caso se partir de exemplos de classificações correctas, que envolvem um conhecimento prévio do terreno, normalmente adquirido através da realização de trabalhos de campo, da interpretação de fotografias aéreas ou a partir de cartas temáticas já existentes, enquanto que no segundo esses exemplos são inexistentes, não se exigindo um conhecimento prévio da área de estudo. No entanto, raramente se inicia um trabalho sem analisar previamente a área a classificar, o que neste caso se traduz num conhecimento que, regra geral, condiciona a escolha do número de classes a estabelecer.

Neste capítulo, descrevem-se alguns dos principais classificadores espectrais de classificação de imagens, apresentando, sempre que se justifique, exemplos de aplicações em áreas urbanas. Numa primeira parte, analisa-se a abordagem supervisionada, detalhando-se todas as fases que lhes estão subjacentes. Numa segunda parte faz-se uma análise semelhante relativamente à estratégia não supervisionada. Finalmente, apresentam-se os mais recentes desenvolvimentos em matéria de classificadores espectrais, que combinam informação espectral com informação auxiliar (não espectral), nomeadamente informação estatística proveniente dos Recenseamentos Gerais da População e Habitação.

4.2 CLASSIFICAÇÃO SUPERVISIONADA

As aplicações desenvolvidas com recurso a técnicas clássicas de análise de dados e a complexidade de situações que ocorrem no globo terrestre, têm fomentado a predominância dos métodos de classificação supervisionada. A classificação supervisionada é fisicamente efectuada em quatro fases distintas: *i*) definição de nomenclatura, onde se estabelecem as classes de ocupação do solo; *ii*) treino; *iii*) classificação; *iv*) apresentação e avaliação de resultados.

Na **fase de treino**, o analista identifica áreas de treino, o mais homogêneas possível do ponto de vista espectral e, com base nestas áreas, desenvolve uma descrição estatística dos atributos espectrais de cada uma das classes de uso e ocupação do solo identificadas na imagem. Na **fase de classificação**, cada pixel é atribuído à classe de ocupação do solo com que apresenta maior similaridade. Os pixels que não apresentem analogias significativas com nenhum dos conjuntos de treino, são normalmente classificados como “desconhecidos” ou simplesmente “não classificados”. Por fim, entra-se na chamada **fase de apresentação de resultados**, na qual a classe atribuída a cada pixel é registada numa imagem final (ou mapa temático) e se produzem tabelas com informação estatística que permite avaliar a qualidade da classificação.

4.2.1 A fase de treino

O objectivo principal da fase de treino é reunir um conjunto de estatísticas que descrevam o comportamento espectral para cada classe de ocupação de solo. A necessidade de obter áreas de treino para uma classificação supervisionada requer uma análise aprofundada da informação espectral contida numa imagem. Para além disso, obriga também à utilização de informação de referência e um profundo conhecimento da área geográfica. Em síntese, a qualidade do processo de treino determina o sucesso da fase de classificação e, por isso, determina também o valor da informação gerada pela classificação.

Existem várias formas de cumprir esta fase: *i*) recolha de informação no terreno; *ii*) delimitação de áreas de treino sobre a imagem visualizada no monitor; *iii*) criação de áreas de treino por crescimento de regiões previamente identificadas na imagem. Idealmente, a informação deverá ser recolhida no local e as coordenadas do perímetro das áreas de interesse deverão ser obtidas através de um mapa ou, de forma directa, utilizando um Sistema de Posicionamento Global (*Global Positioning System – GPS*). As coordenadas fornecidas pela versão portátil de um aparelho deste tipo podem diferir até ± 100 m relativamente à posição real, o que pode não ser suficiente quando se está a trabalhar com dados provenientes de detecção remota que têm uma resolução espacial menor ou igual a 30 m. Se o estudo em causa requerer uma maior precisão, as leituras do GPS podem ser optimizadas recolhendo várias leituras do mesmo local, e efectuando a média dos valores obtidos, ou tendo acesso a uma estação de GPS fixa que providencie a informação necessária à calibração dos resultados. Contudo, este processo raramente é viável, seja por dificuldades logísticas, por problemas orçamentais, ou mesmo porque as coordenadas medidas no terreno têm uma precisão superior às retiradas da imagem.

A delimitação das áreas de treino acaba invariavelmente por ser feita a partir de uma imagem visualizada em computador. A localização das áreas de treino na imagem é normalmente estabelecida com recurso a uma composição colorida, com ampliação, sobre a qual, regra geral,

o analista obtém áreas de treino através da delimitação no monitor das fronteiras (ou polígonos) envolventes dessas áreas. Neste processo deve-se evitar a selecção de pixels situados nas fronteiras de transição entre dois tipos de uso/ocupação do solo. As coordenadas, em linha e coluna, dos vértices dos polígonos delimitados, vão ser usadas como base da extracção (da imagem) dos valores de brilho dos pixels situados dentro das áreas de treino. São estes valores que vão servir de amostra para o desenvolvimento da descrição estatística de cada área de treino. A título de exemplo apresenta-se, na figura 4.1, uma área de treino e o respectivo polígono envolvente, relativo à classe “água”.

Uma alternativa à delimitação de polígonos é o método do crescimento de regiões. Neste caso (figura 4.1 – polígono correspondente à agricultura), o cursor é colocado sobre o pixel considerado como representativo da classe. Depois, de acordo com vários critérios estatísticos, os pixels contíguos com características espectrais similares ao pixel original são assinalados como área de treino.

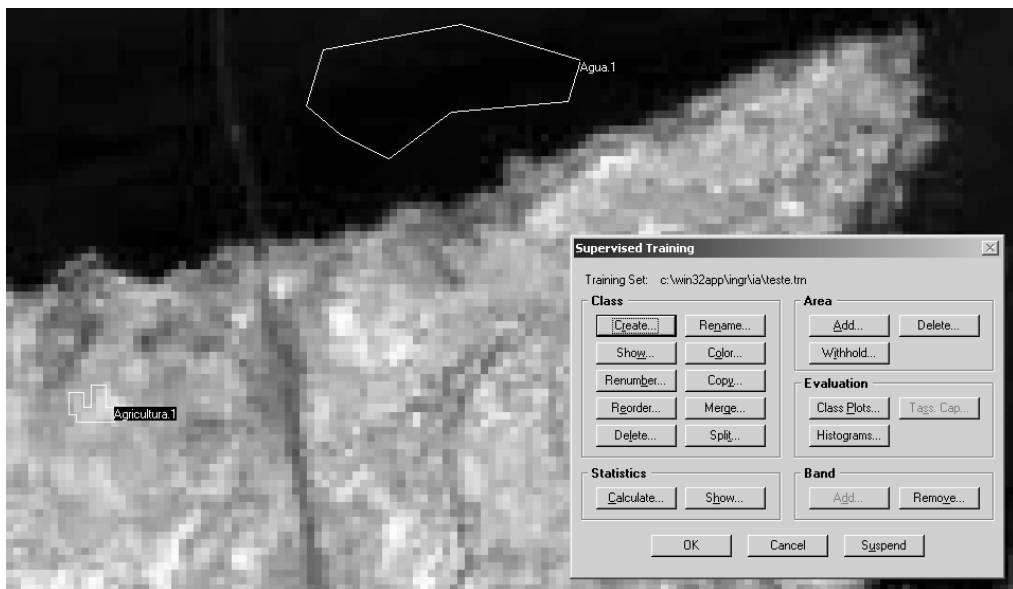


Figura 4.1 – Polígonos correspondentes às áreas de treino “água” e “agricultura”

Se o analista criar as áreas de treino para um conjunto de seis bandas então cada pixel, em cada área de treino, é representado por um vector de medição \mathbf{x}_c , tal que:

$$\mathbf{x}_c = \begin{bmatrix} NR_{ij1} \\ NR_{ij2} \\ NR_{ij3} \\ NR_{ij4} \\ \vdots \\ NR_{ijk} \end{bmatrix}, \quad (4.1)$$

onde NR_{ijk} é o nível radiométrico correspondente ao brilho (ou luminância) do pixel i, j na banda k . Os níveis radiométricos de cada pixel em cada banda e em cada classe de treino podem ser analisados estatisticamente de forma a obter-se um vector de médias (m_c) para cada classe:

$$m_c = \begin{bmatrix} \mu_{c1} \\ \mu_{c2} \\ \mu_{c3} \\ \mu_{c4} \\ \vdots \\ \mu_{ck} \end{bmatrix}, \quad (4.2)$$

onde μ_{ck} representa o valor médio dos dados obtidos para a classe c na banda k . O vector de medição também pode ser analisado de maneira a obter-se a matriz de covariância para cada classe c :

$$V_c = V_{ckl} = \begin{bmatrix} Cov_{c11} & Cov_{c12} & \cdots & Cov_{c1n} \\ Cov_{c21} & Cov_{c22} & \cdots & Cov_{c2n} \\ \vdots & \vdots & \ddots & \vdots \\ Cov_{cn1} & Cov_{cn2} & \cdots & Cov_{cnn} \end{bmatrix}, \quad (4.3)$$

representando Cov_{ckl} a covariância da classe c nas bandas k e l . Doravante, por uma mera questão de simplificação, a notação para a matriz de covariância da classe c será representada apenas por V_c .

Independentemente da forma como são delimitadas as áreas de treino, o número mínimo de pixels nelas contido deve ser, quando se utiliza um classificador baseado em métodos estatísticos, de $n + 1$, onde n corresponde ao número de bandas utilizadas. Um número inferior invalidaria a avaliação apropriada da variância e covariância dos valores das respostas espectrais. Contudo, na prática, é utilizado um número mínimo de $10n$ ou $100n$ pixels, uma vez que a estimação dos vectores médios e matrizes de covariância melhora à medida que o número de pixels existentes nos conjuntos de treino aumenta. Deste modo, é possível afirmar-se que quanto maior for o número de pixels das classes de treino, tanto melhor será a representação estatística de cada classe espectral, e desde que a homogeneidade das áreas de treino seja garantida.

Quando se está a identificar as áreas de treino, revela-se de grande importância a delimitação de várias destas áreas cobrindo toda a imagem. Ou seja, é melhor definir um padrão de treino para

uma determinada classe analisando vinte polígonos, cada um com quarenta pixels, do que analisando apenas um polígono com oitocentos pixels. A distribuição, tão homogênea quanto possível, das áreas de treino sobre a imagem aumenta a probabilidade dos dados de treino serem representativos de toda a variabilidade inerente às classes de uso e ocupação do solo presentes na matriz de dados.

Durante o processo a que se dá o nome de **afinação (ou refinamento) do conjunto de treino**, a qualidade global dos dados contidos em cada uma das áreas de treino iniciais é avaliada analisando-se em seguida a sua separabilidade espectral. O analista confirma se todos os conjuntos de dados correspondem na sua essência a distribuições normais. As áreas de treino que inadvertidamente incluem mais do que uma classe espectral são identificadas e delimitadas de novo. Do mesmo modo, alguns pixels podem ser removidos das áreas de treino, o que se verifica normalmente em áreas de transição onde os pixels (ou neste caso *mixels*) não correspondem a um uso mas a uma conjugação de usos. Os conjuntos de treino que devem ser agrupados (ou apagados) são identificados, determinando-se também a necessidade de obter conjuntos de treino adicionais para classes espectrais fracamente representadas.

Recorrendo à **representação gráfica dos padrões de resposta espectral** (histogramas) pode-se visualizar a distribuição dos padrões de respostas dos conjuntos de treino, procedendo-se se for caso disso ao seu refinamento. Como exemplo, a figura 4.2 apresenta os histogramas correspondentes aos dados de treino da categoria “floresta”, para seis das sete bandas Landsat TM (excluindo-se a banda do infravermelho-térmico). Note-se que, principalmente nas bandas 3, 5 e 7 existem alguns pixels remanescentes do lado esquerdo do histograma que, embora percentualmente pouco significativos, podem fazer perigar as características *gaussianas* idealizadas para os dados; a característica bimodal destes histogramas pode dever-se a diferentes espécies de árvores, diferenças de iluminação, etc. e seria melhor para o processo de classificação que as duas classes subjacentes fossem tratadas independentemente.

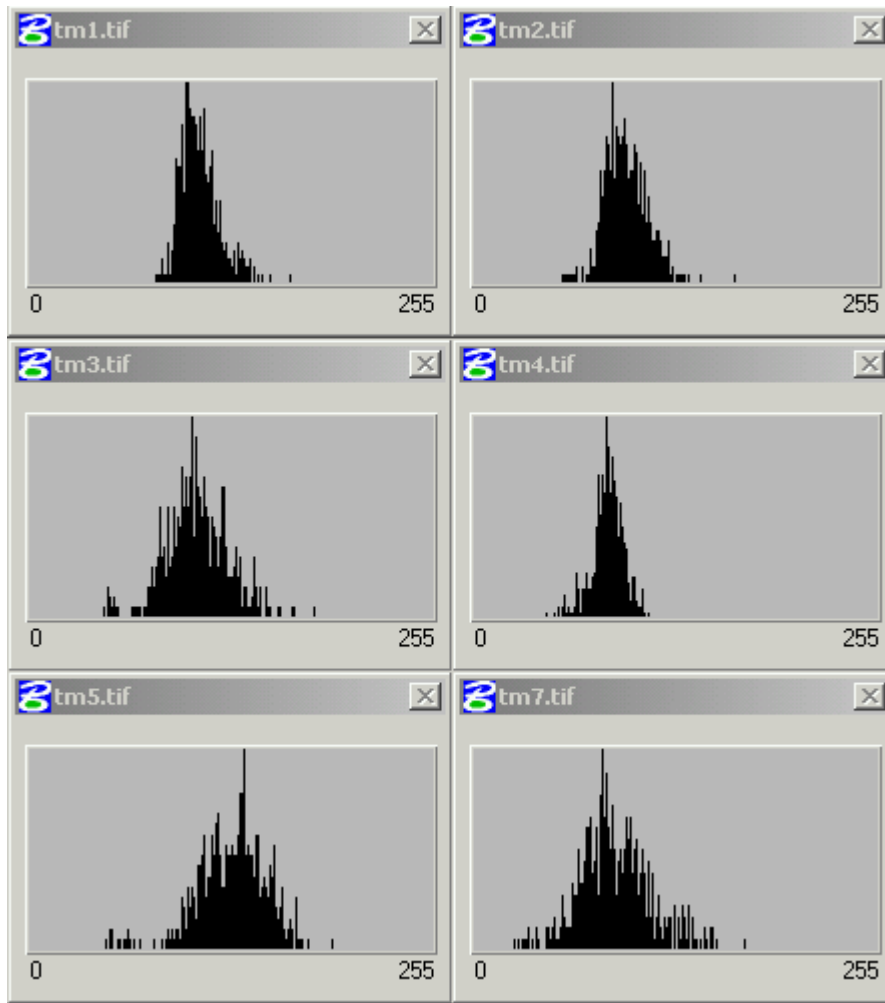


Figura 4.2 – Exemplo de histogramas das áreas de treino respeitantes à classe “floresta”

4.2.2 A fase de classificação

Ao longo dos anos têm sido desenvolvidas inúmeras abordagens matemáticas à questão do reconhecimento de padrões espectrais, tendo sido apresentadas várias propostas de algoritmos. Revela-se de todo o interesse rever a lógica por que se regem alguns destes classificadores. Entre os mais utilizados, destacam-se métodos como o do **paralelepípedo**, da **mínima distância**, de **máxima verosimilhança** e de *Bayes*, eleitos como os melhores classificadores supervisionados para proceder à classificação de imagens. Nestes, como atrás referido, recorre-se a uma nomenclatura para proceder à classificação ou seja, as classes de ocupação são estabelecidas previamente, e os parâmetros estatísticos são aferidos com base em amostras das assinaturas espectrais das classes a representar, vulgo áreas de treino.

1) Método do Paralelepípedo

O classificador do **paralelepípedo**, é bastante simples, sendo usualmente treinado através da inspeção dos histogramas individuais de cada uma das componentes espectrais dos dados de treino. Como exemplo, considerem-se os histogramas de uma determinada classe espectral para um conjunto de dados bidimensional (duas bandas – x_1 e x_2) representados na figura 4.3 (a) e b)). O classificador do paralelepípedo identifica os limites máximo e mínimo dos histogramas e considera-os como os valores limites de nível radiométrico da classe espectral, na banda correspondente ao histograma. Em conjunto, as amplitudes em todas as bandas definem uma caixa multidimensional ou paralelepípedo. Se durante o processo de classificação, um pixel se encontrar dentro de um desses paralelepípedos, é classificado como pertencente à respectiva classe espectral. Deste modo, é possível segmentar um padrão espacial bidimensional (figura 4.3 c)).




Figura 4.3 – Histogramas de um conjunto bidimensional de dados de treino para uma classe espectral (a e b) e região de decisão da classe (c)

Muito embora o classificador do paralelepípedo seja, em princípio, particularmente simples de treinar e usar, tem várias desvantagens. Uma delas é a possibilidade de existirem espaços consideráveis entre os paralelepípedos; os pixels nessas regiões não serão classificados (pixel “a” na figura 4.4) e consequentemente ficarão partes da imagem por classificar. Outra limitação prende-se com o facto de as probabilidades *a priori* de ocorrência de cada classe não serem tidas em consideração. Por fim, quando os dados apresentam uma forte correlação entre bandas existirá forte sobreposição entre dois ou mais paralelepípedos (porque os seus lados são paralelos aos eixos espectrais), fazendo com que existam dados atribuídos a duas ou mais classes (pixel “b” na figura 4.4). O pixel “c” é o único dos representados na figura 4.4 cuja classificação não colocaria qualquer tipo de problema.

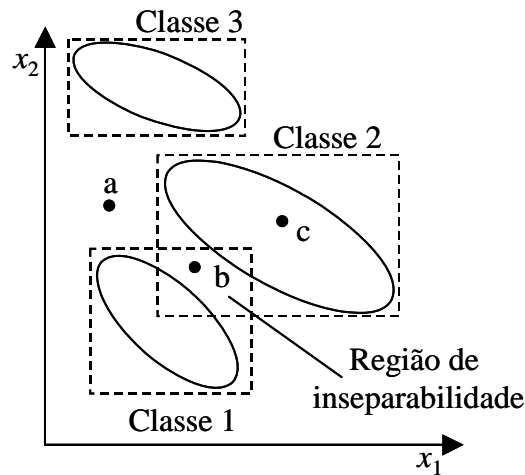


Figura 4.4 – Classificação de dados correlacionados usando o método do paralelepípedo e mostrando a região de inseparabilidade (as elipses representam os diagramas de dispersão para as classes 1, 2 e 3, nas bandas x_1 e x_2)

Resumindo, o classificador do paralelepípedo é um método computacionalmente eficiente. O maior problema deste método reside no facto de as regiões de decisão rectangulares não se ajustarem convenientemente à distribuição dos dados de treino, sobretudo quando a correlação entre bandas (covariância) é elevada, resultando num incremento de confusão para o classificador.

Infelizmente, os padrões de resposta espectral estão frequentemente bastante correlacionados, resultando em regiões de decisão com sobreposição, tornando possível que um pixel satisfaça os critérios de mais do que uma classe. Nesta situação, o pixel é atribuído à primeira classe para a qual satisfaz o critério de decisão. Este problema pode ser reduzido substituindo os rectângulos de cada região de decisão por um conjunto de rectângulos de menores dimensões, com as fronteiras organizadas entre si em forma de escada, descrevendo com maior exactidão os limites das regiões de decisão. Uma outra forma de resolver o problema, talvez até mais elegante, consiste em “pegar” nestes pixels multi-classe e utilizar a regra da distância mínima à média para escolher a classe a que seriam atribuídos.

2) Classificador da Mínima Distância

O método da **mínima distância** requer a determinação dos vectores médios (m_c) para cada classe de treino. Para realizar a classificação com base no critério da mínima distância, este método calcula a distância entre o pixel a classificar e cada vector médio. A classificação propriamente dita consiste em catalogar um pixel na classe de treino mais próxima.

Existem vários critérios para definir a distância anteriormente referida, sendo os mais vulgares a “**distância em torno do quarteirão**”, mais conhecida por **distância de Manhattan** (ou **distância L1**) e a **distância euclidiana** (ou **distância L2**). Considerando dois pontos (pixels neste caso) num espaço n-dimensional:

$$\begin{aligned} \mathbf{a} &= (a_1, a_2, \dots, a_n)^T, \\ \mathbf{b} &= (b_1, b_2, \dots, b_n)^T, \end{aligned}$$

a distância de *Manhattan* entre \mathbf{a} e \mathbf{b} é dada por:

$$D_{ab} = \sum_{i=1}^n |a_i - b_i|, \quad (4.4)$$

e a distância euclidiana entre os mesmos dois pontos, por:

$$D_{ab} = \sqrt{\sum_{i=1}^n (a_i - b_i)^2}. \quad (4.5)$$

Como exemplo, a distância euclidiana (*Dist*) entre o pixel a e a classe c , considerando apenas duas bandas espectrais, é calculada a partir de:

$$Dist = \sqrt{(NR_{ij1} - \mu_{c1})^2 + (NR_{ij2} - \mu_{c2})^2}, \quad (4.6)$$

onde NR_{ij1} e NR_{ij2} representam os valores radiométricos do pixel a (com coordenadas imagem (i, j)) nas bandas 1 e 2, respectivamente, e μ_{c1} e μ_{c2} são os valores médios da classe c nas bandas 1 e 2, respectivamente.

Utilizando o classificador da mínima distância da forma atrás descrita, todos os pixels são atribuídos a uma das classes de treino. Esta característica pode constituir uma desvantagem, uma vez que, ao classificar todos os pixels presentes na imagem, o algoritmo pode efectuar atribuições irrealistas. As consequências deste facto podem ser evitadas especificando-se (a maioria dos programas comerciais permite-o) uma distância máxima, ou limiar, para além da qual um pixel não é atribuído a uma determinada categoria, mesmo que seja aquela cuja média lhe esteja mais próxima. Nesta variante, passa a existir a categoria “não classificados”, sendo o pixel em questão classificado como tal.

A principal desvantagem do classificador da mínima distância é ser insensível à variância da distribuição dos dados. Considerando, como exemplo, a figura 4.5, onde a classe 3 apresenta

grande variabilidade, o pixel a seria classificado como pertencente à classe 2, pois o seu valor está bastante mais próximo da média desta classe. No entanto, pode-se constatar que este pixel se encontra inserido no limiar (representada por círculos correspondentes a duas vezes o desvio padrão) da classe 3, pelo que deveria ter sido classificado nesta classe.




Figura 4.5 – Classificação de dados utilizando o método da mínima distância (as circunferências representam os diagramas de dispersão para as classes 1, 2 e 3, nas bandas x_1 e x_2)

O problema da variabilidade pode ser minimizado definindo distâncias normalizadas (*NDist*):

$$NDist = \sqrt{\frac{(NR_{ij1} - \mu_{c1})^2}{\sigma_{c1}^2} + \frac{(NR_{ij2} - \mu_{c2})^2}{\sigma_{c2}^2}} \quad (4.7)$$

onde σ_{ci}^2 é a variância da classe c na banda i .

A versão normalizada do classificador de mínima distância produz resultados bastante satisfatórios, chegando mesmo a suplantar os resultados obtidos pelo classificador da máxima verosimilhança quando as áreas de treino apresentam uma variabilidade elevada.

3) Classificador de Máxima Verosimilhança

O classificador de **máxima verosimilhança** considera que a distribuição dos valores radiométricos de cada classe é *gaussiana* (distribuição normal). A probabilidade de um pixel pertencer a uma classe é calculada a partir da função densidade de probabilidade para uma distribuição normal, sendo esta completamente descrita pelo vector médio da classe (m_c) e pela

matriz de covariância (V_c) da classe c . A regra de decisão aplicada ao vector de medição desconhecido \mathbf{x} é [58]:

\mathbf{x} pertence à classe c_j sse

$$\ln P(\mathbf{x}|c_j) \geq \ln P(\mathbf{x}|c_i) \text{ para } i = 1, 2, 3, \dots, m \text{ e } i \neq j \quad (4.8)$$

com

$$P(\mathbf{x}|c_i) = (2\pi)^{-\frac{2n}{2}} \cdot |V_i|^{-\frac{1}{2}} \cdot \exp\left\{-\frac{1}{2}(\mathbf{x} - \mathbf{m}_i)^T \cdot V_i^{-1} \cdot (\mathbf{x} - \mathbf{m}_i)\right\} \quad (4.9)$$

ou

$$\ln P(\mathbf{x}|c_i) = \left\{-\frac{1}{2} \ln[\det(V_i)]\right\} - \left[\frac{1}{2}(\mathbf{x} - \mathbf{m}_i)^T V_i^{-1} (\mathbf{x} - \mathbf{m}_i)\right] + c^{te}, \quad (4.10)$$

onde m é o número de classes e n o número de bandas, correspondendo $\det(V_c)$ ao determinante da matriz de covariância V_c .

Para classificar o vector de medida \mathbf{x} de um pixel desconhecido, a regra de decisão de máxima verosimilhança calcula o valor de probabilidade para cada classe, por aplicação da expressão (4.10), atribuindo posteriormente o pixel à classe com o valor de probabilidade mais elevado. Se existirem pixels cujos valores os coloquem numa zona de charneira entre duas classes de probabilidade, de tal modo que a probabilidade de pertencerem a qualquer uma das classes seja demasiado baixa, estes pixels são considerados como elementos não classificados. Pode-se então falar da criação dum limiar de decisão para a “melhor” probabilidade, acima do qual o pixel não é atribuído a nenhuma classe espectral.

A principal desvantagem do classificador da máxima verosimilhança é o elevado número de cálculos necessários para classificar cada pixel. Este facto assume particular importância quando a classificação envolve um grande número de bandas e/ou classes espectrais a diferenciar. Quando esta situação se verifica, este algoritmo é substancialmente mais lento que os dois descritos anteriormente.

Para obviar a este problema, têm sido desenvolvidas algumas abordagens, sendo uma delas a redução da quantidade das bandas utilizadas para efectuar a classificação (e portanto reduzindo a quantidade dos cálculos necessários). Normalmente, este propósito é conseguido através da

transformação em componentes principais (ou **transformação canónica de componentes**) das bandas originais, utilizando-se na classificação as três componentes de maior energia.

As **árvores de decisão** e as **classificações estratificadas e por níveis** (*layers*) também têm sido utilizadas de forma a simplificar os cálculos mantendo a exactidão da classificação [28, 84]. Estas técnicas são aplicadas numa sucessão de passos, sendo várias classes separadas em cada passo da forma mais simples possível. Por exemplo a classe ‘*água*’ pode ser separada de todas as outras classes com base num limiar de confiança (*threshold*) aplicado à banda do infravermelho-próximo. Outras classes podem necessitar de apenas duas ou três bandas para proceder à classificação, recorrendo ao classificador do paralelepípedo, sendo o classificador da máxima verosimilhança e um número maior de bandas, aplicados apenas nos casos em que as categorias de uso e ocupação do solo apresentam uma ambiguidade residual entre classes sobrepostas no espaço de medida [42].

4) Classificador de Bayes

Uma extensão do classificador de máxima verosimilhança é o **classificador de Bayes**. Nesta abordagem combinam-se as probabilidades espectrais calculadas pelo método da máxima verosimilhança com uma outra superfície de probabilidade, obtida ou não a partir de técnicas de teledeteção. Estas probabilidades, estabelecidas antecipadamente, podem ser interpretadas como um meio de deslocação das fronteiras de decisão, por forma a criar, num espaço de medição com dimensão n , maiores volumes para classes que se esperam de grande dispersão e volumes mais pequenos para as de dispersão mais diminuta. O analista começa por determinar as probabilidades *a priori* para cada classe. Por exemplo, recorrendo à situação anterior, ao considerar-se uma área hipotética onde a probabilidade de se encontrar o uso ‘urbano’ é de 0,3 e a de encontrar o uso ‘praia’ é de 0,1, seria de esperar que mais pixels fossem classificados como urbano (numa relação de 3 para 1) simplesmente porque este uso tem uma maior prevalência no terreno. Esta informação *a priori* pode ser incluída na regra de classificação, ponderando cada classe com a sua probabilidade *a priori*. Ao aplicar o algoritmo de máxima verosimilhança assume-se uma probabilidade de ocorrência igual para todas as classes. Existindo informação apropriada, o classificador de Bayes é preferível.

Assim, as fórmulas (4.8) e (4.9) tornam-se:

\mathbf{x} pertence à classe c_j sse

$$\ln(a_j P(\mathbf{x}|c_j)) \geq \ln(a_i P(\mathbf{x}|c_i)) \text{ para } i = 1, 2, 3, \dots, m \text{ e } i \neq j, \quad (4.11)$$

onde a_i é a probabilidade *a priori* da classe i e $P(\mathbf{x}|c_i)$ é dado pela expressão (4.9). As probabilidades *a priori* têm sido utilizadas com sucesso como forma de incorporar os efeitos do relevo e outras características do terreno no processo de classificação, de maneira a melhorar o seu resultado final.

Os classificadores de máxima verosimilhança e de *Bayes* envolvem um considerável esforço computacional, em virtude de ser necessário o cálculo de um elevado número de variáveis para obter a probabilidade de um pixel pertencer a uma determinada classe. No entanto, apenas uma pequena fracção dos valores calculados é disponibilizada na saída final da classificação convencional. Este facto levou a que alguns autores [71] sugerissem a apresentação de mais resultados finais, nomeadamente o cálculo das probabilidades *a posteriori* de um pixel pertencer a uma certa classe, por aplicação da teoria das probabilidades de *Bayes*.

Formalmente, a probabilidade *a posteriori* $P(c_j|\mathbf{x})$ de um pixel \mathbf{x} pertencer à classe c_j é dada por:

$$P(c_j|\mathbf{x}) = \frac{a_{j_i} P(\mathbf{x}|c_j)}{P(\mathbf{x})}, \quad (4.12)$$

com $P(\mathbf{x}) = \sum_{i=1}^m a_i P(\mathbf{x}|c_i)$.

A informação *a posteriori* pode ser utilizada para aceder ao nível de confiança que se pode depositar na classificação de cada pixel. Por exemplo, o analista pode decidir manter apenas os pixels cujas probabilidades *a posteriori* sejam superiores a 0,85. Os pixels remanescentes seriam sujeitos a uma nova fase de treino e classificação.

Recentemente [50] o classificador de *Bayes* foi testado com sucesso em *Norwich* (Reino Unido). O seu principal problema tem origem, paradoxalmente, na sua principal virtude, mais especificamente na utilização de informação auxiliar. Efectivamente a qualidade desta informação condiciona de forma contundente os resultados, restringindo desde logo a aplicação desta metodologia a um certo número de aplicações. Para além disso, o método pressupõe que é conhecida a probabilidade condicional para todas as classes, caso esta não exista, ou não esteja disponível, o classificador comporta-se exactamente como o da máxima verosimilhança, com todas as vantagens e desvantagens daí inerentes.

4.3 CLASSIFICAÇÃO NÃO SUPERVISIONADA

Os métodos não supervisionados não utilizam dados de treino como base para a classificação. Esta família de classificadores compreende algoritmos que examinam os pixels e os agregam num determinado número de classes, baseados nos agrupamentos naturais (ou *clusters*) existentes na imagem. A premissa base é que os valores que correspondam a um mesmo tipo de uso e ocupação do solo devem encontrar-se próximos uns dos outros no espaço de medida, enquanto que os dados de diferentes classes devem estar bem separados.

O processo de agregação (*clustering*) implica o agrupamento dos pixels num espaço multiespectral. Os pixels pertencentes a um determinado *cluster* são considerados espectralmente semelhantes. Para quantificar este relacionamento é necessário recorrer a uma medida de similaridade. Embora existam muitas propostas de medidas, as mais utilizadas nas operações de *clustering* têm sido, à semelhança do verificado para o classificador da mínima distância (cf. 4.2.2) a distância euclidiana e a distância *L1* (ou **interponto**). A distância *L1* é claramente mais eficiente do ponto de vista computacional, mas é considerada menos exacta do que a distância euclidiana.

Contudo, a utilização destas medidas para identificar os *clusters* não invalida que existam várias soluções de agrupamento para um mesmo conjunto de dados (figura 4.6). Deste modo, é necessário possuir os meios para avaliar a qualidade da agregação resultante, os quais vão permitir decidir entre os vários *clusters* possíveis. Um dos indicadores de qualidade mais utilizados é o **Sum of Squared Error (SSE)**¹, definido como

$$SSE = \sum_{C_i} \sum_{x \in C_i} (x - m_i)^T (x - m_i) = \sum_{C_i} \sum_{x \in C_i} \|x - m_i\|^2, \quad (4.13)$$

onde m_i é a média do *cluster* i . O somatório interior aplica-se a todos os pixels pertencentes ao cluster C_i ; o somatório exterior aplica-se sobre todos os *clusters*. Esta medida calcula, para cada *cluster* individualmente, a distância cumulativa entre cada pixel e o centro do seu *cluster* e depois soma os resultados obtidos para todos os *clusters*. Se o valor apurado for inferior a um limiar pré-definido, a classificação pode ser considerada satisfatória.

¹ O *Sum of Squared Error* (SSE) é uma medida estatística que fornece ao analista informação sobre a variação não explicada, a sua tradução para português raramente é feita sendo preferencialmente referida pela sigla SSE, contudo nalguma bibliografia é possível encontrar esta medida referenciada como a **soma dos quadrados no interior dos grupos**.

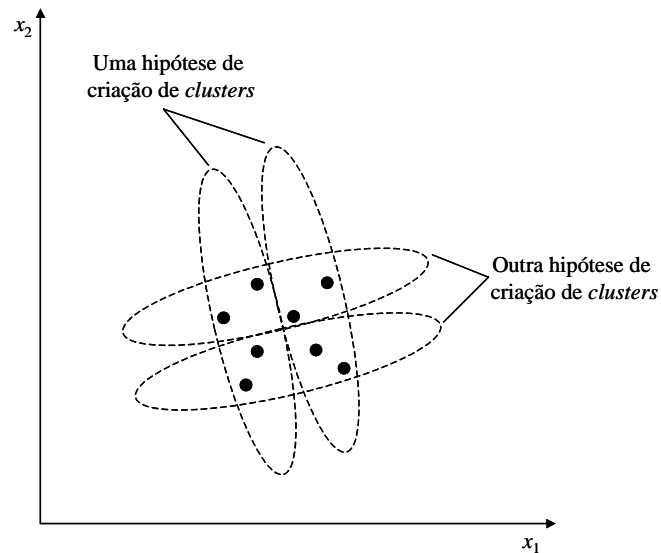


Figura 4.6 – Duas hipóteses diferentes de agrupamento do mesmo conjunto de dados

Deve-se referir que o SSE tem um valor mínimo (teórico) de zero, o qual corresponderia a *clusters* compostos por apenas um pixel. Deste modo, se for utilizado um método adequado para procurar, numa imagem, os *clusters* naturais das classes espectrais é certo, pelo menos teoricamente, que esta operação tem um término. Na prática, o tempo de processamento que seria necessário despende pode inviabilizar o fim natural do processo. Ao invés, os procedimentos iterativos suspendem normalmente os cálculos ao alcançarem um grau de *clustering* “aceitável”.

Posto isto, é possível falar agora num algoritmo baseado nos agrupamentos naturais. Muito embora tal algoritmo devesse depender da diminuição progressiva (e portanto de sucessivos cálculos) do SSE, esta opção não é válida pois na prática a avaliação de todos os *clusters* candidatos implicaria um enorme número de cálculos (valores de SSE). Só para se ter uma ideia da complexidade de tais cálculos refira-se que existem $C^P/C!$ formas de encaixar P pixels em C *clusters* e que seria necessário calcular o SSE em cada etapa do processo de *clustering* de forma a encontrar o valor mínimo. Ao invés de se enveredar por um processo tão rigoroso e computacionalmente exigente como este, opta-se normalmente por utilizar processos heurísticos que são computacionalmente menos exigentes e também conseguem bons resultados.

Um dos métodos heurísticos mais utilizados é o **método iterativo de otimização de *clusters***, também conhecido pelo **método das médias móveis** (ou *K-means*), ou ainda por **método de auto-organização iterativa** (*Iterative Self Organising Data Analysis Technique - ISODATA*). Este método pode ser descrito pelas seguintes etapas:

1. O processo é inicializado através da selecção de diversos C pontos no espaço multiespectral, que irão servir como centros iniciais dos *clusters*. Estes centros são definidos como:

$$\hat{m}_i, i = 1, \dots, C.$$

A selecção inicial dos valores \hat{m}_i é completamente arbitraria, com a excepção de que não podem existir centros iguais.

Para evitar a geração de *clusters* anómalos, com conjuntos de dados pouco vulgares, é costume dispersar-se as médias iniciais dos *clusters* por todo o conjunto de dados¹. Esta acção também pode servir para melhorar a convergência. Antes de dar início a todo o processo o analista tem que, além de escolher \hat{m}_i , indicar o número de *clusters* (C).

2. Cada pixel x do segmento da imagem que vai ser objecto da acção de *clustering* é atribuído ao *cluster* mais próximo. Esta atribuição é usualmente feita com base na distância euclidiana ou na distância $L1$, entre o pixel e o centro do *cluster*.

3. É calculado o novo conjunto de médias que resultam da agregação produzida no ponto (2). As novas médias, que passam a constituir os novos centros dos *clusters*, são definidas por:

$$m_i, i = 1, \dots, C.$$

4. Se $m_i = \hat{m}_i$ para todo o i , o processo termina. Caso contrário, atribui-se a \hat{m}_i o valor corrente de m_i e o processo regressa ao ponto (2).

A figura 4.7 exemplifica o procedimento de optimização iterativa num espaço bidimensional.

¹ Como foi referido no texto o início do processo de optimização iterativa requer que se especifique qual o número de *clusters* esperado, bem como a localização dos seus centros. Contudo, na pratica o número óptimo, ou real, de *clusters* existentes numa imagem não é conhecido. Por isso o analista indica normalmente um número por excesso, considerando que os *clusters* criados que não tenham razão de existir isoladamente poderão ser posteriormente agrupados. A escolha dos centros, embora não seja crítica, vai ter um papel preponderante no tempo total de processamento. De modo a minimizar tempo de computação gasto no processo de iteração costuma utilizar-se a seguinte metodologia: *i*) Os centros iniciais dos *clusters* são escolhidos de forma a que fiquem uniformemente espaçados ao longo da diagonal multidimensional do espaço multiespectral dos pixels (esta linha estende-se da origem ao ponto correspondente ao valor máximo de brilho verificado em cada componente espectral, tipicamente 255). *ii*) A localização dos centros pode ser refinada se o analista tiver algum conhecimento sobre a amplitude dos valores de brilho de cada componente espectral, o que pode ser conseguido, por exemplo, através do cálculo prévio de histogramas.

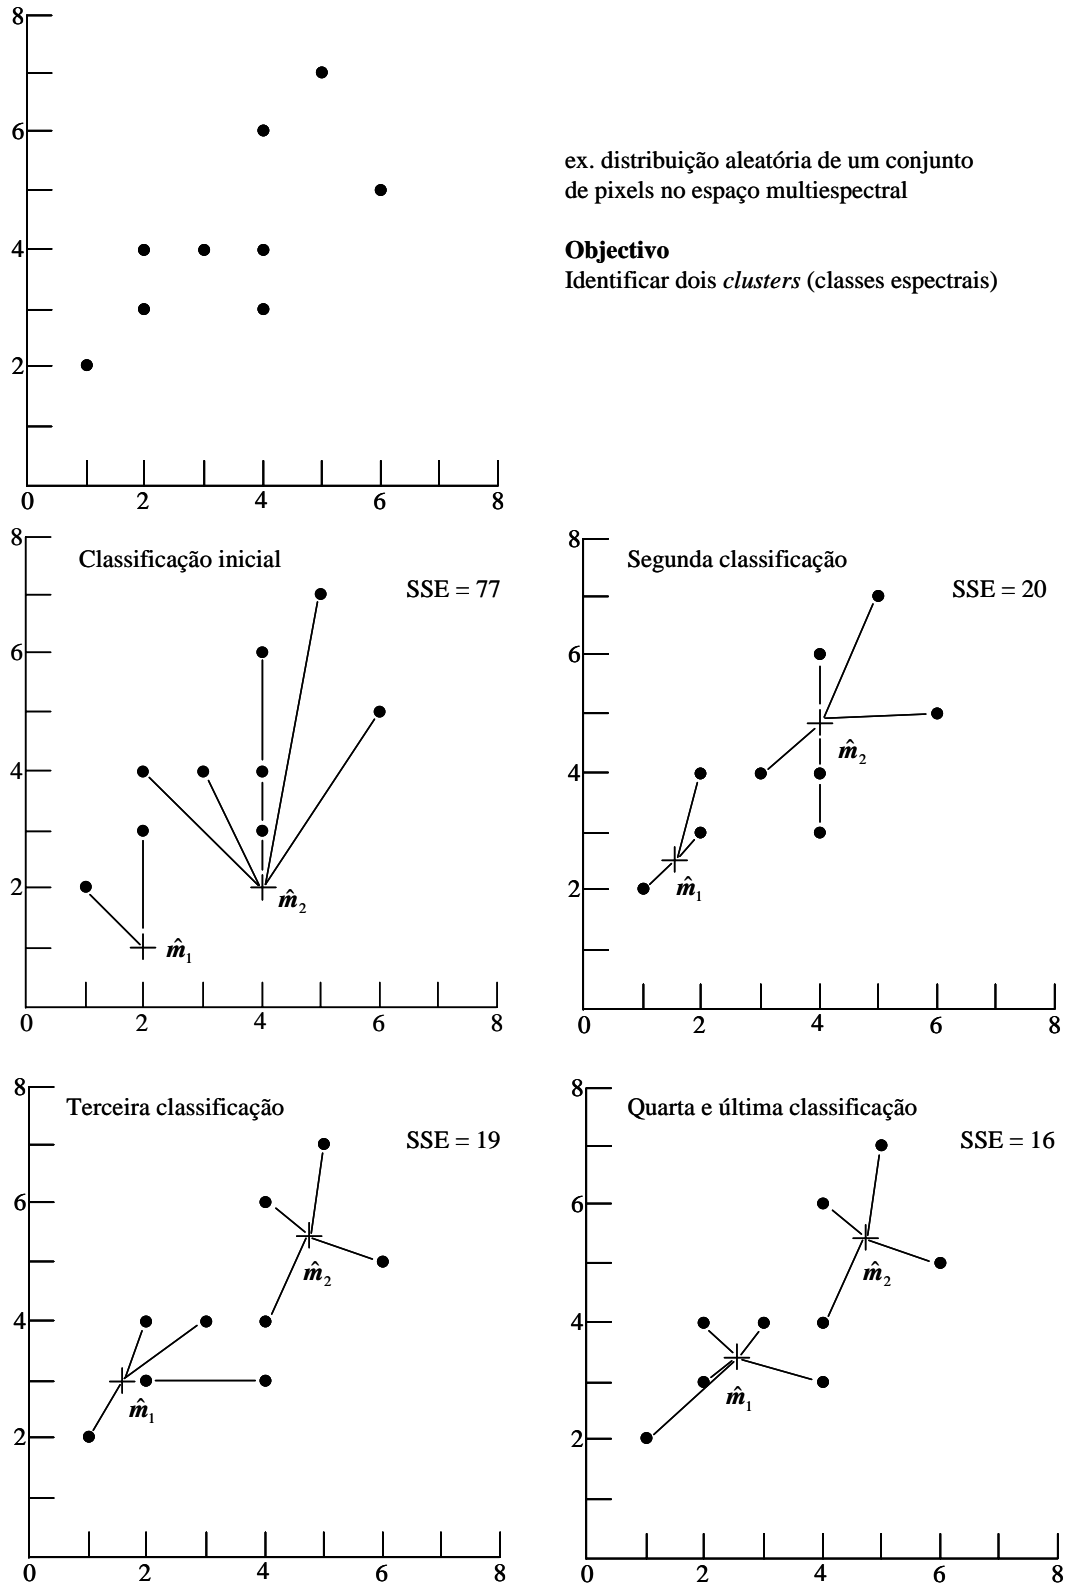


Figura 4.7 – Exemplo de funcionamento do método ISODATA

Depois de terminado o processo de criação de conjuntos homogêneos, ou em qualquer fase que se considere conveniente, os *clusters* podem ser analisados para averiguar se alguns deles contêm tão poucos pixels que possam ser desprezados (apagados), ou se estão tão próximos que

Principais Métodos de Classificação de Imagens

representam uma divisão desnecessária (ou mesmo prejudicial) dos dados e portanto devem ser agregados. Também é possível aferir se existem *clusters* demasiado alongados e dividi-los em dois. Usualmente esta operação é feita definindo, para cada classe espectral, um desvio padrão limiar para além do qual um *cluster* deva ser subdividido.

A abordagem do ISODATA é iterativa, sendo computacionalmente intensiva. Para obviar a este problema, os referidos algoritmos são muitas vezes aplicados apenas a subáreas da imagem em alternativa à cena completa. Estas subáreas são muitas vezes designadas por áreas de treino não supervisionadas e não devem ser confundidas com as áreas de treino mencionadas aquando da discussão dos classificadores supervisionados. Enquanto as áreas de treino supervisionadas estão localizadas em áreas homogéneas do ponto de vista do uso e ocupação do solo, as áreas de treino não supervisionadas são escolhidas de modo a abranger o maior leque possível de usos. Esta grande variabilidade de classes de uso permite assegurar que todas as classes da cena estão representadas na subárea. Estas subáreas são então classificadas independentemente e as classes espectrais resultantes são analisadas (determina-se a sua normalidade e separabilidade espectral) de forma a determinar a sua identidade. Depois, como seria de esperar, os *cluster* similares, representando classes idênticas de ocupação do solo são agregados. São então calculadas as estatísticas de treino para as classes agrupadas e os valores apurados vão ser utilizados para classificar toda a cena (usando um algoritmo da mínima distância ou máxima verosimilhança). Como esta abordagem envolve técnicas, quer da classificação supervisionada, quer da classificação não supervisionada, é catalogada como classificação híbrida.

Os classificadores híbridos são particularmente valiosos em análises onde está presente uma complexa variabilidade dos padrões de resposta espectral para cada uma das classes de uso e ocupação do solo. Estas situações são bastante comuns em áreas urbanas onde a poluição, as árvores, o tráfego e as sombras podem alterar as respostas espectrais de elementos que por natureza são idênticos. Nestas situações, as abordagens híbridas ajudam o analista a lidar com este tipo de variabilidade.

Outra abordagem comum à classificação não supervisionada é o uso de algoritmos que incorporam a sensibilidade à textura e rugosidade da imagem como forma de estabelecer os centros dos *clusters*. A textura é normalmente definida como a covariância observada numa janela móvel (ex. janela 3 x 3 pixels) que percorre toda a imagem. O analista fixa o limiar de variância abaixo do qual a janela é considerada suave (homogénea) e acima do qual é tida como rugosa (heterogénea). A média da primeira janela suave encontrada na imagem passa a ser o centro do primeiro *cluster*, a segunda constitui o centro do segundo *cluster* e assim sucessivamente.

Assim que o número máximo de *clusters* especificado pelo analista é alcançado, o classificador avalia as distâncias entre os centros de todos os *clusters* previamente definidos e agrega os dois mais próximos no espaço de medida. Esta operação é efectuada para toda a imagem. Os centros dos *clusters* resultantes são depois avaliados para determinar a sua separabilidade com base numa distância máxima definida pelo analista. Aqueles *clusters* que estejam separados por uma distância inferior à estipulada são fundidos e as suas estatísticas conjugadas. Os *clusters* finais, resultantes desta abordagem são também utilizados como base de uma classificação supervisionada, utilizando o classificador da mínima distância ou máxima verosimilhança.

As áreas de treino supervisionadas são por vezes utilizadas para ampliar os resultados do procedimento de agregação acima descrito, quando algumas classes de uso e ocupação do solo estão fracamente representadas na análise não supervisionada pura (outra abordagem híbrida). As estradas, por exemplo, e outros elementos lineares, podem não estar representados nas estatísticas de agregação originais, caso não preencham o critério de suavidade subjacente à janela. Para além disso, nalguns classificadores não supervisionados a ordem pela qual alguns elementos são identificados pode resultar numa fraca representação de algumas classes. Por exemplo, o número máximo de classes especificado pelo analista pode ser igualado muito antes da janela percorrer toda a imagem.

As classes obtidas através dos métodos não supervisionados são classes espectrais; como são criadas somente com base nos agrupamentos naturais dos valores dos pixels, a identidade das classes espectrais não é inicialmente conhecida. Numa fase posterior à classificação, o analista tem que confrontar a imagem resultante dos agrupamentos com algum tipo de informação de referência (imagens de maior escala ou mapas de uso e/ou ocupação do solo) para determinar a identidade das classes espectrais. Ou seja, nas classificações supervisionadas definem-se categorias de informação útil e depois analisa-se a sua separabilidade espectral; nas abordagens não supervisionadas determinam-se as classes espectralmente separáveis e depois avalia-se a sua utilidade informativa.

4.4 CLASSIFICAÇÃO SUPERVISIONADA VERSUS NÃO SUPERVISIONADA

A classificação supervisionada assume que algumas localizações das classes de ocupação do solo são conhecidas, estimando parâmetros estatísticos característicos destas classes através dos quais são classificadas as restantes localizações. No caso da classificação não supervisionada não é assumido nenhum conhecimento da superfície. Estes algoritmos (não supervisionados)

tentam identificar os grupos naturais dos dados através dos pressupostos inerentes ao método escolhido pelo operador.

Se existir um conhecimento dito suficiente da superfície então o método supervisionado é preferível pois permite uma efectiva exploração da informação [14]. Infelizmente, em muitos casos, a palavra suficiente pode ser demasiado exigente porque a informação disponível pode não ser suficiente para decidir *a priori* quais as respostas espectrais que são importantes e quais as que devem ser ignoradas (por exemplo podem existir variações espectrais dentro de uma determinada classe que podem não ser conhecidas com antecedência). Embora seja possível em áreas de extensão limitada conhecer suficientemente o universo em estudo para tomar esse tipo de decisões, tudo se torna incessantemente mais difícil para áreas de grandes proporções ($> 100 \text{ km}^2$), devido a factores como o elevado preço de recolha da informação no terreno [78]. Mais ainda, as características espectrais de uma cobertura são passíveis de alteração à medida em que a distância relativamente à classe de treino aumenta.

Como a classificação não supervisionada pretende identificar todos os *clusters* espectrais sem necessariamente conhecer no mapa final quais deles são tematicamente significativos, estes processos detêm por inerência uma vantagem sobre os métodos supervisionados, que é não ser necessário especificar previamente as classes e a sua expressão espectral. Além desta, ainda se pode apontar o facto de a independência relativamente ao operador, permitindo que diferentes analistas a trabalhar sobre a mesma área obtenham o mesmo resultado e/ou que um técnico possa obter dados consistentes sobre diferentes áreas, possibilitando estudos comparativos entre diferentes áreas ou datas.

Contudo, os métodos não supervisionados também têm desvantagens pois uma vez que tentam classificar todos os pixels em classes homogéneas, podem deixar escapar detalhes específicos mas relevantes, o que não acontece nos métodos supervisionados porque o analista conhece as classes de interesse, por mais insignificantes que elas sejam. Outro senão desta técnica é a sua dependência dos parâmetros que guiam a classificação e as inúmeras opções que o operador tem de fazer em relação a esta matéria [9] para que, através de tentativas, se optimizem os valores a considerar. Acrescem a tudo isto as carências da classificação em *cluster* que geram diversos *clusters* correspondentes à mesma classe temática, ou seja, desagregam demasiadamente a informação, dando origem a um número de classes superior ao pretendido [4, 80].

Assim, enquanto que nos métodos supervisionados se corre o risco de o utilizador influenciar o estabelecimento das classes que compõem a classificação, devido ao facto de possuir um conhecimento prévio do terreno, nos métodos não supervisionados pode originar-se uma

classificação difícil de interpretar. Para solucionar este inconveniente, é comum utilizar-se um método misto, partindo-se do conhecimento prévio do operador, para orientar o estabelecimento das classes pelo método não supervisionado ou, inversamente, utilizar o ficheiro de assinaturas espectrais resultante da classificação não dirigida para definir os parâmetros de afectação dos pixels no processo dirigido.

Recorrendo aos classificadores apresentados nos parágrafos anteriores, várias abordagens têm sido levadas a efeito para identificar, delinear e medir, de forma automática ou semi-automática, as diferentes características do espaço urbano, tendo-se chegado a resultados diversos [34]. De facto, se para os estudos que incidem sobre áreas agrícolas estes têm provado o seu valor, quando se faz a transposição para áreas construídas os resultados já não são tão satisfatórios [68].

Com efeito, as áreas urbanas englobam classes de uso espectralmente heterogéneas [6, 28], inviabilizando uma classificação (correcta) com recurso unicamente a algoritmos de classificação pixel-por-pixel, sem ter em atenção as características dos pixels vizinhos [5, 51]. A questão fulcral reside exactamente neste ponto: os algoritmos tradicionais não se adaptam às particularidades destes casos, nomeadamente à frequência espacial dos objectos, na medida em que classificam cada pixel com base unicamente nas suas características espectrais [6].

O problema fundamental ao elaborar mapas de área urbanas com grande precisão centra-se na sua especificidade, pois estas compreendem uma enorme variedade de usos, com diversas respostas espectrais. Mais, existem áreas onde coexistem diversas classes espectrais que em conjunto representam um uso e existem pixels que devido à sua dimensão correspondem a mais do que uma classe temática.

Como já foi referido anteriormente os classificadores que operam na base do *pixel* não estão adaptados para responder a estes problemas pelo que se tornou necessário enveredar por outras vias. Duas das hipóteses adiantadas foram a utilização de classificadores espaciais (contextuais) e a combinação, nos métodos clássicos, de informação espectral com informação auxiliar.

4.5 CLASSIFICAÇÃO COM RECURSO A INFORMAÇÃO AUXILIAR

Actualmente é consensual o sentimento de que a integração entre os Sistemas de Informação Geográfica (SIG) e teledeteção permite maximizar a quantidade de informação disponível e as capacidades de análise [53] possibilitando a combinação entre dados espectrais e **informação**

auxiliar [26, 56]. A informação designada como **auxiliar ou colateral** pode ser sumariamente definida como aquela que se adquire por meios não relacionados com a teledetecção, sendo aplicada na classificação de informação remota com o intuito de melhorar a capacidade analítica do classificador. O recurso a informação não espectral baseia-se no pressuposto que toda a informação adicional, recolhida de forma inteiramente independente face à fornecida pelos dispositivos orbitais, promove um incremento do potencial de discriminação de classes e, conseqüentemente, substancia a capacidade do indivíduo para levar a cabo outro tipo de análises. Esta técnica tem sido bastante utilizada sob três perspectivas diferentes:

1. Estratificação de pré-classificação, entendendo-se como a divisão hierarquizada de uma imagem em sub-regiões (figura 4.8) as quais, apesar de bem definidas na informação auxiliar, são de difícil discernimento no seio das imagens de satélite. Desta forma, é possível operar-se com áreas mais pequenas, diminuindo assim a variabilidade interna de cada classe, melhorando as probabilidades de sucesso e diminuindo o tempo de processamento.




Figura 4.8 - Processo de estratificação da informação espectral

2. Classificação, se a informação auxiliar for utilizada durante a classificação como uma banda independente [27, 28]. Como exemplo, a altimetria constitui um poderoso auxiliar na análise do coberto vegetal, dado que os padrões de distribuição espacial das espécies florestais estão intimamente correlacionados com a topografia. Apesar da sua fácil aplicação, esta técnica introduz novas bandas no processo de classificação, logo aumenta o tempo requerido para o processamento.

Outra abordagem consiste em obter as probabilidades *a priori* de um pixel pertencer a uma determinada classe, seja através do conhecimento real do terreno ou de uma determinada relação entre as classes espectrais e a informação auxiliar. Neste contexto, o classificador de *Bayes* tem sido aplicado com bastante sucesso [49, 50] na medida em que combina as potencialidades do classificador de máxima verosimilhança com o manancial de informação não espectral contido num SIG, permitindo que este último influencie as probabilidades tidas em conta pelo primeiro.

3. Discriminação de pós-classificação, através da qual os pixels mal classificados são reavaliados e agrupados em categorias de acordo com regras de decisão extraídas da informação auxiliar.

Dentro da utilização da informação auxiliar, e independentemente da perspectiva adoptada, tem ganho corpo a utilização de informação estatística proveniente, principalmente dos recenseamentos da população. Um dos primeiros passos nesse sentido foi dado com a identificação de uma correlação entre as áreas com grande densidade populacional e as áreas identificadas como “urbanas” na imagem de satélite, tendo esta linha de acção sido posteriormente desenvolvida com recurso a dados sócio-económicos [26]. No seguimento dos estudos referidos, foram desenvolvidas metodologias interessantes, nomeadamente nas áreas da detecção da rede viária, da monitorização do crescimento urbano em áreas periféricas [38, 56] e da reclassificação contextual das morfologias urbanas [6].

Entretanto, foi proposta em [82], uma metodologia interessante para integrar informação contextual e espectral sobre áreas urbanas. As unidades estatísticas designadas por *ilôts*, correspondentes às subsecções portuguesas¹ serviram para produzir uma diferenciação entre o espaço urbano e rural, ou para se ser mais preciso, “ocupado” e “não ocupado”. Esta dicotomia foi conseguida considerando como “não ocupadas” as áreas onde a informação estatística indicava que não existiam edifícios, sendo as restantes áreas, por exclusão, consideradas “não ocupadas”.

Depois de se classificar a imagem (SPOT) através de um método clássico (ISODATA), imagem resultante (classificada) é cruzada com o mapa proveniente do tratamento estatístico e a área urbana é individualizada passando, a partir daí, todas as operações a incidir apenas sobre ela. No processo que se segue os dados estatísticos são utilizados apenas para estabelecer correlações,

¹ Unidade territorial que identifica a mais pequena área homogénea, de construção ou não, existente dentro da secção estatística. Corresponde ao quarteirão nas áreas urbanas, ao lugar ou parte do lugar nas áreas rurais, ou áreas residuais que podem conter ou não alojamentos (isolados). **Secção Estatística:** Unidade territorial correspondente a uma área contínua de uma única Freguesia com cerca de 300 alojamentos destinados à habitação. **Quarteirão urbano:** Área delimitada por ruas e ocupada por edifícios, passando os seus limites pelos eixos das referidas ruas, ou quando o quarteirão só é parcialmente delimitado por ruas, a suas fronteiras deveram ser os limites de terreno estável mais próximo, ou, caso este não existe, uma linha imaginária que diste 50m das traseiras dos últimos edifícios, mas que corresponda sempre ao mesmo lugar das habitações. **Lugar:** Aglomerado populacional com 10 ou mais alojamentos destinados à habitação de pessoas e com uma designação própria, independentemente de pertencer a uma ou mais freguesias. Os seus limites, em caso de dificuldade na sua clara identificação devem ter em atenção a continuidade de construção, ou seja, os edifícios que não distem entre si mais de 200 metros. Para este efeito, não se considera a descontinuidade de construção motivada por interposição de vias de comunicação, campos de futebol, logradouros, jardins, etc.

Principais Métodos de Classificação de Imagens

como por exemplo, verificar a concordância entre a percentagem de pixels classificados como habitação de alta densidade e a quantidade efectiva de edifícios com estas características registada nas estatísticas, ou para produzir índices mistos, como o da atractividade de cada local, que é estabelecido com base no princípio de que as habitações mais próximas das zonas verdes eram as mais procuradas pelos possíveis compradores.

Em conformidade com o descrito pode considerar-se estar-se perante uma abordagem virada para a estratificação pré-processamento, dado que a única utilização real dos dados auxiliares no processo de classificação é na produção da máscara que irá individualizar as áreas urbanas de toda a envolvente.

Em 1996 foi dado um passo importante no sentido de otimizar a integração de informação auxiliar na classificação de imagens, utilizando-se o classificador de *Bayes* para conjugar dados provenientes dos Censos com imagens Landsat, com o intuito de produzir um mapa de uso do solo para a cidade de *Norwich*. As probabilidades *a priori* (tabela 4.1) foram calculadas com base nos dados estatísticos (Censos) referentes às 449 unidades estatísticas (*enumeration districts* – equivalentes às subsecções portuguesas) que compõem a cidade [50].

| | Total de alojamentos | Alojamentos isolados | Alojamentos Semi-isolados | Alojamentos térreos | Alojamentos tipo apartamento |
|--------------------------------|----------------------|----------------------|---------------------------|---------------------|------------------------------|
| Censos | 90056 | 21286 | 22795 | 27030 | 17013 |
| Probabilidades <i>a priori</i> | 1,0 | 0,4240 | 0,3027 | 0,2393 | 0,0339 |

Tabela 4.1 – Probabilidade de ocorrência das classes de espaço em *Norwich*. (Adaptado de [50])

Os valores a que chegaram (probabilidades *a priori*) permitiram, utilizando o classificador de *Bayes*, estabelecer a probabilidade *a posteriori* de um pixel pertencer a uma determinada classe, ou seja, utilizando a vertente da alteração nos classificadores. Os resultados da aplicação desta metodologia foram bastante encorajadores e encontram-se expressos na tabela 4.2.

| Tipos de Alojamentos | Censos | | Máxima Verosimilhança | | Bayes | |
|----------------------|---------------|--------|-----------------------|--------|------------|--------|
| | N (edifícios) | % | N (pixels) | % | N (pixels) | % |
| Isolados | 37364 | 42,40 | 12486 | 38,75 | 13910 | 43,17 |
| Semi-isolados | 26675 | 30,27 | 10311 | 32,00 | 9161 | 28,43 |
| Térreos | 21088 | 23,93 | 8030 | 24,92 | 7440 | 23,09 |
| Apartamentos | 2987 | 3,39 | 1395 | 4,33 | 1712 | 5,31 |
| Total | 88114 | 100,00 | 32222 | 100,00 | 32223 | 100,00 |

Tabela 4.2 – Comparação das performances dos classificadores de *Bayes* e de Máxima Verosimilhança. (Adaptado de [50])

Integração de Dados Estatísticos na Classificação de Imagens de Satélite

No entanto, apesar de existir informação estatística referenciada à subsecção (*enumeration districts*) as probabilidades *a priori* de ocorrência de cada classe de uso não foram calculadas para cada uma das unidades estatísticas, mas sim para a globalidade da cidade (tabela 4.1). Por outro lado, toda a cidade foi classificada, não tendo sido efectuada uma estratificação pré-classificação entre espaço “construído” e “não construído”, a qual poderia permitir uma melhoria nos resultados da classificação (dado que as classes a identificar correspondem na totalidade a espaços construídos).

Um dos mais recentes desenvolvimentos na integração de informação auxiliar no processo de classificação de imagens ocorreu em Portugal, no Centro Nacional de Informação Geográfica (CNIG)¹, onde em colaboração com o Instituto Nacional de estatística (INE), foi desenvolvido um projecto designado por Detecção Remota e Estatísticas Urbanas (DREU), cujo objectivo se centrava na avaliação da dinâmica da Área da Grande Lisboa nas duas últimas décadas [10]. Para tal, recorreu-se a informação espectral (SPOT) e auxiliar, sendo esta última composta por dados do Recenseamento Geral da População e da Habitação (geo-referenciados à subsecção estatística), pela rede viária e por um modelo digital do terreno (MDT).

A metodologia apresentada estende-se ao longo de três fases (figura 4.9), sendo que antes houve uma pré-fase de preparação correspondente à rectificação e geo-referenciação da imagem de satélite. Iniciando a primeira fase esteve a estratificação da área de estudo por concelho e seguidamente a classificação da imagem com o algoritmo da máxima verosimilhança [52] e com algumas aplicações pontuais de métodos contextuais [69] para tentar identificar com maior precisão aeroportos, estádios de futebol, dunas e praias. Na fase de treino do classificador foi utilizado o MDT para construir um mapa de simulação dos efeitos topográficos com o intuito de obviar a uma melhor discriminação das classes espectrais. Por fim aplicou-se uma técnica de pós-processamento ao nível do pixel optando-se por uma segmentação do tipo crescimento de regiões em detrimento dos filtros convencionais [53] e para concluir estabeleceu-se a ligação entre as classes espectrais individualizadas e os usos que efectivamente ocorrem sobre a superfície, produzindo o SATMAP.

¹ Actual Instituto Geográfico Português (IGP).

Principais Métodos de Classificação de Imagens

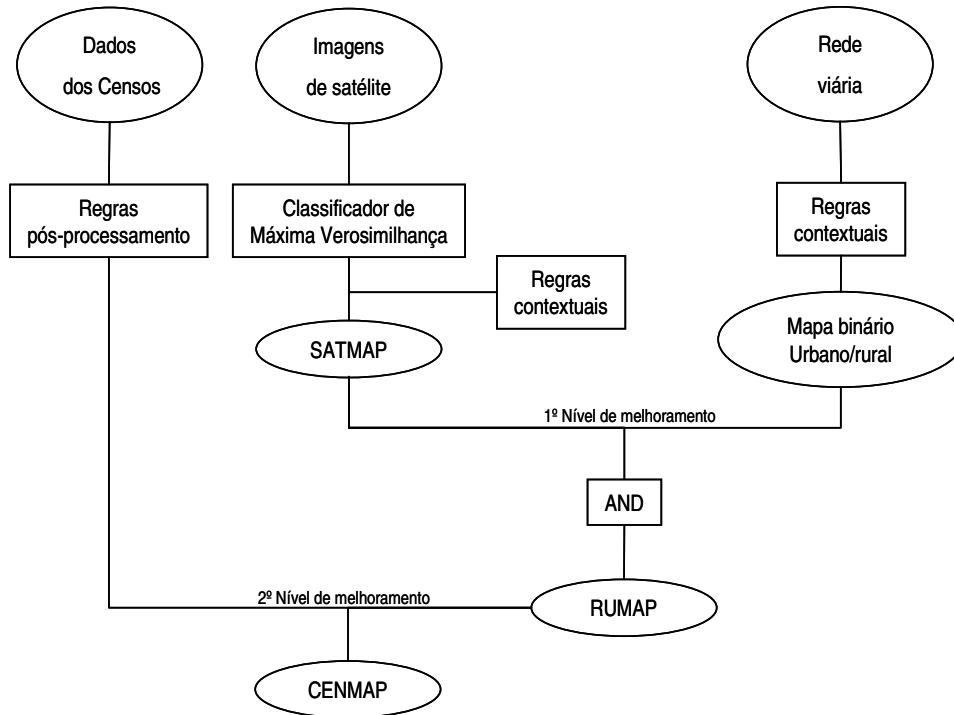


Figura 4.9 – As três fases de processamento do DREU. (Adaptado de [10])

Na segunda fase (figura 4.10) foi elaborado o mapa designado de RUMAP, através de quatro etapas:

- 1 – Estratificação da imagem em áreas urbanas e rurais utilizando a banda SPOT Pan e um algoritmo contextual de distância à rede viária (através da aplicação de um filtro passa-baixo foi criada uma mancha que se veio a verificar corresponder de um modo geral às áreas urbanizadas).
- 2 – Reclassificação das áreas urbanas e rurais utilizando um método de crescimento de regiões semelhante ao aplicado no SATMAP.
- 3 – Separação da área urbana em residencial e não residencial usando a máscara urbano/rural e o SATMAP.
- 4 – Identificação das classes de uso e ocupação do solo.

Para finalizar todo este processo integraram-se, através de regras automáticas, os dados estatísticos com o SATMAP e o RUMAP, avaliando-se depois a qualidade dos dados obtidos. Assim, muito embora tenha sido utilizada informação contextual no início (MDT) e durante (rede viária) o processo de classificação, os dados estatísticos só foram utilizados numa perspectiva de discriminação pós-classificação, ou seja, esta informação serviu para discriminar melhor algumas classes de uso urbano, zonas industriais e identificar áreas que até então não tinham sido: serviços públicos, zonas portuárias e áreas residenciais colectivas.

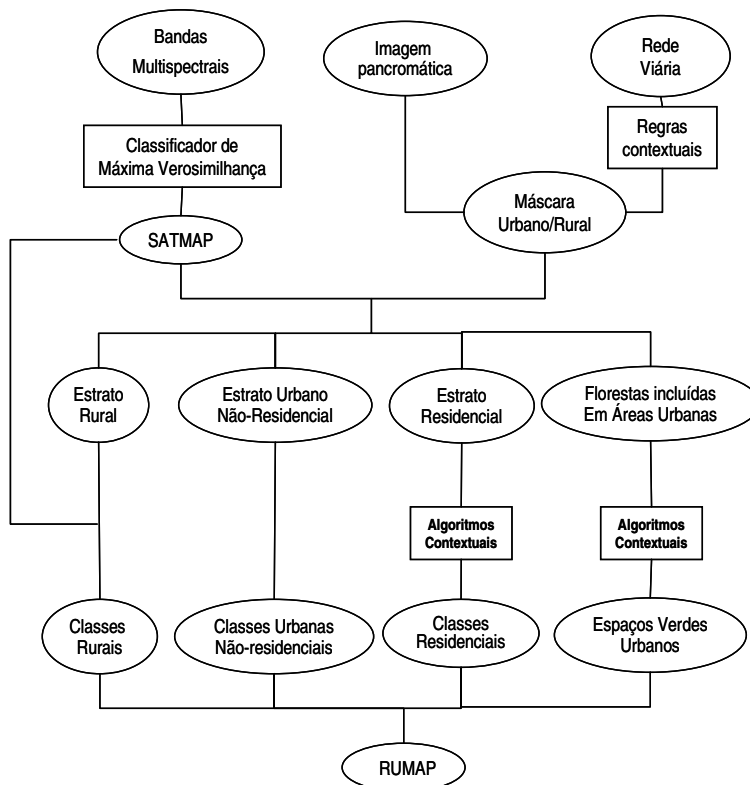


Figura 4.10 – Metodologia utilizada na produção do RUMAP. (Adaptado de [10])

Por exemplo, estas últimas, foram identificadas por apresentarem um elevado número de alojamentos por edifício residencial misturado com pixels que correspondem a uma grande quantidade de vegetação, os serviços públicos tinham um elevado número de pessoas por edifício residencial e foram consideradas como áreas portuárias as subsecções adjacentes ao mar e/ou rio que estavam classificadas como artificializadas mas que não apresentavam edifícios residenciais. São apresentados a seguir (tabela 4.3) os resultados gerais, para os três mapas produzidos:

| | Número de classes | Exactidão Global | <i>Kappa</i> |
|---------------|-------------------|------------------|--------------|
| SATMAP | 18 | 80 | 78 |
| RUMAP | 19 | 86 | 85 |
| CENMAP | 22 | 89 | 88 |

Tabela 4.3 – Exactidão dos mapas SATMAP, RUMAP e CENMAP. (Adaptado de [10])

Da análise da tabela 4.3, para além dos resultados globais da classificação – bastante positivos - sobressai o facto de à medida que a informação contextual foi sendo introduzida o resultado final foi sendo progressivamente melhor. Deste modo sai reforçada a ideia que, desde que exista informação fiável sobre a área em estudo, a classificação de imagens de satélite só tem a beneficiar com a inclusão desta informação nas diversas fases de processamento.

5

CLASSIFICAÇÃO DE IMAGENS DE SATÉLITE COM RECURSO A INFORMAÇÃO NÃO ESPECTRAL

5.1 INTRODUÇÃO

Como foi referido no capítulo anterior, é possível melhorar a qualidade da classificação de imagens de satélite através da utilização de informação auxiliar, não espectral. Neste capítulo, exploram-se as potencialidades desta vertente da teledeteção - classificação de imagens digitais obtidas por intermédio de satélites com recurso a informação dita auxiliar. O objectivo principal é elaborar uma carta de uso e ocupação do solo, que posteriormente será confrontada com resultados obtidos através de outras técnicas, de forma a aquilatar a viabilidade da metodologia desenvolvida.

O primeiro passo na persecução deste objectivo centrou-se na escolha da área teste, onde a metodologia foi aplicada. Esta deve ser bastante heterogénea relativamente aos usos, na medida em que o método proposto visa uma posterior extrapolação a toda a Área Metropolitana de Lisboa (AML, figura 5.1). Optou-se por seleccionar uma área – assinalada com a letra A na figura 5.1 - correspondente a um rectângulo com 2300 m de altura por 4000 m de largura, conduzindo a uma área um pouco superior a 9 km² o que, traduzido em termos de imagem

SPOT Pan – que apresenta a resolução espacial mais alta com que se vai operar – se materializa numa imagem com 230 linhas e 400 pixéis por linha.

Em termos geográficos, a escolha recaiu no concelho de Oeiras e, particularmente, na zona envolvente ao Estádio Nacional (figura 5.2). Muito embora possa ser considerado um concelho urbano, Oeiras ainda se encontra sobre a influência centralizadora de Lisboa constituindo uma periferia desta, embora com bons padrões de qualidade habitacional e uma economia cada vez mais independente. Este estatuto permite-lhe apresentar uma variedade de usos que já não é possível encontrar na capital, onde o tecido urbano já está praticamente todo consolidado.

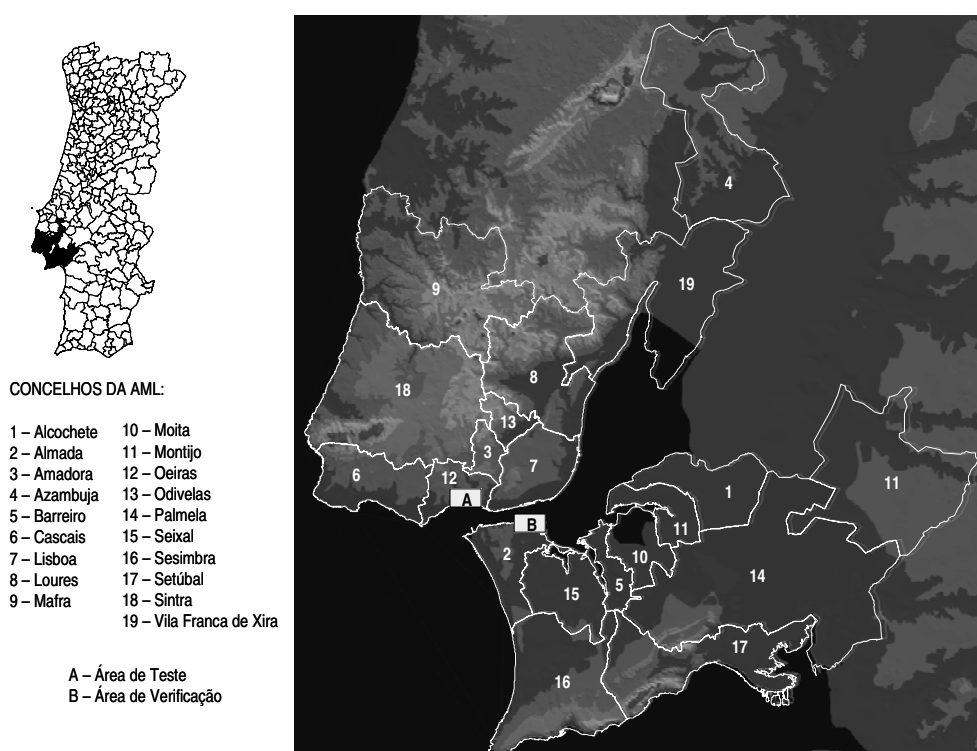


Figura 5.1 – Enquadramento das áreas de teste (A) e de verificação (B)

Com efeito, no município de Oeiras ainda se fazem sentir os efeitos da periurbanização, assistindo-se a uma confluência de espaços florestais, agrícolas, expectantes (livres), industriais, comerciais e habitacionais, uni e plurifamiliares (figura 5.2), com alguns focos (cada vez menos) de clandestinos. Felizmente, foi possível encontrar uma área onde existiam todas estas variáveis, o que conduziu de imediato à sua escolha como área de teste. Foi ainda escolhida uma segunda área, para funcionar como verificação, ou seja, para constatar se a metodologia proposta não seria demasiado adaptada à área teste, o que teria graves implicações na sua aplicação ao nível da AML. A escolha incidiu sobre uma área de iguais dimensões, mas na margem Sul, no concelho de Almada, que detém algumas similitudes com Oeiras (clandestinos

e fenómeno da periurbanização) mas é, ao mesmo tempo, suficientemente distinta desta para poder ser utilizada na validação do método.



Figura 5.2 – Perspectiva aérea da área de estudo (exageração vertical 3x), com destaque para as zonas de habitação unifamiliar (A) e plurifamiliar (B)

Por último (mas não de menos importância) delineou-se a metodologia a seguir – e que se encontra esquematizada na figura 5.3 - tendo em atenção toda a base teórica apresentada nos capítulos anteriores, e prosseguindo uma linha de trabalho onde têm vindo a ser feitas algumas experiências no campo da integração SIG-teledetecção [74 - 77]. Os passos representados no esquema da figura 5.3 correspondem, de uma forma genérica, às secções constituintes deste capítulo.

Na secção 5.2, descreve-se a informação a utilizar e justificam-se as razões que estiveram na base da sua escolha. Na secção 5.3, especificam-se todos os passos que foram dados no sentido de preparar a informação utilizada de modo a que esta seja compatível entre si. Na secção 5.4, expõe-se a metodologia de classificação proposta, a qual é constituída por três etapas fundamentais: estratificação de pré-classificação; utilização de classificadores de Máxima Verosimilhança (MV) e de *Bayes*; aplicação de regras de pós-processamento. Por fim, na secção 5.5, verifica-se a exactidão dos resultados obtidos na área de teste, comparando-os com a realidade e aplica-se a metodologia proposta à área de verificação, para se comprovar que não existe uma adaptação (por parte do método desenvolvido) demasiado grande à área de teste.

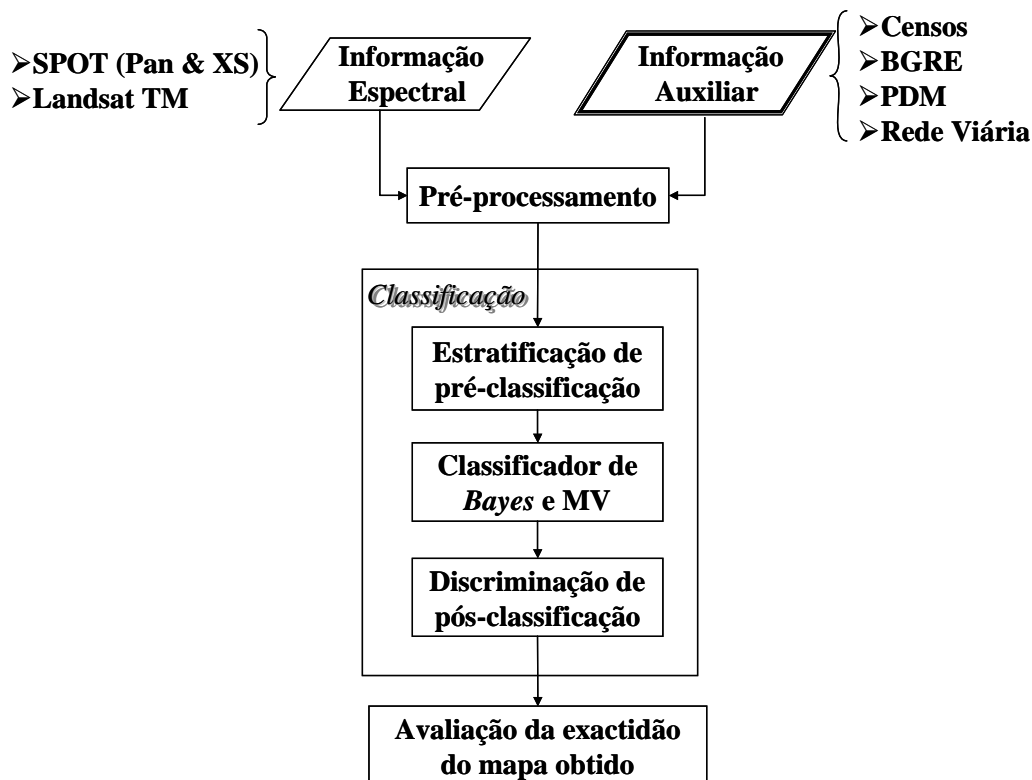


Figura 5.3 – Esquema da metodologia desenvolvida para a classificação de imagens de satélite

5.2 SELECÇÃO DA INFORMAÇÃO

Para se atingirem os objectivos propostos, recorreu-se a várias fontes de informação que se podem dividir em dois grande grupos: o da informação auxiliar e o das imagens provenientes de sensores orbitais. No primeiro caso, utilizou-se a informação disponibilizada pela Carta de Ordenamento (ratificada em 1994) do Plano Director Municipal (PDM), pela rede viária (1998), e pelo Instituto Nacional de Estatística (INE), esta discriminada à subsecção estatística (definida na secção 4.5) e correspondente ao Recenseamento Geral da População de 1991. Esta última, assume também duas identidades, que consequentemente requerem abordagens distintas. Por um lado, existe a vertente vectorial, materializada na Base Geográfica de Referenciação Espacial (BGRE) e que corresponde à delimitação espacial das subsecções estatísticas; por outro, a informação estatística propriamente dita, referente a cada uma das subsecções, que se divide em quatro grandes subgrupos: “Famílias”, “Alojamentos”, “Indivíduos” e “Edifícios”. Destes dados estatísticos, eliminou-se desde logo o primeiro subgrupo (“Famílias”), pelo facto de não conter qualquer informação relevante para o trabalho em curso. Das restantes, retiveram-se apenas os campos considerados como fundamentais na persecução dos objectivos propostos, e que se apresentam na tabela 5.1.

| CAMPOS | SIGNIFICADO |
|---|--|
| Número de Alojamentos Familiares | Todos os alojamentos que albergam pelo menos uma família |
| Número de Alojamentos Clássicos | Alojamentos integrados em edifícios clássicos. |
| Número de Alojamentos Colectivos | Hotéis e similares, lares de terceira idade, conventos, hospitais, prisões, etc. |
| Número de Indivíduos Residentes | Todos os indivíduos que habitam na subsecção (estivessem ou não presentes no momento do recenseamento) |
| Total de Edifícios (clássicos) | Número total de edifícios cuja estrutura e materiais empregues são de natureza não precária (duração prevista de pelo menos 10 anos) |
| Edifícios por data de construção | Número de edifícios por ano de construção |
| Edifícios por Número de Pavimentos | Número de edifícios por número de Pavimentos |
| Edifícios Exclusivamente Residenciais | Número de edifícios destinados exclusivamente a habitação |
| Edifícios Principalmente Residenciais | Número de edifícios destinados principalmente a habitação |
| Edifícios Principalmente não Residenciais | Número de edifícios destinados principalmente a actividades que não a habitação |

Tabela 5.1 – Informação estatística referenciada à subsecção e seleccionada em primeira instância

A utilização da rede viária como informação auxiliar deve-se a esta já existir em formato vectorial, tornando-se desnecessário recorrer às imagens de satélite para extrair uma informação já disponível e que podia ser inserida na classificação final com uma exactidão de 100%. Para além disso, a inclusão da rede viária permite eliminar do processo de classificação a classe “rede viária” que tem grandes semelhanças (valores radiométricos semelhantes) com a habitação plurifamiliar e que, ao ser retirada, permite classificar com melhor exactidão esta última. Relativamente ao PDM, este foi seleccionado porque, muito embora as classes de ordenamento que nele estão representadas sejam predominantemente indicadoras dos usos de solo permitidos, também existem classes que representam os usos existentes na altura da elaboração do plano, permitindo a elaboração de regras de pós-classificação, com o objectivo de melhorar o resultado da classificação.

Relativamente aos dados espectrais, optou-se por utilizar todas as bandas SPOT (uma pancromática e três multiespectrais) e Landsat TM (com excepção da banda 6 que foi excluída devido à sua fraca resolução espacial), obtidas nos Verões de 1995 e 1997, respectivamente. Esta opção deve-se ao facto de se pretender juntar a melhor resolução espacial das imagens SPOT, com a maior resolução espectral das imagens Landsat. Na grande maioria dos estudos até agora desenvolvidos, é usual utilizar-se apenas as bandas Landsat TM em conjugação com a SPOT Pan, visto que as bandas SPOT XS não fornecem uma mais valia, em termos espectrais relativamente às bandas Landsat TM (estas últimas têm uma maior abrangência espectral).

Neste estudo optou-se por utilizar as bandas SPOT XS essencialmente por estas fornecerem informação espectral razoável com uma resolução espacial superior às bandas Landsat TM.

Para terminar, resta referir que foram ainda utilizados um ortofotomapa à escala 1:10 000 e a Carta de Uso e Ocupação do Solo da AML (projecto CartusAML). Esta informação, em formato matricial e vectorial, respectivamente, serviu para: *i*) no caso do ortofotomapa, corrigir a BGRE e georreferenciar as imagens de satélite; *ii*) no caso da Carta de Uso e Ocupação do Solo da AML, validar os resultados obtidos pelos algoritmos de classificação (de imagens de satélite) testados no decorrer desta dissertação. Findo este reparo, esquematizou-se a informação em dois grandes grupos, tal como se pode observar na figura 5.4.

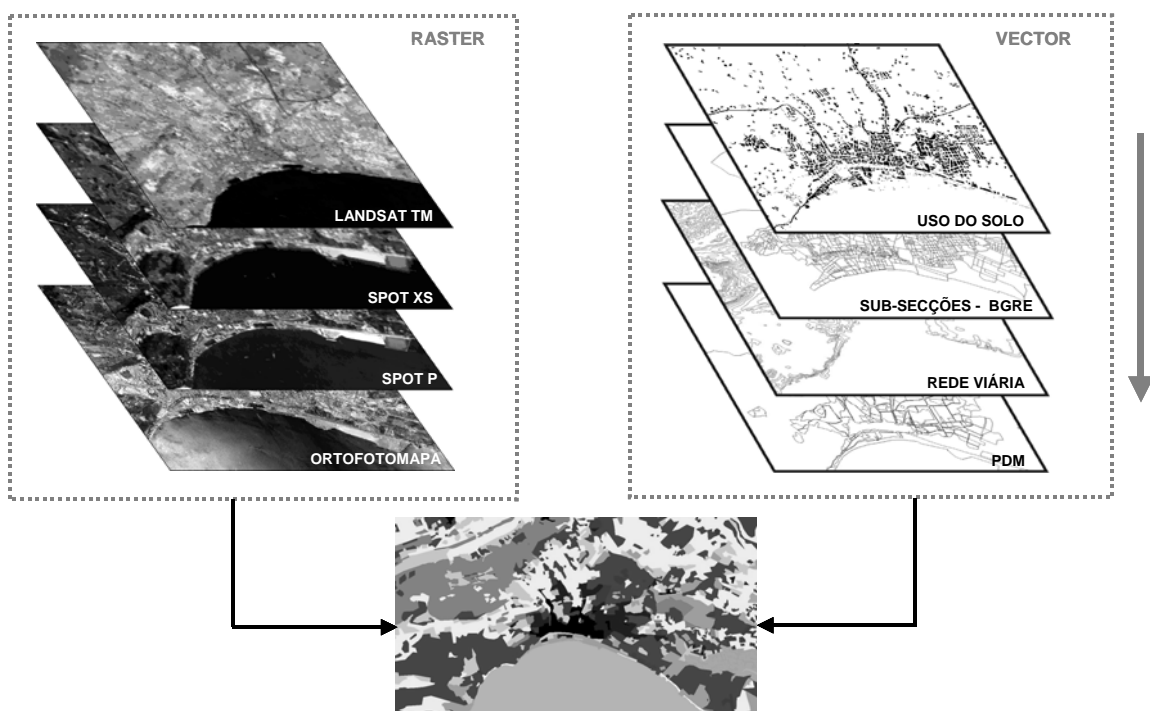


Figura 5.4 – Integração da informação matricial e vectorial

5.3 PRÉ-PROCESSAMENTO DA INFORMAÇÃO

5.3.1 Melhoramento da Informação Espectral e Auxiliar

Antes de se iniciar o processo de extracção de informação útil a partir de dados espectrais e auxiliares, é necessário corrigir esses dados de erros decorrentes do processo de aquisição e “optimizá-los” tendo em vista a sua utilização por um utilizador humano. Nesta secção, descrevem-se as técnicas de correcção/melhoramento aplicadas aos dados utilizados no método em estudo:

- melhoria do contraste de imagens de satélite;
- georreferenciação das imagens de satélite;
- correcção da BGRE.

a) Melhoria do contraste das imagens de satélite

O primeiro passo no tratamento dos dados espectrais foi a alteração do contraste das imagens de satélite. De facto, os sistemas informáticos que operam com imagens funcionam, geralmente, com base em ficheiros com uma extensão de 256 níveis de cinzento (0 a 255), correspondentes à amplitude máxima de valores representados num ficheiro de 8 bits. No entanto, é raro uma imagem abranger todos os níveis de radiância capazes de serem detectados pelo sensor, uma vez que dificilmente capta paisagens muito variadas do ponto de vista espectral. Os níveis digitais ocupam, assim, uma pequena parte do intervalo compreendido entre 0 e 255 (figura 5.5), originando um contraste pouco perceptível entre tipos de ocupação distintos. Uma vez que as técnicas de classificação utilizadas na metodologia desenvolvida requerem, em algumas das etapas, a intervenção de um operador humano, é necessário melhorar a interpretabilidade das imagens. Assim, o objectivo da alteração do contraste é expandir o conjunto de valores de brilho presentes na imagem por um conjunto de valores de cinzento mais vasto. O resultado é uma nova imagem onde o contraste entre os elementos de interesse para o analista é superior ao da imagem inicial.




Figura 5.5 – Banda SPOT Pan e respectivo histograma

Na chamada **expansão linear do contraste**, o conjunto de valores digitais da imagem inicial é uniformemente expandido, de forma a preencher toda a gama de valores da imagem de saída (figura 5.6). Depois de realizada esta operação, as variações, mesmo subtis, dos valores da imagem inicial, serão ampliadas na imagem de saída e, portanto, serão mais facilmente identificados visualmente pelo operador. Com esta operação, as áreas de tom claro ficam claras e as de tom escuro ficam mais escuras. A expansão linear do contraste faz corresponder o menor

nível radiométrico da imagem a 0, e o maior a 255, sendo os outros distribuídos de forma linear pelo intervalo entre estes valores extremos, através da expressão:

$$NR' = \frac{NR - MIN}{MAX - MIN} \times 255, \quad (5.1)$$

em que

NR' - nível radiométrico na imagem final;

NR - nível radiométrico na imagem inicial;

MIN - nível radiométrico mínimo da imagem inicial;

MAX - nível radiométrico máximo da imagem inicial.




Figura 5.6 – Banda SPOT Pan após a expansão linear do contraste e respectivo histograma

Uma variante, muito utilizada, desta técnica de melhoramento do contraste é a **expansão linear do contraste com saturação**. Este processo força um conjunto de valores extremos da imagem inicial a adquirir o mesmo valor na imagem de saída (figura 5.7). Com a expansão linear do contraste com saturação, é possível obrigar uma percentagem específica dos pixels a adquirirem os valores extremos (0 e 255). Geralmente, uma saturação 2,5% a 5% resulta bastante bem em termos de contraste da imagem.

Uma desvantagem da expansão linear do contraste é o facto deste processo atribuir o mesmo número de níveis de visualização tanto aos valores digitais de rara ocorrência na imagem como aos mais frequentes. Para resolver este problema, recorre-se frequentemente à **equalização do histograma**. Nesta abordagem, os valores da imagem são atribuídos aos níveis de visualização, com base na sua frequência de ocorrência, com o objectivo de atingir um histograma o mais uniforme possível (figura 5.8). Em casos onde se afigura difícil obter uma boa visualização da imagem, este processo revela-se como uma opção bastante válida.




Figura 5.7 – Banda SPOT Pan após expansão linear do contraste com saturação a 5% e respectivo histograma




Figura 5.8 – Banda SPOT Pan após equalização do histograma e respectivo histograma

Em casos especiais, alguns elementos específicos podem ser analisados num maior detalhe radiométrico, atribuindo-se para o efeito, toda a amplitude dos valores de saída exclusivamente a um determinado conjunto de valores da imagem inicial. Como exemplo, a banda TM4 do satélite Landsat apresenta um histograma bimodal (figura 5.9), correspondendo os valores concentrados à esquerda às zonas de água. Sendo estas zonas relativamente fáceis de identificar, pode proceder-se à alteração do contraste, tendo em atenção apenas a restante gama de valores.




Figura 5.9 – Banda Landsat TM4 e respectivo histograma

Face ao anteriormente exposto, e em virtude de o método da expansão linear do contraste com saturação ser unanimemente considerado como aquele que melhores resultados obtém, optou-se por aplicar esta técnica de alteração do contraste a todas as bandas espectrais.

b) Georreferenciação das imagens de satélite

A segunda etapa corresponde à **georreferenciação** das imagens de satélite, relativamente à base cartográfica, processo denominado “**correção geométrica**”. Esta operação revela-se necessária porque as imagens digitais “brutas” apresentam geralmente distorções geométricas tão significativas que impedem a sua utilização como mapas. Com efeito, ao ser adquirida, uma imagem vai originar um ficheiro digital adimensional e “com erros de perspectiva”. Para que se possa trabalhar e explorar a informação contida na imagem, nomeadamente extrair elementos, medir distâncias, áreas, etc., é necessário proceder à sua correção geométrica.

A georreferenciação pode ser realizada de duas formas: **rectificação imagem-mapa** ou **registo imagem-imagem**. No primeiro caso, a geometria da imagem é tornada planimétrica. Sempre que se necessita de medir com exactidão área, perímetros e distâncias, deve utilizar-se este método¹. Quanto ao segundo método, o registo imagem-imagem, pode ser definido como o processo de alinhamento por translação e rotação, através do qual duas imagens de geometria similar e da mesma área geográfica são posicionadas de forma coincidente relativamente uma à outra, de forma a que a mesma área de terreno apareça representada na mesma posição em todas as imagens registadas. Ambos os processos envolvem, normalmente, a selecção de pontos de controlo na imagem (que será a imagem de referência no segundo caso), a identificação das suas coordenadas pixel (linha e coluna) e, posteriormente, a identificação das coordenadas correspondentes no mapa (primeiro caso) ou na outra imagem (segundo caso).

O registo imagem-imagem é utilizado quando, por exemplo, se pretende comparar duas imagens obtidas em diferentes datas e avaliar as alterações de uso do solo que ocorreram. Muito embora seja possível rectificar as duas imagens relativamente a um mesmo sistema de projecção cartográfica e analisá-las posteriormente (o que é muitas vezes feito), tal operação não é necessária se o objectivo for simplesmente identificar as diferenças entre elas.

Os mesmos princípios gerais de processamento de imagem encontram-se na base quer do registo, quer da rectificação. A única diferença reside no facto de, no primeiro caso, a base de

¹ No entanto, pode não ser possível remover toda a distorção provocada pelos acidentes naturais do terreno.

referência ser outra imagem e, no segundo, um mapa elaborado segundo uma determinada projecção cartográfica. Daqui se conclui que, se uma imagem é utilizada como base de referência (ao invés de um mapa), qualquer imagem registada sobre ela irá herdar os erros geométricos existentes na imagem de referência. Devido a estas características, a maior parte das aplicações em teledeteção faz uso de imagens rectificadas relativamente a um mapa de referência. Contudo, quando se pretende efectuar uma análise das alterações de uso e ocupação do solo, ou cruzar informação espectral proveniente de diferentes sensores, utiliza-se frequentemente uma abordagem híbrida, que conjuga os dois métodos que têm vindo a ser descritos.

No contexto do presente trabalho, optou-se por uma abordagem híbrida, utilizando-se como referência uma imagem, mas que se encontrava georreferenciada segundo o sistema de projecção Gauss-Kruger (Transversa de Mercator). Esta decisão assentou principalmente em três factores:

1. Elementos como limites de zonas de água e terrenos ou a intersecção de pequenos ribeiros não se encontram representados nos mapas, mas podem ser fáceis de identificar nas imagens;
2. Existia uma imagem com uma escala equivalente a 1:10 000, enquanto que o mapa de maior escala era de 1:25 000, apresentando portanto um nível de detalhe bastante inferior;
3. A imagem à escala 1:10 000 é um ortofotomapa, onde foram corrigidos os erros introduzidos pelos acidentes naturais do terreno.

Tendo em atenção estes três aspectos, deu-se o primeiro passo necessário à correcção geométrica, que consiste na selecção de um suporte de referência adequado. Considerando que havia todo o interesse em que a base de referência fosse uma imagem com resolução espacial igual ou superior à das imagens a registar, e para evitar que as imagens registadas adquirissem, conforme já foi referido, os erros geométricos da imagem de base, optou-se por referenciar todas as imagens relativamente ao ortofotomapa (embora esta opção ponha outros problemas, como a identificação dos pontos de controlo). Com efeito, se entre o ortofotomapa (resolução espacial de 0,5 m) e a banda SPOT Pan (resolução espacial de 10 m) existem evidentes analogias visuais, o mesmo já não acontece em relação às bandas SPOT XS (resolução espacial de 20 m) e Landsat TM (resolução espacial de 30 m).

Integração de Dados Estatísticos na Classificação de Imagens de Satélite

A correcção geométrica de imagens envolve o relacionamento das coordenadas espaciais de um ponto da imagem (as coordenadas em termos de linha e coluna (i, j) de um pixel) com as coordenadas espaciais correspondentes na superfície terrestre (x, y) .

A relação entre as coordenadas de um pixel na imagem e o ponto correspondente na superfície terrestre pode ser expressa por intermédio de uma transformação geométrica, como:

$$\begin{aligned}i &= f(x, y) \\j &= g(x, y)\end{aligned}\tag{5.2}$$

onde (i, j) são as coordenadas de um ponto na imagem original, (x, y) são as coordenadas do ponto correspondente na superfície e (f, g) são as funções que descrevem a transformação geométrica. As funções f e g dependem do tipo de relação que se assume existir entre as coordenadas na imagem e na superfície. Como a sua forma explícita não é conhecida, tomam normalmente a forma de polinómios do primeiro, segundo ou terceiro grau. Nas situações mais simples, pode-se assumir que estas funções (f e g) se aplicam de forma homogénea a toda a imagem. Em casos com maior distorção geométrica, pode ser necessário calcular f e g localmente. Geralmente, para distorções moderadas e numa área relativamente pequena de uma imagem (por exemplo um quarto de uma imagem Landsat TM), uma **transformação linear (Afim)** de primeira ordem é suficiente para corrigir, do ponto de vista geométrico, a imagem.

Esta transformação, que foi a utilizada para georreferenciar todas as imagens que serviram de base ao estudo presente na tese, pode corrigir um vasto conjunto de distorções, incluindo translações, mudanças de escala, rotações e obliquidade, sendo formalmente descrita por:

$$\begin{aligned}i &= a_0 + a_1x + a_2y \\j &= b_0 + b_1x + b_2y\end{aligned}\tag{5.3}$$

Se os coeficientes a_i e b_i ($i = 0, 1, 2$) forem conhecidos, pode-se utilizar a expressão (5.3) para relacionar qualquer ponto da referência cartográfica com o seu correspondente na imagem de satélite. No entanto, na maioria dos casos, o analista desconhece o valor dos coeficientes, sendo necessário estimá-los com o recurso a um conjunto de pares de pontos correspondentes, ou pontos de controlo, definidos na imagem a corrigir e na base cartográfica (ortofotomapa). Estes pontos devem ser espacialmente bem definidos, correspondendo muitas vezes a cruzamentos de estradas, afluentes e efluentes de rios, limites costeiros bem definidos (costas rochosas) e pistas de aviação, entre outros.

Classificação de Imagens com Recurso a Informação não Espectral

O número de pontos escolhidos deve ser suficiente para que os coeficientes do polinómio sejam estimados (cada ponto fornece informação sobre a sua posição em x e em y). Para um polinómio de primeira ordem são necessários, no mínimo, três pontos. Num polinómio de segundo grau seriam necessários seis pares de pontos e, num de terceiro grau, dez pares. Na prática, é escolhido um número significativamente maior de pontos (uma regra bastante utilizada é a de identificar dez vezes mais pontos que o mínimo requerido) e os coeficientes são estimados com recurso ao método dos mínimos quadrados. Desta forma, um hipotético ponto de controlo que possua um erro posicional significativo, quer na imagem quer na base cartográfica, terá pouco impacto na qualidade dos coeficientes e consequentemente da georreferenciação.

Utilizando-se os seis coeficientes expressos em 5.3 é possível transferir (relocalizar) os valores de pixel de uma imagem (distorcida) original (x', y') para a grelha de uma imagem final rectificada (x, y) :

$$\begin{aligned}x' &= f(x, y) \\y' &= g(x, y)\end{aligned}\tag{5.4}$$

onde (x', y') são as coordenadas da imagem original, e (x, y) as coordenadas da imagem georreferenciada.

Idealmente, x' seria igual a x e y' a y , mas esta situação raramente se verifica. Qualquer discrepância entre estes dois conjuntos de valores indica a persistência de distorções geométricas na imagem, mesmo depois do processo de georreferenciação. Uma forma de medir estas distorções é calcular o Desvio Quadrático (DQ) para cada ponto de controlo, através da expressão:

$$DQ = \sqrt{(x'-x)^2 + (y'-y)^2}\tag{5.5}$$

Calculando-se o DQ para todos os pontos de controlo é possível observar qual o ponto com maior erro e/ou calcular o Desvio Quadrático Médio (DQM). Normalmente, o analista especifica um certo valor (limiar) de DQM aceitável. Se este valor for ultrapassado é comum: *i*) apagar o ponto de controlo com maior erro; *ii*) recalculer os coeficientes; *iii*) recalculer o DQ para os restantes pontos de controlo. Este processo repete-se até que o DQM seja igual ou inferior ao limiar especificado. Assim que é atingido um valor aceitável de DQM pode-se passar à fase seguinte que tem por objectivo preencher uma imagem final (x, y) com níveis radiométricos encontrados na imagem original (x', y') .

Se as coordenadas (x', y') coincidirem com as coordenadas pixel originais (x' e y' são números inteiros), os valores originais dos pixels nessa posição são automaticamente transferidos para a posição (x, y) correspondente na imagem corrigida (figura 5.10-a). Caso contrário (x' e y' são fracionários), é necessário interpolar o valor do pixel a colocar na posição (x, y) a partir dos pixels originais vizinhos da posição (x', y') (figura 5.10-b). Neste trabalho utilizou-se, como método de interpolação a técnica do **vizinho mais próximo** (ou interpolação de ordem zero)¹.




Figura 5.10 – Transposição, da imagem inicial para a imagem rectificadora, de pixels com coordenadas centrais inteiras (a) e decimais (b)

O método do vizinho mais próximo, é o processo de interpolação mais simples e mais rápido, em virtude de utilizar apenas o valor do pixel da imagem original com coordenadas (i, j) mais próximas das coordenadas obtidas pela transformação (x', y') (figura 5.11). Este pixel é depois transferido para a sua posição correspondente na imagem final (georreferenciada). Esta técnica é a ideal quando a imagem georreferenciada se destina a posterior classificação, pois preserva os valores radiométricos da imagem original, redistribuindo apenas a sua posição, de modo a fornecer uma imagem geometricamente correcta. A desvantagem desta técnica é a produção de falsas discontinuidades (“degraus”) sobre os contornos da imagem final.

¹ No anexo 3 descrevem-se outras técnicas usuais para a interpolação de imagens.

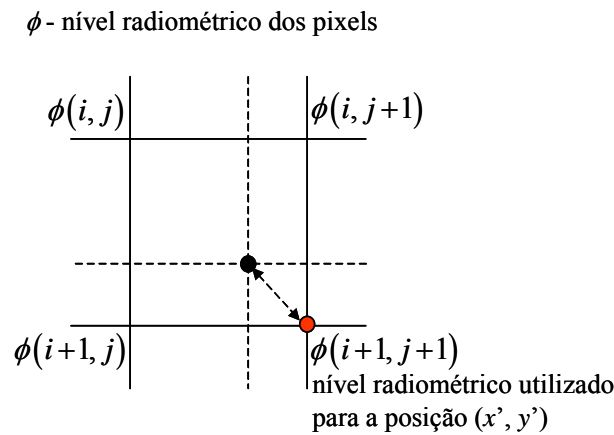


Figura 5.11 – Interpolação do valor do pixel pelo método do vizinho mais próximo

Resta referir que, aquando do processo de reamostragem, foi requerido que o tamanho do pixel fosse redimensionado, para que todas as imagens ficassem com a mesma resolução espacial (10 m), viabilizando assim operações com os dados provenientes das duas plataformas orbitais (Landsat e SPOT).

Assim sendo, começou-se por georreferenciar a imagem SPOT pancromática, na medida em que esta é a que apresenta uma maior resolução espacial (10 m), sendo este processo realizado com a ajuda de um ortofotomapa de 1998. Terminada a georreferenciação, o DQM não deve ser superior a 5 m, ou seja, o equivalente a metade de um pixel da imagem em questão. O processo foi depois repetido para as imagens SPOT XS (10 metros de erro máximo) e Landsat TM (15 metros de erro máximo), verificando-se que, para estas últimas, o erro foi um pouco superior ao máximo estabelecido, em virtude da sua resolução espacial (30 m) condicionar fortemente a identificação de correspondências na imagem de referência (ortofotomapa). Na tabela 5.2, apresentam-se o número de pontos de controlo utilizados para as várias operações de georreferenciação, bem como o erro médio de cada uma destas operações e o erro máximo encontrado.

| IMAGENS | Número de Pontos de Controlo | DQM máximo ideal | DQM (m) | DQ Máximo |
|------------|------------------------------|------------------|---------|-----------|
| SPOT Pan | 34 | 5 | 2,249 | 2,3 |
| SPOT XS | 18 | 10 | 5,850 | 9 |
| Landsat TM | 9 | 15 | 19,220 | 20 |

Tabela 5.2 – Parâmetros do processo de geo referenciação

c) Correção da BGRE

Antes de se avançar com qualquer procedimento relativamente à dados estatísticos, foi necessário preparar a sua base gráfica (BGRE), que apresentava alguns problemas de exactidão

posicional, devido a um processo de digitalização (mesa digitalizadora) pouco preciso, que actualmente se encontra já em desuso. Neste processo, corrigiu-se a BGRE sobre um ortofotomapa, deslocando os limites das subsecções para os locais onde eles realmente pertencem (figura 5.12). De notar que, na altura da elaboração da BGRE, a opção tomada pelo INE era a mais avançada e foi o desenvolvimento tecnológico e o consequente aumento das exigências em termos de qualidade que o tornou preterido face a outros. Contudo, a nova base geográfica que servirá de suporte aos Censos 2001 já foi elaborada segundo os métodos mais avançados, nomeadamente digitalização no computador sobre ortofotomapas.




Figura 5.12 – Correção da base de georeferenciação espacial do INE: (a) ortofotomapa correspondente à área de estudo com a BGRE sobreposta; (b) ampliação de uma área urbana mostrando a BGRE original ; (c) ampliação de uma área urbana mostrando a BGRE corrigida

Como se pode constatar pela figura 5.12, existem diversas incoerências no mapa disponibilizado ao público pelo INE, existindo mesmo subsecções que estendem o seu raio de acção pelo rio Tejo. Contudo, os problemas com a BGRE não terminaram com a eliminação destes pontos de fricção, já que também ao nível dos dados alfanuméricos se verificaram alguns problemas,

constatando-se que existiam registos na base gráfica sem correspondência alfanumérica, e vice-versa. Mais tarde, veio a verificar-se que, no primeiro caso, se tratavam de subsecções que estavam abrangidas pelo segredo estatístico e que portanto não tinham informação referenciada ou, para a segunda situação, simplesmente não tinham sido digitalizadas. Todos estes pormenores tiveram que ser regularizados através de processos de correcção e edição, tendo por base tecnologia SIG de procedência *Intergraph*. Deste modo, como as subsecções que estavam abrangidas pelo segredo estatístico correspondiam a áreas bastante extensas (subsecções não urbanas) e com uma ou duas famílias residentes (no máximo) foram consideradas como inabitadas, por outro lado, as subsecções que não tinham sido digitalizadas foram introduzidas na BGRE no âmbito deste trabalho e de um protocolo entre a AML e os municípios que a constituem.

5.3.2 Processamento da Informação Auxiliar

Corrigida a BGRE, realizaram-se todas as operações relacionadas com o tratamento estatístico da informação auxiliar (figura 5.13), nomeadamente: criação de um mapa binário que permitiu diferenciar em todas as imagens, os pixéis “água” e “não água” (*masc_h2o*); definição de um primeiro mapa binário traduzindo os usos “urbano” e “não urbano” (*urb_1*); cálculo das probabilidades de ocorrência *a priori* das classes urbanas; criação de uma banda urbana contextual, a introduzir na etapa de classificação propriamente dita.

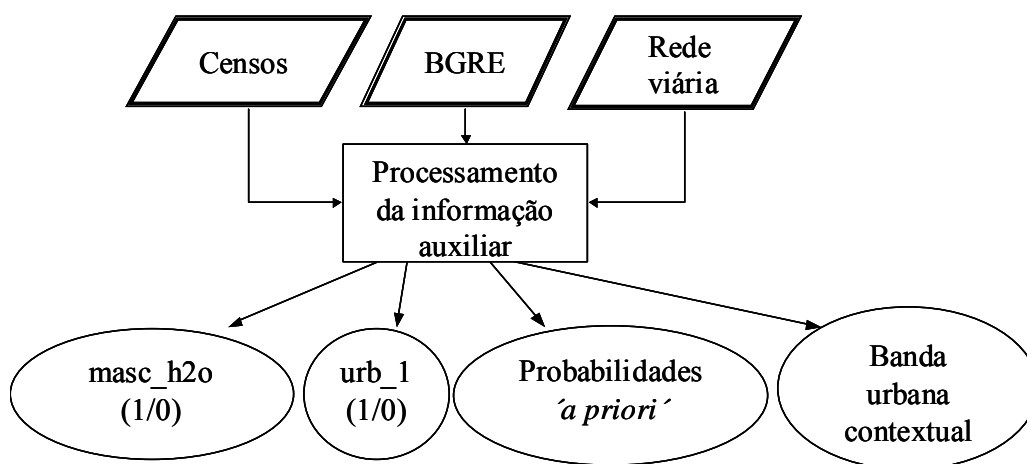


Figura 5.13 – Informação de entrada e saída correspondente ao processamento de informação auxiliar

a) Produção da máscara “água”/”não água” (masc_h2o)

Para produzir a máscara binária “água”/”não água” identificou-se a área correspondente ao rio Tejo, ou seja, a única zona de água na imagem. Foi neste passo que se fez, pela primeira vez, uso da informação não espectral, através do recurso ao ficheiro gráfico corrigido da delimitação das subsecções (BGRE), que apresenta o limite de costa perfeitamente definido (não existem subsecções estatísticas dentro de água) e que foi transformado num ficheiro matricial binário, em que a área ocupada por água tinha valor 0 e a restante 1. Multiplicando uma imagem por esta máscara, é possível extrair a classe “água” dessa imagem (figura 5.14).




Figura 5.14 – Utilização de uma máscara para isolar as áreas acima do nível do mar. (a) imagem original; (b) máscara binária “água”/”não água”; (c) imagem final

De notar que muito embora os classificadores tradicionais consigam quase sempre identificar os pixéis da classe “água” com uma precisão de 100% não resolvem o problema dos que apresentam uma mistura de vários usos (nomeadamente junto à costa), conhecidos habitualmente como mixéis. Nestas situações, é comum pixéis correspondentes à linha de costa serem classificados como água, e vice-versa.

b) Produção da máscara “urbano” / “não urbano” (urb_1)

No passo seguinte procedeu-se a uma análise mais cuidada da informação estatística seleccionada (tabela 5.1), tendo em atenção os objectivos a atingir. Com efeito, a primeira selecção, que conduziu à tabela 5.1, incluía informação relativa aos indivíduos e aos alojamentos; no primeiro caso (indivíduos), a opção tomada teve por base o trabalho descrito em [82], onde foi verificada a existência de uma forte correlação entre os mapas representando a densidade populacional e as áreas classificadas como urbanas na imagem de satélite; no segundo caso (alojamentos), seguiu-se uma das regras de pós-classificação utilizadas no projecto DREU [10] que estabelecia que as subsecções classificadas como urbanas e onde

existisse um grande número de alojamentos colectivos seriam classificadas como áreas de alojamento público (ex. hotéis).

Estes subgrupos foram considerados desnecessários, ou mesmo inutilizáveis, para o cálculo das probabilidades *a priori*, na medida em que a densidade populacional apenas serviria para entrar na classificação das imagens de satélite como banda contextual, com o objectivo de diferenciar o urbano do não urbano e, no âmbito do presente trabalho, existe informação com melhor qualidade para ser utilizada com essa função (como se verá no decorrer desta secção).

Quanto ao método utilizado no projecto DREU, este não poderia ser adaptado ao presente trabalho, porque a informação relativa aos alojamentos reporta-se ao interior dos edifícios; assim, permite inferir se existem edifícios afectos, por exemplo à hotelaria, mas não se consegue avaliar o seu número e, consequentemente, qual o seu peso no número total de edifícios. Como o classificador de *Bayes* utiliza como parâmetros as probabilidades (entre outras) *a priori* de uma classe ocorrer, e perante a impossibilidade de calcular as probabilidades dos edifícios colectivos, este subgrupo de informação (alojamentos) foi considerado inutilizável.

Assim, da primeira selecção de dados, apresentada na tabela 5.1, fez-se uma segunda escolha, optando-se apenas pela informação relativa ao subgrupo “edifícios”, na medida em que neste caso era possível calcular as probabilidades de todas as classes que se pretendia identificar e, dado que se reporta aos edifícios, contém informação que pode mais eficazmente ser correlacionada com a reflectância. Isto porque os satélites, ao registar informação reflectida pela superfície terrestre, também recolhem informação sobre os edifícios, ao contrário do que acontecia relativamente aos alojamentos que, por se encontrarem no interior dos edifícios, são “invisíveis” para os satélites.

O tratamento propriamente dito dos dados estatísticos começou com a identificação das subsecções onde não existiam edifícios e, que, portanto, não são urbanas. As subsecções não urbanas foram imediatamente excluídas da BGRÉ, uma vez que como se pretendia aplicar o algoritmo de *Bayes* apenas às áreas urbanas, não fazia sentido elas estarem representadas no mapa (BGRÉ) que iria servir de base ao cálculo das probabilidades *a priori*.

Retirando da BGRÉ as subsecções não urbanas (ou rurais) deu-se o primeiro passo no sentido de criar um ficheiro que constituísse uma diferenciação entre o urbano e o rural (figura 5.15-a). O ficheiro com as subsecções urbanas (figura 5.15-a) foi intersectado com a rede viária (figura 5.15-b), que está integrada no tecido urbano, mas efectivamente não o é, dando origem à


primeira máscara urbano-rural (figura 5.15-c), indicada no esquema metodológico como urb_1 (figura 5.16).

De seguida, seleccionaram-se as classes que poderiam ser calculadas com recurso ao classificador de *Bayes*, e para as quais as probabilidades de ocorrência *a priori* podiam ser estimadas. As classes consideradas foram “Núcleo Urbano Antigo”, “Habitação Unifamiliar”, “Habitação Plurifamiliar” e “Comércio e Serviços”. A razão da escolha destas quatro classes deve-se à analogia que elas permitem entre a informação espectral e estatística (condição essencial para a aplicação do classificador de *Bayes*).

Com efeito, para além do facto de ser possível calcular as probabilidades *a priori* para estas quatro classes, as três primeiras (“Núcleo Urbano Antigo”, “Habitação Unifamiliar” e “Habitação Plurifamiliar”) também podem ser identificadas com base na informação espectral: O “Núcleo Urbano Antigo” corresponde a edifícios construídos antes de 1945 e cuja cobertura, para além de estar envelhecida (o que já de si permite a distinção relativamente ao mesmo tipo de material mais recente), foi elaborada com recurso a materiais actualmente não utilizados; a “Habitação Unifamiliar” é inteiramente caracterizada por edifícios com cobertura de telha (argila) e a “Habitação Plurifamiliar” é composta, na sua maioria, por edifícios com cobertura de betão, existindo alguns casos pontuais em que a cobertura é de telha (fonte de erro que, no entanto, pode ser atenuada com o recurso à informação estatística). A classe “Comércio e Serviços” não é identificável com recurso à informação espectral mas, como será explicado na secção seguinte, as características da informação estatística permitem *per si* a identificação desta classe. Posto isto, foi necessário estabelecer as fórmulas de cálculo das probabilidades de ocorrência *a priori* das quatro classes acima mencionadas, através de um processo que será descrito na próxima secção.



(a)



(b)



(c)

Figura 5.15 – Produção da máscara urb_1: (a) BGRE sem as subsecções não urbanas (ou rurais); (b) rede viária; (c) BGRE sem as subsecções não urbanas (ou rurais) e sem a rede viária ($c = a \times b$) - Máscara urb_1 (a área presumivelmente urbana corresponde ao preto e a branco está o que de certeza é não urbano)

c) Cálculo das probabilidades *a priori*

Uma vez seleccionada a informação estatística a usar, foi necessário estabelecer fórmulas para o cálculo das probabilidades de ocorrência (*a priori*) das quatro classes urbanas atrás mencionadas. Os edifícios com mais de dois pisos (pavimentos) foram considerados habitação plurifamiliar; os edifícios de um ou dois pisos foram considerados habitação unifamiliar. O núcleo urbano antigo foi estabelecido como o conjunto de edifícios construídos até 1945, inclusivamente. Esta opção deveu-se ao facto de ser esta a data utilizada na elaboração da Carta de Uso do Solo da AML para 1991 (que poderia servir de ficheiro de validação) e de nesta década ter havido uma alteração no tipo de materiais de construção utilizados, facto que também é perceptível através das imagens de satélite e que, permite uma grande correlação entre os dois tipos de dados (estatísticos e espectrais). Os edifícios principalmente não residenciais (última linha da tabela 5.1) foram considerados afectos ao comércio e serviços, independentemente da data de construção e do número de pisos.

As probabilidades de ocorrência *a priori* referentes a uma subsecção, são dadas por (no anexo 4 existe uma explicação mais pormenorizada de como se chegou a estas expressões):

$$p(\text{'Habitação plurifamiliar'}) \equiv p(\text{HP}) = \text{HP}/\text{TE}, \quad (5.6)$$

$$p(\text{'Habitação unifamiliar'}) \equiv p(\text{HU}) = \text{HU}/\text{TE}, \quad (5.7)$$

$$p(\text{'Núcleo urbano antigo'}) \equiv p(\text{NUA}) = \text{NUA}/\text{TE}, \quad (5.8)$$

$$p(\text{'Comércio e serviços'}) \equiv p(\text{CS}) = \text{CS}/\text{TE}, \quad (5.9)$$

com

HP - número de edifícios plurifamiliares, construídos depois de 1945;

HU - número de edifícios unifamiliares, construídos depois de 1945;

NUA - número de edifícios (exclusivamente ou principalmente) residenciais, construídos antes 1945;

CS - número de edifícios predominantemente não residenciais;

TE - número total de edifícios, relativos à subsecção.

Naturalmente, a soma destas quatro probabilidades tem que ser igual a um. Note-se, no entanto, que alguns dos índices requeridos (nomeadamente o HP, HU e NUA) não podem ser obtidos directamente da tabela 5.1. Por exemplo, esta tabela fornece o número de edifícios plurifamiliares e o número de edifícios construídos depois de 1945, mas não o número de

Classificação de Imagens com Recurso a Informação não Espectral

edifícios plurifamiliares construídos depois de 1945, como é requerido. Tendo este facto em consideração, adoptou-se a seguinte estratégia para calcular as probabilidades *a priori*:

1. Compute $p(\text{CS}) = \text{CS}/\text{TE}$
2. If
 $p(\text{CS}) > 0,8$
then
 $p(\text{CS}) = 1, p(\text{HP}) = p(\text{HU}) = p(\text{NUA}) = 0$
else
 $p(\text{CS}) = 0$
3. If
 $p(\text{CS}) = 0$
then
 $p(\text{NUA}) = \text{NUA}/\text{TE}$
 $p(\text{HP}) = (\text{HP}_t - \alpha \text{NUA})/\text{TE}$
 $p(\text{HU}) = (\text{HU}_t - \beta \text{NUA})/\text{TE}$

com


HP_t - número de habitações plurifamiliares;

HU_t - número de habitações unifamiliares.


Devido à distribuição assimétrica da classe “Comércio e Serviços”, ou seja, ao facto de existirem subsecções com baixas probabilidades *a priori* ($\leq 0,05$) de possuírem edifícios exclusivamente afectos ao “Comércio e Serviços” e, em antítese, haver outras onde essa mesma probabilidade é bastante elevada ($>0,8$), não se verificando a existência de probabilidades intermédias, optou-se por classificar todos os edifícios existentes nas subsecções onde $p(\text{CS}) > 0,8$ como de “Comércio e Serviços” e todos os edifícios das subsecções onde $p(\text{CS}) \leq 0,8$ como de habitação (englobando as classes “Núcleo Urbano Antigo”, “Habitação Unifamiliar” e “Habitação Plurifamiliar”), considerando-se neste caso $p(\text{CS}) = 0$ e assumindo-se o erro daí resultante.

A classe “Núcleo Urbano Antigo” engloba edifícios plurifamiliares e unifamiliares, por isso a sua probabilidade de ocorrência *a priori* foi calculada antes das probabilidades das classes “Habitação Unifamiliar” e “Habitação Plurifamiliar” de forma a garantir a sua prevalência sobre estas últimas duas classes. Por fim, a probabilidade de ocorrência *a priori* das classes “Habitação Unifamiliar” e “Habitação Plurifamiliar” é calculada retirando-se do número total de edifícios a percentagem de edifícios antigos que são unifamiliares e plurifamiliares. Os

parâmetros α e β ($\alpha+\beta=1$) representam essa percentagem. Na fase de processamento, face à idêntica (baixa) correlação apresentada por estas duas variáveis relativamente ao número de edifícios anteriores a 1945 (figura 5.16) utilizou-se $\alpha=\beta=0,5$.



(a)



(b)

Figura 5.16 – Regressão linear e correlação entre os edifícios unifamiliares (a) e os edifícios plurifamiliares (b) com os edifícios anteriores a 1945. As ordenadas representam a probabilidade *a priori* da classe “Núcleo Urbano Antigo” e as abcissas as probabilidades *a priori* das classes “Habitação Unifamiliar” (a) e “Habitação Plurifamiliar” (b). Os pontos representam as subsecções.

d) Cálculo da banda contextual

O último passo a dar relativamente ao processamento da informação auxiliar é a criação de uma banda urbana contextual (figura 5.17-a). Esta banda estabelece três grandes grupos de subsecções – subsecções fortemente urbanizadas, subsecções pouco urbanizadas e subsecções com pouca probabilidade de terem edifícios. Isto foi conseguido com recurso a uma simples técnica de *clustering* (figura 5.17-b), utilizando como variáveis a densidade populacional (número de indivíduos/km²), a densidade de edifícios (número de edifícios/km²) e a percentagem de edifícios unifamiliares e plurifamiliares relativamente ao número total de edifícios.

Os algoritmos de *clustering* operam sobre dois tipos fundamentais de tabelas de dados: o primeiro tipo apresenta as entidades (subsecções) sob a forma de uma matriz de dimensão $n \times p$, correspondendo as n linhas às subsecções e as p colunas às características (variáveis) seleccionadas para a análise; o segundo tipo consiste numa matriz de dimensão $n \times n$ cujos elementos correspondem à medida de proximidade entre cada duas subsecções do conjunto.

Quando se está a realizar uma análise fazendo o algoritmo operar sobre uma matriz do segundo tipo, o problema estatístico das unidades de medida não se coloca. De facto, uma medida de similitude ou distância é por definição adimensional, ou, caso não o seja, essa semelhança ou distância está representada na mesma escala de unidades para cada par de subsecções representadas na matriz. Todavia, quando a matriz inicial sobre a qual se vai efectuar a abordagem é uma matriz que contém variáveis expressas em diferentes escalas de medida, o problema deve ser discutido: qualquer medida de semelhança ou distância irá reflectir, em maior ou menor medida, o peso, por um lado, das variáveis com maiores escalas de medida e por isso com maiores valores e, por outro, das variáveis com maior dispersão. É aconselhável, portanto, que se proceda a uma standardização prévia das variáveis de modo a que tenham todas o mesmo peso análise.

Assim, devido ao facto das variáveis utilizadas neste processo possuírem características diferentes (densidades e percentagens), foi necessário standardizá-las, de modo a torná-las compatíveis entre si e com o processo de *clustering* propriamente dito. O processo mais utilizado para este efeito, o qual é relativamente simples uma vez conhecidas as médias e desvios-padrão das variáveis, consiste na transformação dos dados em novas variáveis com média nula e desvio-padrão igual à unidade. Deste modo, as variáveis standardizadas (Z) foram calculada através da expressão:

$$Z = \frac{n - \mu}{\sigma}, \quad (5.10)$$

com

n - valor inicial do registo;

μ - média da variável;

σ - desvio padrão da variável.

A técnica de *clustering* adoptada foi a **hierárquica**. O ponto de partida desta técnica baseia-se na construção de uma matriz de semelhanças ou diferenças entre as subsecções, que corresponde inicialmente a n grupos, igual ao número de subsecções em análise e que descreve o grau de semelhança ou diferença entre cada dois pares de subsecções. Portanto, a análise de *clusters* começa com uma matriz de dados, onde as linhas representam as subsecções e as colunas as variáveis. A partir desta primeira matriz é construída uma segunda em que as subsecções são representadas quer em linha, quer em coluna (cada elemento da matriz é uma medida de semelhança ou dissemelhança entre cada duas subsecções). A distância euclidiana (descrita na secção 4.2.2) é aquela, das várias medidas que podem ser utilizadas para calcular a distância ou dissemelhança entre os elementos da matriz de dados, que tem sido mais utilizada e portanto foi a aplicada no processo de *clustering* que visa a criação da banda contextual.


Após a construção da matriz de distâncias, o passo seguinte é agrupar as subsecções com base nessa mesma matriz. O método mais utilizado (e aquele que foi adoptado) é o **aglomerativo**, onde as subsecções são sucessivamente agregadas até se atingir um único grande grupo (com n elementos). O método de agregação das subsecções em grupos recebe a designação de algoritmo de *clustering* ou *amalgamation rule*. O critério de agregação mais utilizado – e portanto seleccionado – é o do vizinho mais próximo (**Single Linkage**), o qual define como semelhança entre dois grupos a distância entre as suas subsecções mais próximas. Dados dois grupos, a distância entre os dois é a menor das distâncias entre os elementos dos dois grupos. O agrupamento vai sendo feito através de um “relaxe sucessivo da proximidade absoluta”: cada subsecção é agregada à que lhe está mais próxima; depois, cada grupo resultante é agregado ao que lhe está mais próximo e assim sucessivamente até se atingir o(s) grupo(s) cuja hierarquia é mais elevada (daí a designação de método **hierárquico aglomerativo**).

Os resultados da aplicação do algoritmo de clustering estão representados no **dendograma** (ou **árvore binária**) da figura 5.17-b. As subsecções são representadas nas abcissas (nós) e os ramos ilustram o momento em que o algoritmo junta dois subgrupos. O tamanho de cada ramo é proporcional à distância de agregação dos subgrupos (**coeficiente de fusão**).



(a)

Ligação Unidireccional
Distância Euclidianas



(b)

Figura 5.17 – (a) Banda contextual urbana proveniente do processo de *clustering* (a) onde: preto - subsecções fortemente urbanizadas; cinzento escuro - subsecções pouco urbanizadas; cinzento claro - subsecções com pouca probabilidade de terem edifícios; (b) dendograma da classificação dos índices através de *clustering*

5.4 METODOLOGIA DE CLASSIFICAÇÃO

A metodologia de classificação desenvolvida segue uma abordagem por níveis (*layers*), sendo composta por três fases principais: 1 – Estratificação de pré-classificação; 2 – Aplicação dos classificadores de *Bayes* e de Máxima Verosimilhança; 3 – Aplicação de regras de pós-classificação. As abordagens tradicionais utilizam a informação auxiliar apenas numa destas fases. O método proposto, destaca-se da generalidade dos métodos existentes como um método onde a informação auxiliar (ou informação dela extraída) é utilizada em todas as fases de classificação.

5.4.1 Estratificação de pré-classificação

O objectivo principal desta fase é disponibilizar, para utilização no classificador, três estratos principais de informação – “água”, “áreas urbanas” e “áreas não urbanas” – que serão processados individualmente. Na fase de pré-processamento já tinha sido criada uma máscara binária “água/terra”, que permitiu isolar em todas as bandas (imagens de satélite e a banda urbana contextual) a classe “água”, e uma primeira aproximação à máscara binária “urbano/não urbano” (urb_1). Nesta fase é produzida uma versão mais precisa da máscara binária “urbano/não urbano” (urb_fim).

O procedimento de pré-classificação, que se encontra esquematizado na figura 5.18, consiste na aplicação do algoritmo ISODATA (descrito em 4.3), que tem como dados de entrada: as bandas espectrais, a banda urbana contextual, e duas bandas TVI (*Transformed Vegetation Index*) obtidas a partir de cada um dos grupos (SPOT e Landsat) de imagens de satélite; o propósito da máscara “água” (masc_h2o) é meramente excluir, da restante informação de entrada, a classe “água”. As bandas TVI, calculadas de acordo com (5.14) e (5.15), representam a quantidade de biomassa existente à superfície, apresentando uma forte correlação com a densidade de construção e, conseqüentemente, permitindo uma maior diferenciação entre o espaço construído e não construído [1, 36].

$$TVI(LANDSAT) = \sqrt{\frac{TM4 - TM3}{TM4 + TM3} + 0,5}, \quad (5.11)$$

$$TVI(SPOT) = \sqrt{\frac{XS3 - XS2}{XS3 + XS2} + 0,5}. \quad (5.12)$$

O resultado das expressões (5.11) e (5.12) pode apenas tomar valores compreendidos entre 0 e 1. Em consequência, os índices TVI foram ainda sujeitos a uma transformação linear para que os seus valores cobrissem a gama de valores compreendida entre 0 e 255.

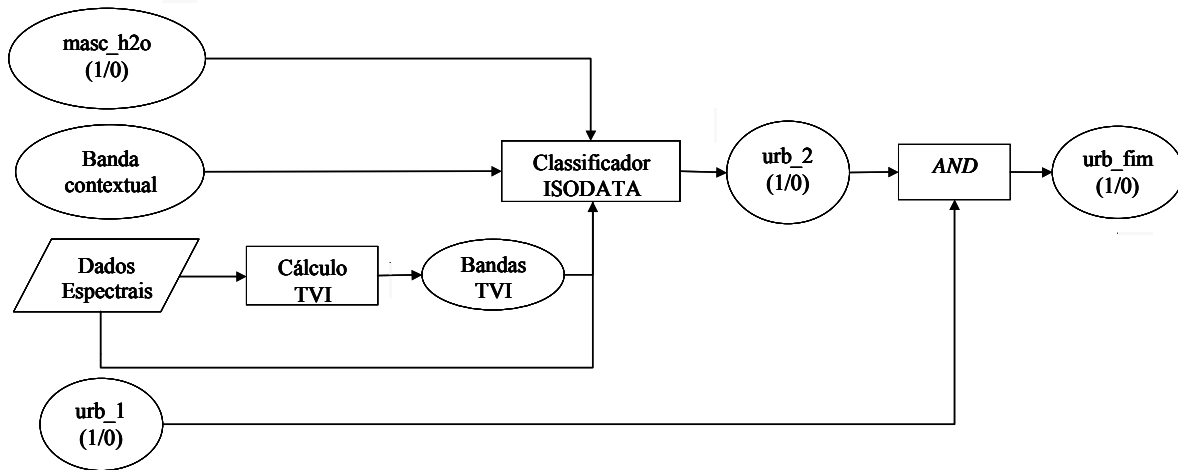




Figura 5.18 – Diagrama esquemático dos processos efectuados na fase de estratificação pré-classificação

No segundo passo, foi aplicado o algoritmo de classificação não supervisionada ISODATA para classificar os dados de entrada em diversas classes espectrais, tendo sempre como objectivo bem definido a estratificação “urbano/não urbano”. Na figura 5.19 apresentam-se os resultados obtidos para três valores de número de classes.


A razão para a escolha do algoritmo ISODATA para esta classificação deveu-se a dois factores principais: *i*) a intenção de, nesta fase, não definir classes de uso e ocupação do solo; *ii*) o conhecimento de trabalhos anteriores, comprovando que a conjugação deste algoritmo com uma banda contextual (semelhante à utilizada neste trabalho) pode melhorar os resultados da classificação [27, 28]. O melhor resultado, tendo em consideração a discriminação entre as áreas urbanas e não urbanas, foi obtido pela classificação em seis classes (figura 5.19-a). Reclassificando esta imagem de forma a criar uma imagem binária onde os valores correspondentes às classes presumivelmente urbanas, seriam reclassificados como 1 e os restantes como 0, criou-se a máscara *urb_2* (figura 5.20-b) que, ao ser intersectada (operação AND) com a *urb_1* (figura 5.20-a), deu origem ao mapa de espaços urbanos (*urb_fim*) que serve de base à aplicação do algoritmo de *Bayes* (figura 5.20-c).



(a) 6 classes



(b) 8 classes




(c) 12 classes


Figura 5.19 – Exemplos de classificações obtidas pelo ISODATA



(a)



(b)



(c)

Figura 5.20 – Máscaras binárias “urbano” / “não urbano”: urb_1 (a), urb_2 (b) e urb_fim (c): O preto corresponde à classe ‘urbano’.

Integração de Dados Estatísticos na Classificação de Imagens de Satélite

As três máscaras criadas permitiram aumentar a diferenciação urbano/rural, como se pode observar pelas medidas de exactidão expressas na tabela 5.3 (explicadas de forma detalhada na secção 5.5), nomeadamente o aumento progressivo da exactidão global: 45,4% para a urb_1, 84,7% para a urb_2 e 91,8% para a urb_fim. Na urb_1 todas as áreas assinaladas como não urbanas eram-no efectivamente, mas existia uma grande percentagem de áreas assinaladas como urbanas que não correspondiam a essa classe. Com a criação da urb_2, identificaram-se as áreas espectralmente tidas como urbanas. Neste caso aumentou-se de um modo geral, a distinção entre o urbano e o não urbano, mas perdeu-se algum pormenor em certas áreas, o que fez baixar a exactidão do utilizador (EU). A última máscara (urb_fim) apresenta melhores resultados que a anterior (urb_2) em virtude do seu cruzamento com a urb_1 ter permitido a extracção da rede viária e das áreas que, embora espectralmente sejam classificadas como urbanas, não o sejam seguramente, pois possui-se o conhecimento prévio de que lá não existem edifícios. O exemplo mais pertinente é o do areeiro situado a Noroeste, que estava classificado como urbano na máscara urb_2 e que foi praticamente excluído na máscara urb_fim.

| | | EO (0-1) | EC (0-1) | PP (%) | PC (%) | KIA (0-1) | Índice Kappa (0-1) | EG (%) |
|-----------------------|----------------|---------------------|---------------------|-------------------|-------------------|----------------------|-------------------------------|-------------------|
| | Urb_1 | | | | | | | |
| 0 – Não Urbano | | 0,61 | 0,00 | 38,6 | 100,0 | 1,00 | 0,40 | 45,4 |
| 1 - Urbano | | 0 | 0,83 | 100 | 16,97 | 0,01 | | |
| | Urb_2 | | | | | | | |
| 0 – Não Urbano | | 0,11 | 0,10 | 88,5 | 89,7 | 0,64 | 0,63 | 84,7 |
| 1 - Urbano | | 0,24 | 0,27 | 75,3 | 72,9 | 0,61 | | |
| | Urb_fim | | | | | | | |
| 0 – Não Urbano | | 0,10 | 0,00 | 89,5 | 99,9 | 0,73 | 0,75 | 91,8 |
| 1 - Urbano | | 0,00 | 0,27 | 99,9 | 72,9 | 0,72 | | |

Tabela 5.3 – Erros de omissão (EO), erros de comissão (EC), exactidão do produtor (EP), exactidão do utilizador (EU), KIA (*Kappa Index of Agreement*), índice Kappa e exactidão global (EG).

Ainda relativamente à qualidade dos dados, refira-se que a máscara urb_2, calculada sem a banda contextual, atingiu uma exactidão global de 83,4%, e a mesma máscara, estimada sem recurso às duas bandas TVI, alcançou apenas uma exactidão global de 76,2%. Neste caso, a utilização do índice de vegetação constituiu efectivamente uma mais valia para a metodologia desenvolvida e a banda contextual, introduzindo um melhoramento marginal, pode não constituir uma opção válida quando se entra em consideração com a dualidade “tempo de (pré)processamento/qualidade dos resultados”.

5.4.2 Aplicação dos classificadores de Máxima Verosimilhança e de Bayes

A segunda fase do procedimento de classificação encontra-se esquematicamente representada na figura 5.21. As máscaras binárias, obtidas nas fases anteriores, relativas aos usos “água” (masc_h2o) e “urbano” (urb_fim), foram cruzadas com todas as bandas espectrais, dando origem a duas novas imagens por cada original: uma com as classes não urbanas (“Floresta”, “Mato”, “Solo a Nu”, “Área Agrícola”, “Vias”, “Praia” e “Grandes Equipamentos”) e outra com os usos urbanos (“Comércio e Serviços”, “Núcleo Urbano Antigo”, “Habitação Plurifamiliar”, “Habitação Unifamiliar”, “Indústria” e “Grandes Equipamentos”).

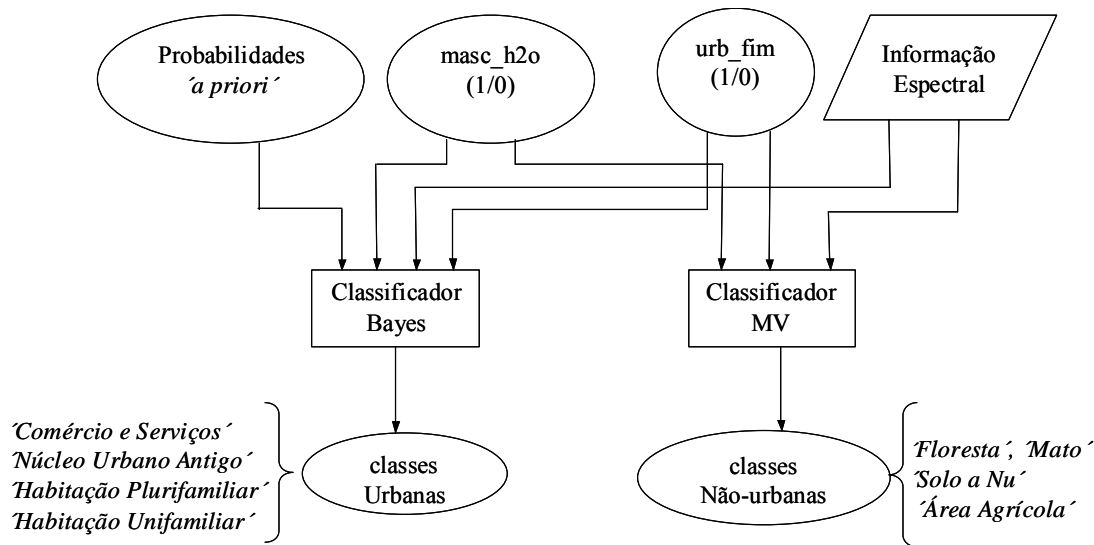


Figura 5.21 - Esquema metodológico dos processos de classificação recorrendo aos algoritmos de Máxima Verosimilhança (MV) e de Bayes

As classes “Floresta”, “Mato”, “Solo a Nu” e “Área Agrícola”, pertencentes às imagens não urbanas, foram extraídas utilizando um classificador de máxima verosimilhança. Note-se que, como foi referido anteriormente, o uso “Vias” já se encontrava disponível através da informação auxiliar (Rede Viária). As classes “Praia” e “Grandes Equipamentos” não urbanos são obtidos na fase seguinte, recorrendo a regras de pós-classificação produzidas a partir do Plano Director Municipal (PDM) e a duas imagens que, para cada pixel, representam a distância entre esse pixel e o pixel mais próximo classificado como “água” ou como “rede viária”, respectivamente.

As imagens urbanas e as imagens correspondentes às quatro probabilidades *a priori* (calculadas na secção 5.3.2 e representadas na figura 5.22) constituem a base de aplicação do classificador de Bayes. Estas probabilidades permitem discriminar quatro classes urbanas (“Comércio e Serviços”, “Núcleo Urbano Antigo”, “Habitação Plurifamiliar”, “Habitação Unifamiliar”) que,

Integração de Dados Estatísticos na Classificação de Imagens de Satélite

devido à similaridade das suas respostas espectrais, seriam mal classificadas se fosse aplicado um algoritmo de máxima verosimilhança. Os usos “Indústria” e “Grandes Equipamentos” urbanos são identificados na próxima fase de classificação, utilizando regras de pós-classificação, obtidas com base no Plano Director Municipal (PDM) e numa imagem de distância à rede viária.

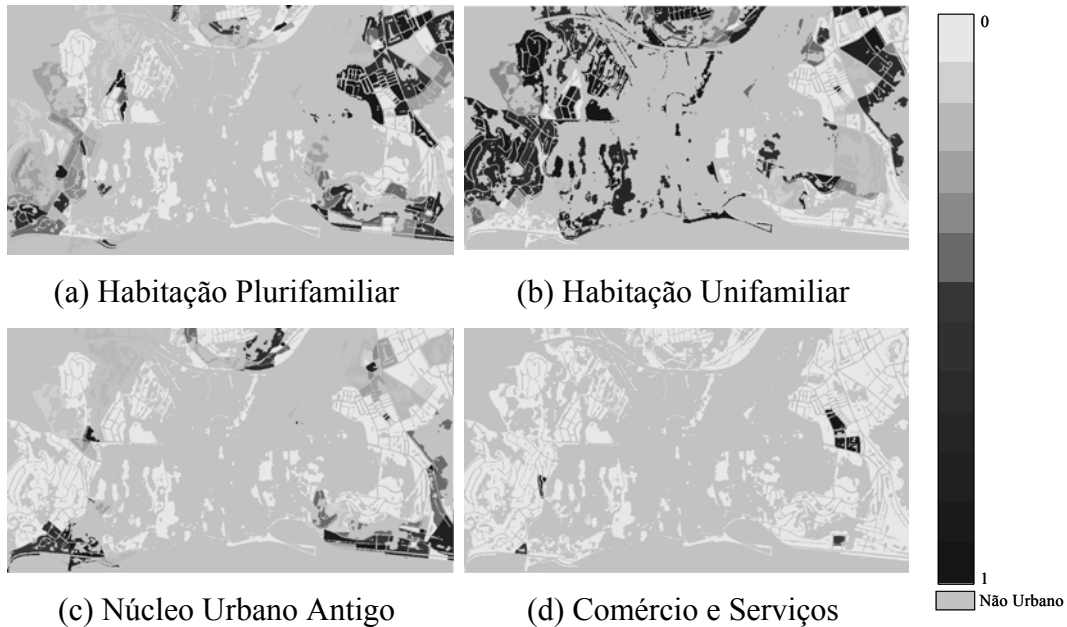
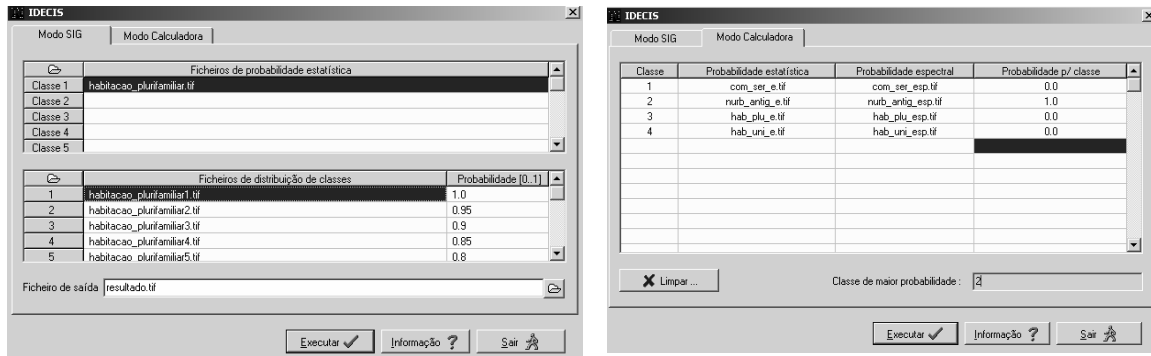


Figura 5.22 – Probabilidades *a priori* para quatro classes de uso urbano

Como já foi referido, as imagens espectrais urbanas foram integradas com as quatro probabilidades *a priori* através do classificador de *Bayes*, utilizando-se para o efeito um pequeno programa desenvolvido no âmbito desta dissertação e baptizado de IDECIS (**I**ntegração de **D**ados **E**statísticos na **C**lassificação de **I**magens de **S**atélite). A aplicação em questão está estruturada em dois módulos, sendo o primeiro designado SIG (figura 5.23-a), na medida em que é nele que são apuradas as probabilidades finais de cada pixel pertencer a uma determina classe; o segundo módulo (figura 5.23-b), referenciado como calculadora, transforma o algoritmo de *Bayes* num classificador rígido, ou seja, numa análise pixel a pixel vai atribuir a cada pixel a classe com maior probabilidade de ocorrência.



(a) módulo SIG

(b) módulo calculadora

Figura 5.23 – Programa IDECIS

As áreas de treino, necessárias à implementação, tanto do algoritmo de *Bayes* como do algoritmo de máxima verosimilhança, foram delimitadas sobre a composição colorida que oferecia uma melhor discriminação visual dos usos (figura 5.24-b). Esta composição foi obtida através dos seguintes passos¹: 1 – criação de uma primeira composição atribuindo as bandas TM 7, 4 e 1 aos canais R (**R**ed – encarnado), G (**G**reen – verde) e B (**B**lue – azul), respectivamente; 2 – transformação do espaço de cor de RGB para IHS (**I**ntensity – intensidade; **H**ue – tonalidade; **S**aturation – saturação); 3 – substituição do canal I pela banda SPOT Pan; transformação do espaço de cor de IHS para RGB.

Optou-se por esta abordagem para tirar partido das diversas resoluções espaciais e espectrais das imagens de satélite disponíveis. Uma das principais vantagens da transposição de uma composição colorida do sistema *RGB* para o *IHS*, e vice-versa é a de possibilitar a fusão das imagens que constituem a composição colorida inicial (frequentemente bandas Landsat TM) com uma quarta de maior resolução espacial (geralmente a SPOT Pan), obtendo-se um novo produto em que os vários padrões espectrais fornecidos pelo Landsat são dispostos em diferentes tonalidades e onde o SPOT Pan fornece dados maior resolução espacial que permitem, por seu turno, identificar a textura da superfície.

¹ As imagens digitais são tipicamente visualizadas através de composições coloridas aditivas, utilizando três cores primárias: encarnado (**R**ed), verde (**G**reen) e azul (**B**lue). Este sistema de visualização é conhecido por RGB, sendo bastante utilizado no processamento digital de imagens para visualizar composições coloridas arbitrárias, em cor verdadeira ou falsa cor.

Outro dos sistemas de cor é o que utiliza a intensidade (**I**ntensity), a tonalidade (**H**ue) e a saturação (**S**aturation) para definir uma cor. Neste sistema (*IHS*) a intensidade corresponde ao brilho de uma cor, a tonalidade refere-se ao comprimento de onda dominante, ou médio, da luz que contribui para a cor e a saturação específica a pureza de uma cor relativamente ao cinzento.




Figura 5.24 – Exemplos de composições coloridas criadas para a delimitação de áreas treino (resolução espacial de 10 m)

5.4.3 Regras de pós-classificação

A última fase do método envolve a aplicação de regras bastante específicas para reclassificar alguns pixels que tenham sido atribuídos a classes erradas nas fases anteriores e que possam ser corrigidos com o uso de regras contextuais e/ou com conjunto de informação auxiliar disponível (rede viária e PDM). Neste contexto, foram consideradas quatro classes de uso: “Vias”, “Praia”, “Indústria” e “Equipamentos Desportivos” (uma subclasse dos “Grandes Equipamentos”). A rede viária, como já foi anteriormente referido, estava disponível em formato digital e as restantes classes resultam da informação disponível no PDM ou, na ausência desta, das seguintes regras contextuais:

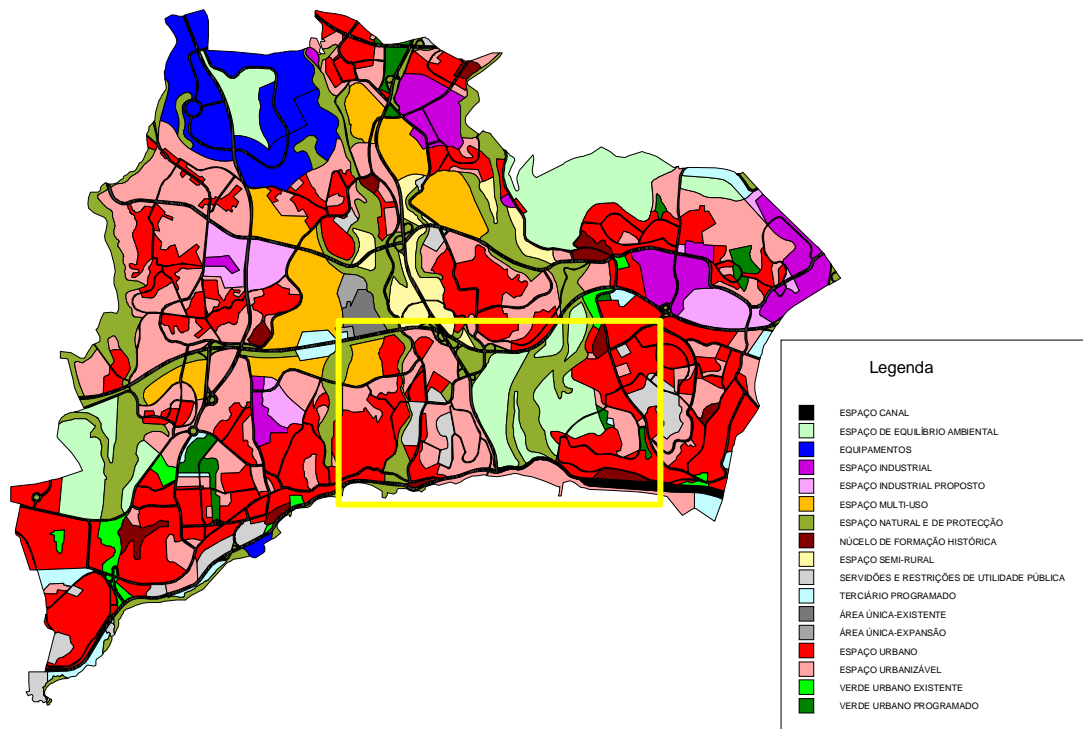
- **“Praia”** - pixels que, embora pertencendo à área urbana (valor 1 na máscara urb_2), não foram classificados em nenhuma das classes urbanas, e que estão situados a menos 200 m da linha de costa (limite estabelecido por lei que define o domínio público hídrico);
- **“Indústria”** - pixels classificados como urbanos (valor 1 na máscara urb_fim), mas assinalados como indústria no PDM (figura 5.25-a);

- **“Equipamentos Desportivos”** - pixéis classificados como mato ou solo a nu, fazendo parte de uma região homogénea com uma área e um perímetro típicos dos campos de futebol e ténis e que distem menos de 500 m da estrada mais próxima (figura 5.25-b). Para este caso, foram ainda confrontados os resultados da classificação das imagens de satélite com a planta de ordenamento do PDM, com o intuito de averiguar se este acrescentaria algo mais à classificação. No entanto, no caso de Oeiras, este plano é composto por classes bastante abrangentes, de modo que não foi possível otimizar a utilização desta informação. Os “Grandes Equipamentos” restantes foram retirados da classe do PDM, “equipamentos existentes”.


Todas as classes apuradas foram então integradas num mapa de classificação final mediante a aplicação do seguinte algoritmo:

- A classificação dos pixéis é levada a efeito com base numa perspectiva classe a classe, sendo orientada da classe com maior nível de confiança para a com menor, nomeadamente:
 1. **“Vias”** (retiradas directamente da rede viária)
 2. **“Água”** (retirada da máscara masc_h2o)
 3. **“Comércio e Serviços”** e **“Núcleo Urbano Antigo”** (obtidos através do classificador de *Bayes*)
 4. **“Grandes Equipamentos”** (resultantes do PDM e/ou regras contextuais – incluem os equipamentos desportivos) e **“Praia”** (resultante da máscara urb_2 e regras contextuais)
 5. **“Indústria”** (resultante da máscara urb_fim e do PDM)
 6. **Outras classes “urbanas”** (obtidas através do classificador de *Bayes*)
 7. **Outras classes “não urbanas”** (obtidas através do classificador de Máxima Verosimilhança)

Assim que uma classe é atribuída a um pixel, não poderá ser sobreposta por outra classe. O mapa final de uso e ocupação do solo encontra-se representado na figura 5.26.



(a)



(b)

Figura 5.25 - Exemplos de informação auxiliar: Planta de Ordenamento do PDM de Oeiras (a) e distâncias relativamente à rede viária (b). No mapa (b) a rede viária está representada a preto e as distâncias das cores frias (azul) para as cores quentes (encarnado)

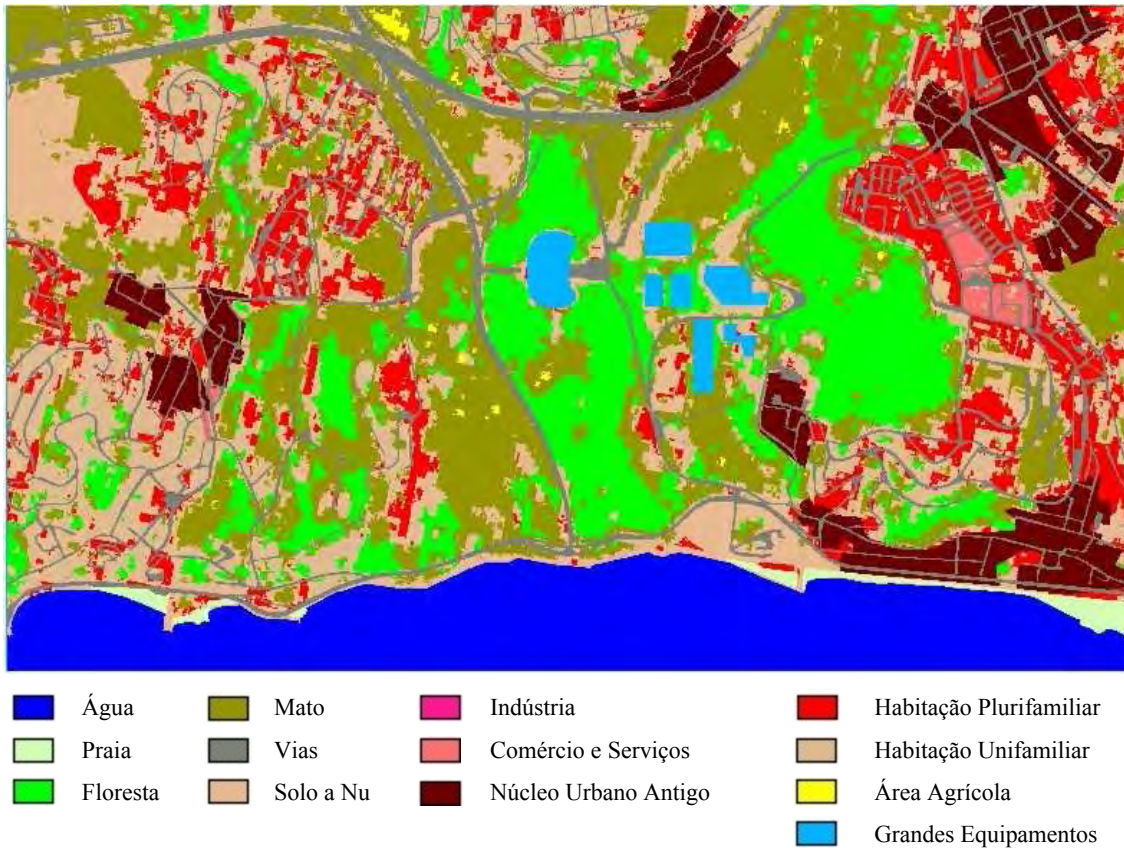


Figura 5.26 – Carta de uso e ocupação do solo resultante da aplicação do método proposto

5.5 VALIDAÇÃO DOS RESULTADOS

Chegado o epílogo de todo o processo de investigação descrito, resta aferir a validade da metodologia desenvolvida o que, apesar de ser o último procedimento, acaba por se assumir como um dos mais importantes. Para proceder à validação dos resultados é necessário efectuar duas operações: *i) delimitar as áreas de teste*, ou seja, definir o conjunto de pixéis, onde será feita a correspondência com a realidade; *ii) escolher* e aplicar as **medidas** e/ou **métodos de validação (avaliação do erro)** às áreas de teste.

5.5.1 Delimitação das áreas de teste

As áreas de teste deverão ser uniformes e representativas de uma classe de ocupação do solo. Também são diferentes (têm outra localização) das áreas de treino e devem ser consideravelmente mais extensas. Muitas vezes, as áreas de teste são localizadas aquando da fase de treino da classificação supervisionada, delimitando-se para o efeito mais áreas de treino do que aquelas que efectivamente seriam necessárias para calcular os parâmetros estatísticos a usar pelo classificador. Um subconjunto destas áreas de treino seria depois “suspenso”, de

Integração de Dados Estatísticos na Classificação de Imagens de Satélite

forma a não integrar o processo de classificação e entraria na avaliação da exactidão como a informação de referência conhecida (*ground truth*). A exactidão obtida através deste método representa, no mínimo, uma primeira aproximação à exactidão global (para toda a imagem). Contudo, sendo homogéneas, as áreas de teste podem não permitir verificar com rigor a exactidão da classificação relativamente à variabilidade de cada classe de ocupação do solo ao nível do pixel.

Uma forma de garantir uma avaliação adequada à especificidade da análise ao nível do pixel é comparar todos os pixéis da imagem classificada com a verdade do terreno. No entanto, se ao nível da investigação esta avaliação total detém um grande valor, na prática, recolher informação de referência para toda a imagem classificada é bastante oneroso e subverte o propósito de se efectuar uma classificação de uso/ocupação do solo com recurso a imagens de satélite.

A recolha, ao acaso, de valores de pixel para amostra, resolve o problema acima enunciado mas, por outro lado, também tem alguns problemas intrínsecos. Em primeiro lugar, a recolha de informação para um grande número de pontos distribuídos ao acaso é, muitas vezes, difícil e dispendiosa. Em segundo lugar, a validade deste processo depende fortemente da qualidade da georreferenciação da imagem classificada, pois o erro de uns metros pode implicar que um determinado pixel vá ser validado relativamente à verdade do terreno de um local a que ele na realidade não corresponde. Uma forma de tentar resolver este problema é recolher valores de amostra (pixéis), o mais longe possível das regiões de fronteira entre classes de uso.

Outro factor a ter em consideração é o de os pixéis recolhidos serem geograficamente representativos da imagem em análise. Uma simples distribuição de pontos de recolha ao acaso (recolha sistemática), tende a menosprezar áreas pequenas, mas nem por isso menos importantes. Por isso, recorre-se geralmente a uma recolha estratificada de pontos, onde cada categoria de ocupação do solo é considerada individualmente. Cada amostra deve ter em atenção a área em estudo e o tipo de uso que aí se observa. Isto porque, a quantidade de observações por unidade de superfície não é necessariamente a mesma para todos os sectores de um mapa, na medida em que está directamente relacionada com as características da área em estudo. Objectivamente, uma área homogénea requer necessariamente um número de validações menor que uma outra onde se observe um “rendilhado de usos”, como se pode presenciar nas áreas peri-urbanas. Na maioria das situações reais, para obter uma avaliação fiável da qualidade da classificação deve optar-se por uma abordagem mista, combinando o método de recolha sistemático e estratificado.

O número real de pixéis a ser referenciado no terreno e utilizado para calcular a exactidão das categorias individuais nos mapas de classificações de imagens de satélite é muitas vezes difícil

de determinar. Para resolver esta situação, alguns especialistas usam uma equação baseada na distribuição binomial ou na aproximação normal à distribuição binomial para calcular o tamanho da amostra requerido [42, 58]. Estas técnicas avaliam estatisticamente o tamanho da amostra necessário para calcular a exactidão global de uma classificação. As equações são baseadas na proporção das amostras comuns classificadas (ex. pixéis, *clusters* ou polígonos) e em alguns erros admissíveis. Por exemplo, o tamanho da amostra N a ser utilizado para aferir com exactidão o mapa da classificação do uso do solo pode ser determinado pela fórmula para a Teoria das Probabilidades Binomiais:

$$N = \frac{Z^2(p)(q)}{E^2}, \quad (5.13)$$

onde p é a percentagem esperada de exactidão, $q = 100-p$, E é o erro permitido (assumido), e $Z = 2$ para um desvio padrão normal de 1.96 e um nível de confiança de 95% (acima ou abaixo). Numa amostra para a qual a exactidão esperada é de 85% e o erro admitido de 5%, o número de pontos necessários para obter resultados credíveis é:

$$N = \frac{2^2(85)(15)}{5^2} = 204. \quad (5.14)$$

Com uma exactidão do mapa esperada de 85% e um erro aceitável de 10%, o tamanho da amostra seria de 51. Quanto maior for o erro admissível, menos pontos serão necessários para avaliar a exactidão da classificação.

Este método, embora permita estimar o número total de pixéis de teste necessários, é pouco usado na validação da classificação de imagens de satélite, devido à grande dimensão destas imagens. Com efeito, uma amostra de 0,5% de uma única banda TM contém cerca de 300 000 pixéis.

Normalmente, aponta-se para que existam, na matriz de erro, pelo menos 50 amostras por cada categoria de uso e ocupação do solo; contudo, se a área em análise for extensa (mais de 4000 km²) e/ou existam muitas classes (mais de 12) então a amostra deverá ser aumentada para 75 ou mesmo 100 pixéis por categoria. O número de amostras também pode ser ajustado com base na importância relativa de cada categoria, tendo em conta os objectivos do projecto, ou pela variabilidade inerente a cada classe. Pode ser útil retirar menos amostras das categorias que mostram menos variabilidade, tais como água ou mato, e aumentar a amostragem nas categorias que são mais variáveis, tais como áreas urbanas. O objectivo é equilibrar os parâmetros

estatísticos, de modo a obter uma amostra adequada para gerar uma matriz de erro apropriada, com o tempo, custo, e limitações práticas associadas ao projecto de detecção remota.

Neste caso, visto estar disponível para a área de estudo a cartografia de uso e ocupação do solo obtida através da interpretação de fotografia aérea vertical (figura 5.27) e considerando que por muito correctos que sejam os métodos de recolha de amostras estes podem sempre distorcer os factos, optou-se por uma verificação exhaustiva, pixel a pixel, de toda a imagem.

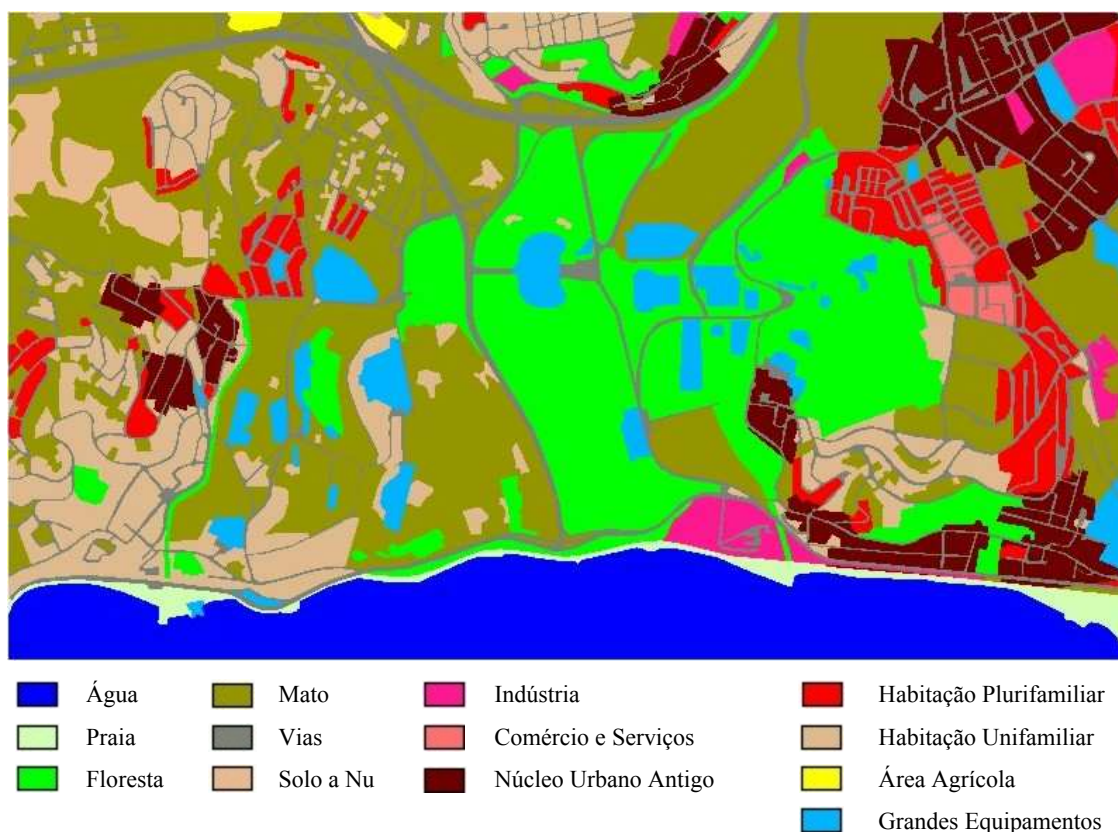


Figura 5.27 - Uso do solo para 1998 obtido por foto-interpretação

5.5.2 Avaliação do erro

Como primeira abordagem, comparou-se a realidade do terreno (imagem obtida por foto-interpretação, figura 5.27) com o resultado obtido pelo método desenvolvido (figura 5.26) e pelos classificadores paramétricos tradicionais, nomeadamente o do paralelepípedo (figura 5.28), da mínima distância com distâncias normalizadas (figura 5.29) e de máxima verosimilhança (figura 5.30). Para o efeito, utilizou-se um método estatístico discreto multivariado conhecido como **tabela de contingências**, **matriz de confusão** ou **matriz de erro**, que permite avaliar a exactidão semântica do mapa temático produzido. As tabelas de contingência (figura 5.31) comparam, categoria a categoria, a relação entre os dados de referência (*ground truth*) e os resultados correspondentes à classificação das imagens de satélite.

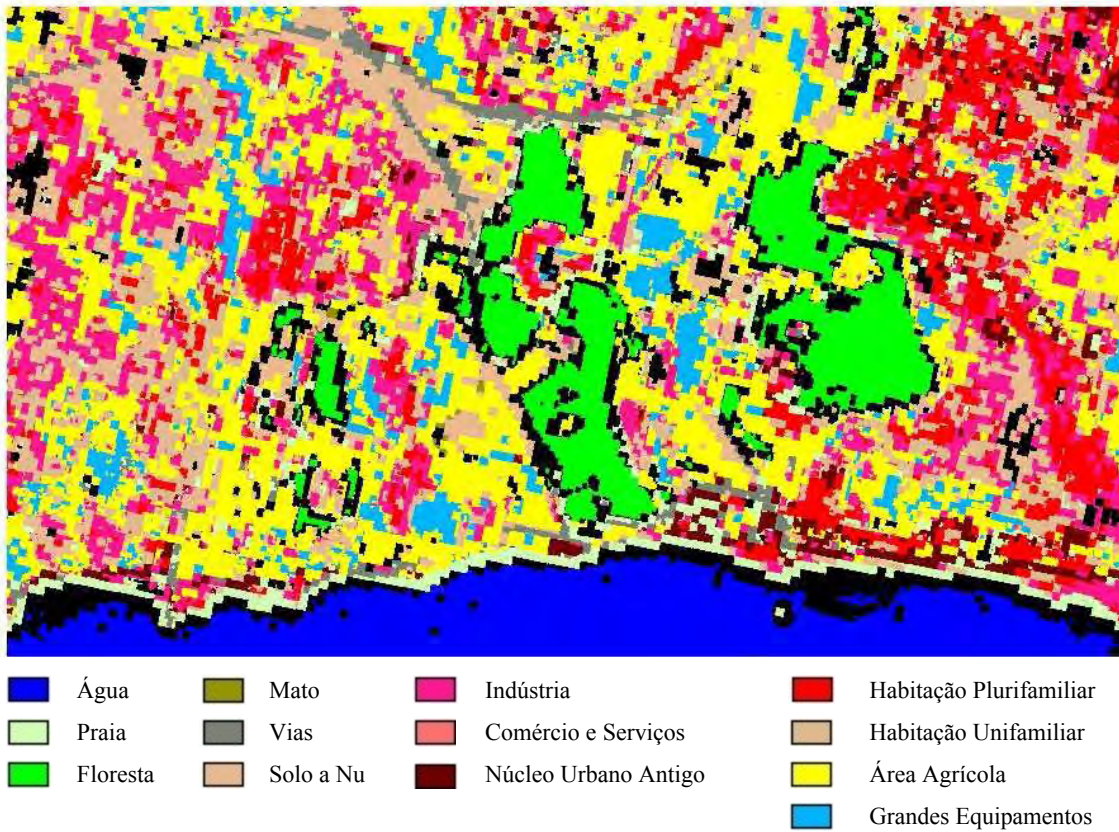


Figura 5.28 - Uso do solo obtido pelo classificador do paralelepípedo

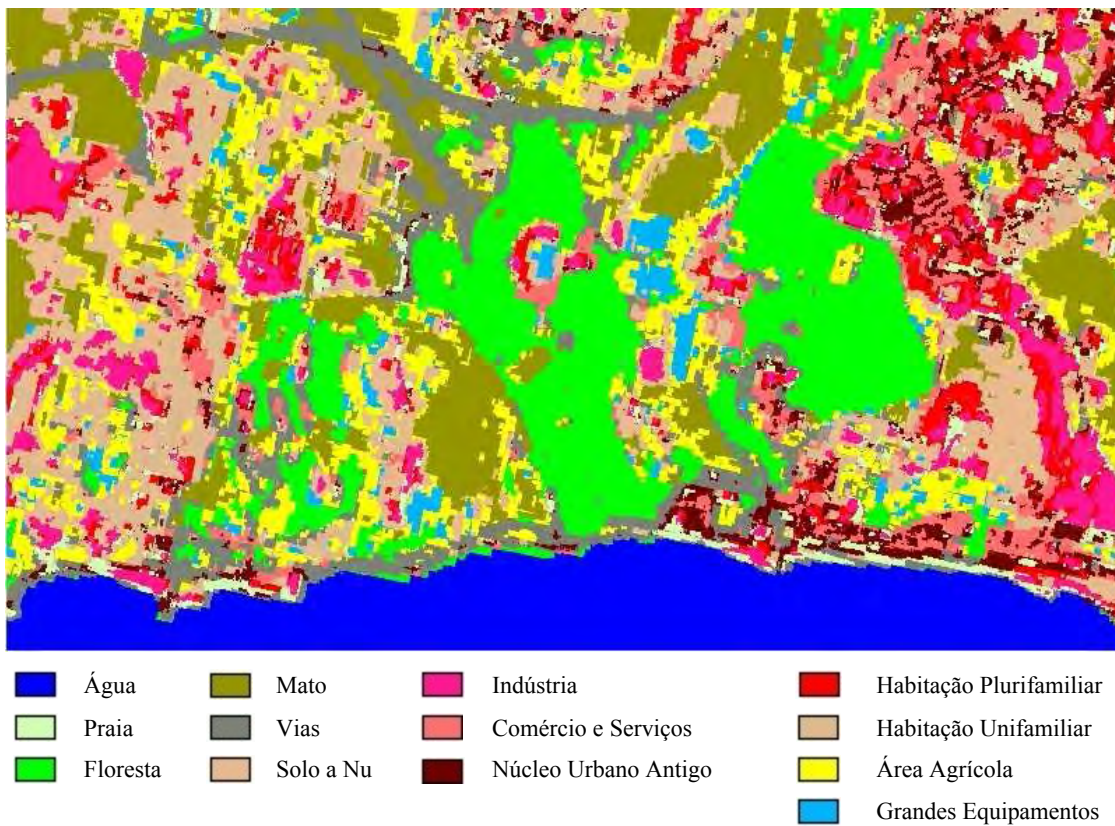


Figura 5.29 - Uso do solo obtido pelo classificador da mínima distância

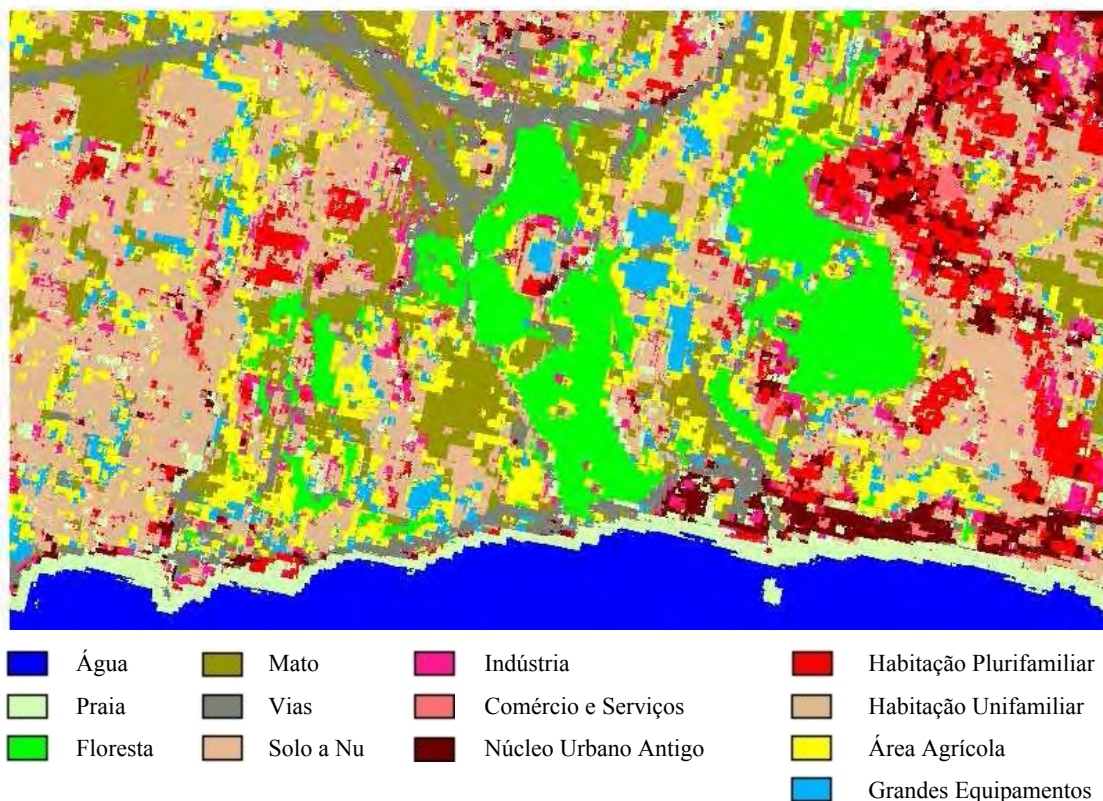


Figura 5.30 - Uso do solo obtido pelo classificador de máxima verossimilhança

Estas matrizes são quadradas, apresentando um número de linhas e colunas igual ao número de categorias cuja exactidão de classificação está a ser avaliada. Para o efeito, dispõem-se as classes correspondentes à classificação em linhas e as relativas à realidade em colunas. Os elementos bem classificados encontram-se representados ao longo da diagonal da matriz e todos os elementos situados fora da diagonal correspondem a erros de classificação. Deste modo, é possível contemplar as classes que foram adjudicadas a cada pixel, identificando-se dois tipos de erros: os de **comissão** (EC) que ocorrem quando se atribui um pixel da imagem a uma classe à qual ele não pertence (inclusão) e os de **omissão** (EO), que se traduzem em não atribuir a determinada classe um pixel que lhe pertence (exclusão). Na matriz, os erros de omissão correspondem aos elementos não diagonais de cada coluna (ex. os 16 pixéis, na figura 5.31, que deveriam ter sido classificados como “praia” não o foram) e os erros de comissão aos elementos não diagonais de cada linha (ex. na figura 5.31, 38 pixéis correspondentes à classe “urbano” e 24 pertencentes à categoria “mata” foram incorrectamente classificados como “agrícolas”).

| | | CLASSIFICAÇÃO | | | | | | | CLASSES DE USO |
|-------|-------|---------------|----|-----|-----|-----|-------|-------------|----------------|
| | | 1 | 2 | 3 | 4 | 5 | Total | | |
| CAMPO | 1 | 480 | 0 | 5 | 0 | 0 | 485 | 1. Água | |
| | 2 | 0 | 52 | 0 | 20 | 0 | 72 | 2. Praia | |
| | 3 | 0 | 0 | 313 | 40 | 0 | 353 | 3. Mata | |
| | 4 | 0 | 16 | 0 | 126 | 0 | 142 | 4. Urbano | |
| | 5 | 0 | 0 | 38 | 24 | 359 | 421 | 5. Agrícola | |
| | Total | 480 | 68 | 356 | 210 | 359 | 1473 | | |

Figura 5.31 – Exemplo de Tabela de contingências

A **exactidão global** é obtida dividindo o número total de pixéis correctamente classificados (a soma dos elementos da diagonal) pelo número total de pixéis existentes na imagem de referência. Da mesma forma, a exactidão de cada categoria pode ser obtida através do quociente entre os pixéis correctamente classificados de uma categoria e o número total de pixéis da linha ou coluna correspondente. Desta medida podem extrapolar-se dois outros indicadores conhecidos como **exactidão do produtor** (EP) e **exactidão do utilizador** (EU), os quais consideram que o primeiro está mais interessado na exactidão do processo de atribuição e o segundo na qualidade do mapa produzido, sendo calculados através das expressões:

$$EP = (1 - EO) \times 100 \quad \text{e} \quad EU = (1 - EC) \times 100. \quad (5.15)$$

Depois de calculadas, estas medidas de exactidão são normalmente sujeitas a uma interpretação mais detalhada e análises estatísticas posteriores. Com efeito, mesmo uma atribuição dos pixéis às classes feita totalmente ao acaso pode resultar numa percentagem não nula de resultados certos. Para fazer face a esta situação é costume recorrer-se a outro método para aquilatar a exactidão da classificação. Este método avalia a concordância entre o resultado da classificação, obtida através da aplicação do método desenvolvido (designada por **exactidão observada**) e uma atribuição puramente aleatória de classes aos pixéis (designada por **concordância devido ao acaso**). Esta medida de concordância é designada por **índice Kappa** (κ), **KHAT** ou **KIA** (*Kappa Index of Agreement*) sendo definido em termos dos elementos (x_{ij}) da tabela de contingências. Designado por:

$$x_{i+} = \sum_j x_{ij}, \quad (5.16)$$

o somatório de todas as colunas para a linha i , e por:

$$x_{+i} = \sum_i x_{ij}, \quad (5.17)$$

o somatório de todas as linhas para a coluna j , o índice *Kappa* é definido por:

$$\kappa = \frac{N \sum_{i=1}^l x_{ii} - \sum_{i=1}^l (x_{i+} x_{+i})}{N^2 - \sum_{i=1}^l (x_{i+} x_{+i})}, \quad (5.18)$$

onde

l - número de linhas na matriz de erro;

x_{ii} - elemento na linha i e coluna i da matriz;

N - número total de observações incluídas na matriz .

À medida que a **exactidão observada** se aproxima de 1 e a **concordância devido ao acaso** se aproxima de 0, o índice *Kappa* tende para 1. No entanto, o valor 1 representa uma situação ideal, poucas vezes observada. Como exemplo, um *Kappa* de 0,67 pode ser entendido como uma indicação de que a classificação realizada é 67% melhor que uma efectuada ao acaso. Seguindo a mesma linha de raciocínio, um *Kappa* de 0 sugere que o resultado da classificação em análise não é melhor que uma classificação dos pixels feita ao acaso. Se a concordância devida ao acaso for bastante elevada, o *Kappa* pode tomar valores negativos – uma indicação de uma classificação com um desempenho bastante mau. É também possível calcular os coeficientes de concordância condicionais (para cada classe), a partir de:

$$\kappa_i = \frac{Nx_{ii} - x_{i+} x_{+i}}{Nx_{i+} - x_{i+} x_{+i}}. \quad (5.19)$$

Os valores de *Kappa* são geralmente inferiores aos obtidos pela exactidão global. Esta diferença é esperada, em virtude de cada índice recorrer a diferentes tipos de informação existente na tabela de contingências. A exactidão global apenas utiliza os dados que se encontram ao longo da diagonal da matriz, excluindo os erros de omissão e comissão. Por outro lado, o índice *Kappa* incorpora os elementos não diagonais da matriz como um produto dos valores marginais das linhas e colunas.

Não é possível apontar de uma forma inequívoca que medida deve ser aplicada e quando. Normalmente, é desejável que se calculem e avaliem as duas.

Classificação de Imagens com Recurso a Informação não Espectral

Antes de terminar, há ainda que focar dois aspectos bastante importantes. O primeiro relaciona-se com o facto de a qualidade do cálculo de qualquer exactidão corresponder à qualidade dos dados utilizados como “*ground truth*”. Assim, sempre que possível, a estimativa dos erros inerentes aos dados de referência deve ser incorporada no processo de cálculo da exactidão. É comum a exactidão dos dados de referência ser afectada por factores como a má delimitação de áreas, erros de foto-interpretação, erros de entrada dos dados e alterações no uso e ocupação do solo entre a data da imagem de referência e a data das imagens classificadas. O segundo ponto a focar é que o processo de avaliação da exactidão deve ser formulado de maneira a reflectir os objectivos da classificação. Isto é, um pixel classificado como sapal no interior de um campo de milho pode ser pouco significativo se o objectivo for o desenvolvimento de um PDM. Por outro lado, este mesmo erro pode ser importante se o intuito da classificação for fornecer uma base para o cálculo das taxas a aplicar aos agricultores.

Relativamente ao presente estudo, e observando os resultados apresentados pelos classificadores testados (tabela 5.4), sobressai a superior prestação do método desenvolvido. Como seria de esperar, o método do paralelepípedo foi o que piores resultados apresentou, registando-se um certo equilíbrio entre os da mínima distância e máxima verosimilhança, com uma ligeira vantagem para o primeiro, face ao carácter assimétrico da distribuição dos dados.

| Classificador | Índice <i>Kappa</i> (0 - 1) | Exactidão Global (%) |
|------------------------------|------------------------------------|-----------------------------|
| Paralelepípedo | 0,18 | 20,2 |
| Mínima Distância | 0,35 | 37,8 |
| Máxima Verosimilhança | 0,33 | 36,5 |
| IDECIS | 0,67 | 70,5 |

Tabela 5.4 – Índice *Kappa* relativo a cada um dos classificadores

Analisando os resultados numa perspectiva classe a classe (tabelas 5.5 e 5.6), verifica-se que o IDECIS obtém globalmentemelhores resultados, com a excepção das classes 4 (“Mato”) e 7 (“Indústria”). O método proposto falhou completamente a classificação das áreas industriais porque, neste caso, a classificação dependia exclusivamente das regras de pós-classificação. Como a qualidade da informação existente no PDM que sustentava essas regras era deficiente, não permitiu identificar as áreas em questão.

| Classe | Paralelepípedo | | Mínima Distância | | Máxima Verosimilhança | | IDECIS | |
|------------------------------------|----------------|------|------------------|------|-----------------------|------|--------|------|
| | EO | EC | EO | EC | EO | EC | EO | EC |
| 0. Não Classificados | 0,25 | 0,00 | 0,00 | 0,00 | 0,00 | 0,00 | 0,00 | 0,00 |
| 1. Água | 0,57 | 0,00 | 0,03 | 0,02 | 0,11 | 0,00 | 0,00 | 0,00 |
| 2. Praia | 0,63 | 0,84 | 0,84 | 0,91 | 0,29 | 0,81 | 0,01 | 0,01 |
| 3. Floresta | 0,99 | 0,06 | 0,37 | 0,26 | 0,49 | 0,13 | 0,29 | 0,24 |
| 4. Mato | 0,91 | 0,23 | 0,63 | 0,19 | 0,70 | 0,27 | 0,34 | 0,24 |
| 5. Vias | 0,25 | 0,51 | 0,77 | 0,73 | 0,80 | 0,68 | 0,00 | 0,00 |
| 6. Solo a Nu | 0,82 | 0,97 | 0,64 | 0,92 | 0,42 | 0,92 | 0,45 | 0,78 |
| 7. Indústria | 0,84 | 0,97 | 0,88 | 0,96 | 0,82 | 0,91 | 1,00 | 0,00 |
| 8. Comércio e Serviços | 0,99 | 0,97 | 0,80 | 0,98 | 0,96 | 0,98 | 0,00 | 0,01 |
| 9. Núcleo Urbano Antigo | 0,88 | 0,73 | 0,83 | 0,70 | 0,83 | 0,68 | 0,01 | 0,01 |
| 10. Habitação Plurifamiliar | 0,64 | 0,78 | 0,81 | 0,80 | 0,70 | 0,76 | 0,42 | 0,60 |
| 11. Habitação Unifamiliar | 0,81 | 0,73 | 0,68 | 0,66 | 0,57 | 0,68 | 0,46 | 0,45 |
| 12. Área Agrícola | 0,33 | 0,99 | 0,80 | 0,99 | 0,48 | 0,98 | 0,73 | 0,65 |
| 13. Grandes Equipamentos | 0,85 | 0,87 | 0,84 | 0,72 | 0,82 | 0,79 | 0,68 | 0,02 |

Tabela 5.5 – Erros de comissão (EC) e omissão (EO) apresentados pelos quatro classificadores relativamente a cada uma das classes

| Classes | Mínima Distância | | | | IDECIS | | | |
|------------------------------------|------------------|------|------|------|--------|-------|-------|-------|
| | KIA | EG | EP | EU | KIA | EG | EP | EU |
| 1. Água | 0,94 | 98,5 | 94,9 | 98,6 | 0,99 | 99,9 | 99,9 | 99,9 |
| 2. Praia | 0,19 | 12,8 | 21,6 | 12,8 | 0,98 | 99,0 | 98,9 | 99,0 |
| 3. Floresta | 0,65 | 13,4 | 70,3 | 70,0 | 0,65 | 75,0 | 70,2 | 75,0 |
| 4. Mato | 0,29 | 84,6 | 38,6 | 84,6 | 0,54 | 75,9 | 65,1 | 75,9 |
| 5. Vias | 0,15 | 26,8 | 23,6 | 26,8 | 1,00 | 100,0 | 100,0 | 100,0 |
| 6. Solo a Nu | 0,18 | 14,8 | 25,1 | 14,8 | 0,48 | 21,7 | 54,3 | 21,7 |
| 7. Indústria | 0,07 | 3,6 | 11,9 | 3,6 | 0,00 | 0,0 | 0,0 | 100,0 |
| 8. Comércio e Serviços | 0,17 | 2,0 | 21,5 | 2,0 | 0,99 | 98,5 | 99,1 | 98,5 |
| 9. Núcleo Urbano Antigo | 0,13 | 25,7 | 17,0 | 25,7 | 0,98 | 98,9 | 98,7 | 98,9 |
| 10. Habitação Plurifamiliar | 0,14 | 23,0 | 18,0 | 23,0 | 0,53 | 39,3 | 57,6 | 39,3 |
| 11. Habitação Unifamiliar | 0,25 | 35,4 | 33,1 | 35,4 | 0,47 | 54,8 | 53,1 | 54,8 |
| 12. Área Agrícola | 0,13 | 0,5 | 22,3 | 0,5 | 0,26 | 34,2 | 26,9 | 34,3 |
| 13. Grandes Equipamentos | 0,12 | 24,6 | 14,6 | 24,6 | 0,30 | 97,3 | 31,8 | 97,3 |

Tabela 5.6 – Índice KIA, exactidão global (EG), exactidão do produtor (EP) e exactidão do utilizador (EU) por classe

Classificação de Imagens com Recurso a Informação não Espectral

Ainda relativamente ao IDECIS, observa-se que este melhorou a precisão global (superior a 97%) das classes onde havia informação estatística disponível, nomeadamente as classes 1, 2, 5, 8, 9 e 13. De referir ainda que a classe 5 (“Rede Viária”) tem um resultado de 100%, porque já existia em formato digital, tendo-se procedido apenas à sua conversão de vectorial para matricial. Por fim, resta referir que o classificador desenvolvido permite identificar com boa fidelidade, classes que são “invisíveis” para os satélites (ex. “Comércio e Serviços”).

Para avaliar a adaptabilidade do método desenvolvido a novas situações repetiu-se, para o efeito, todos os passos expostos ao longo deste capítulo (figura 5.32), mas para uma área diferente, situada na margem Sul do Tejo, mais propriamente no Concelho de Almada e que corresponde, grosso modo, ao arco Almada-Cacilhas. Os resultados foram bastante animadores, apresentando o IDECIS uma exactidão na ordem dos 92% (tabela 5.7).

| Classificador | Índice Kappa | Exactidão Global (%) |
|-------------------------|---------------------|-----------------------------|
| Mínima distância | 0,46 | 47,8 |
| URBANOS | 0,89 | 92,1 |

Tabela 5.7 – Coeficiente Kappa e exactidão global relativos a cada um dos classificadores para a área de verificação

A primeira hipótese avançada como justificação para estes resultados, superiores aos obtidos para a área de estudo inicial, foi a informação contida no PDM de Almada, cujo grau de desagregação, bastante superior ao seu homónimo de Oeiras, permitiu a elaboração de regras mais eficazes. Contudo, este resultado poderia estar viciado pela área de verificação, ou seja, esta área ao ser mais homogénea do que a área de teste poderia promover um resultado necessariamente melhor, dando a noção artificial de um bom desempenho por parte do classificador. Para salvaguardar esta situação, aplicou-se igualmente o classificador da mínima distância, que, embora também tenha apresentado melhores resultados (cerca de 48% como exactidão global), não teve uma melhoria tão evidente como o IDECIS.

Numa observação categoria a categoria (tabela 5.8), é possível observar-se que ambas as classificações (obtidas pelos dois métodos) melhoram em relação à área de teste. O IDECIS esteve sempre “um passo à frente” dos classificadores tradicionais; manteve a sua grande coerência para as áreas onde existe informação estatística e obteve bons desempenho sem classes como a 7 (“Indústria”), 2 (“Militar”) e 13 (“Grandes Equipamentos”) devido à discriminação semântica do PDM de Almada, que permitiu criar regras de pós-classificação mais eficientes.

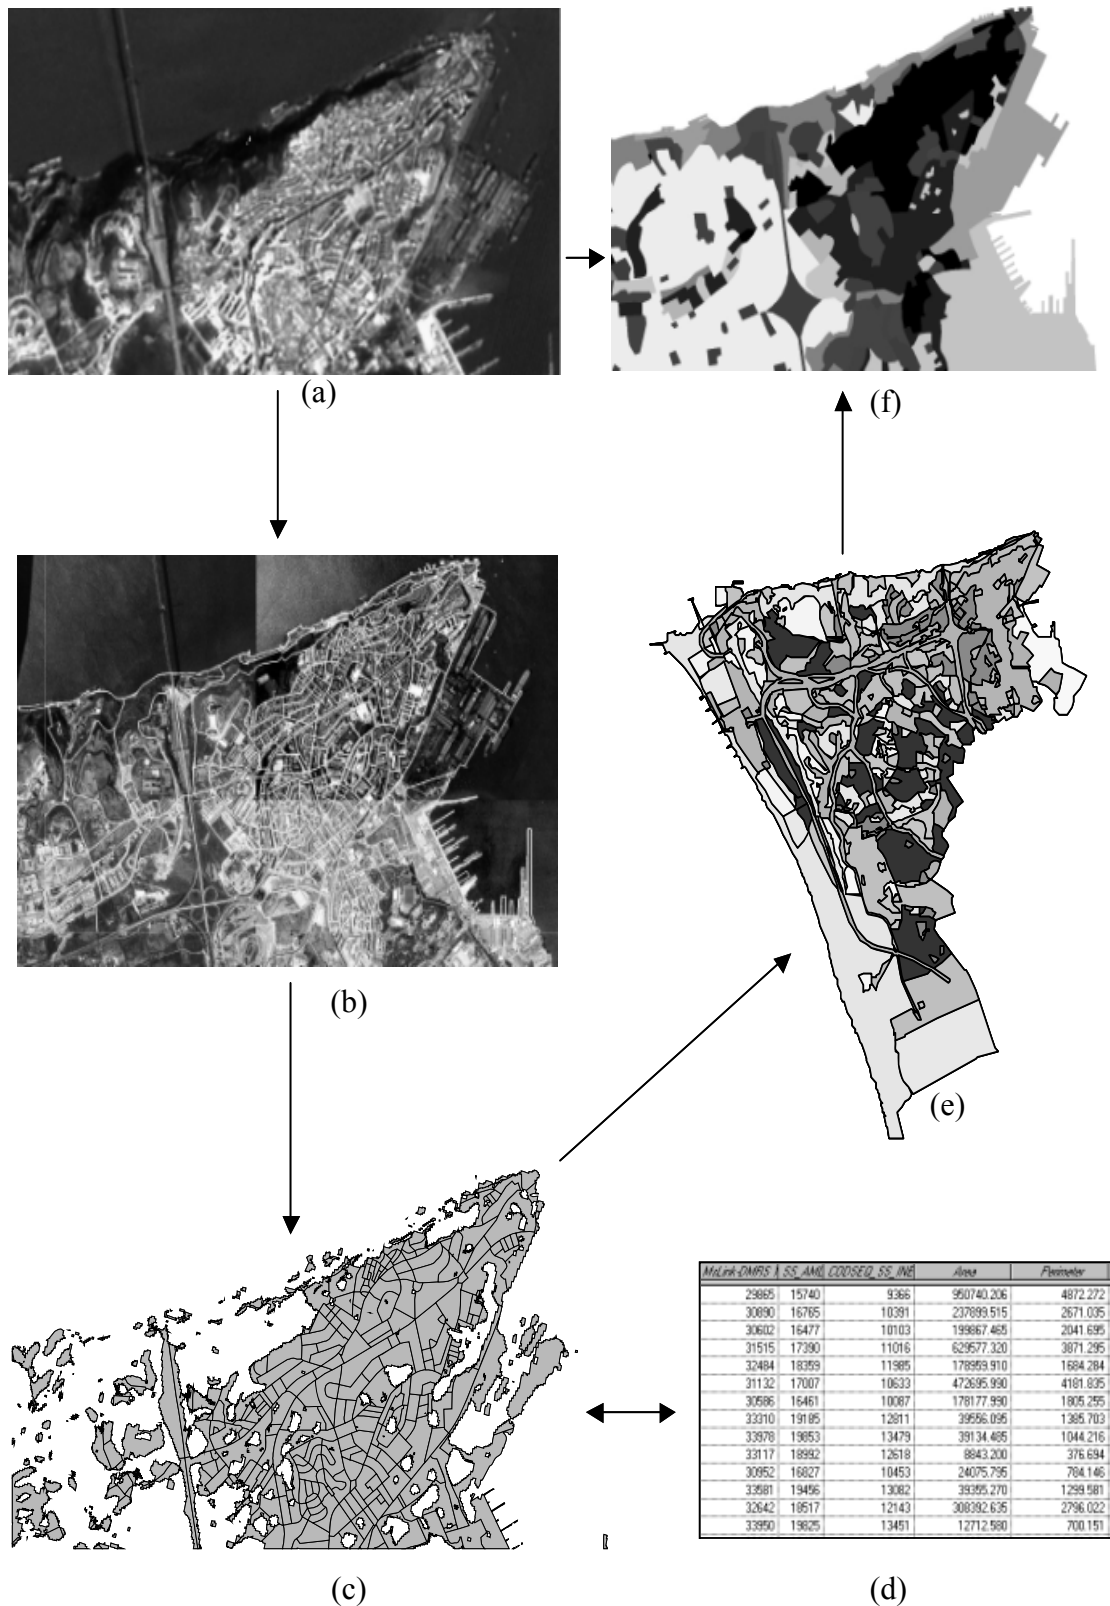


Figura 5.32 – Aplicação da metodologia proposta à área de verificação: (a) composição colorida SPOT XS; (b) sobreposição da BGRE sobre o ortofotomapa; (c) extracção das áreas “urbanas; (d) probabilidades a priori; (f) PDM; (e) classificação final.

| Classes | Mínima Distância | | | | IDECIS | | | |
|-----------------------------|------------------|------|------|------|--------|-------|-------|-------|
| | KIA | EG | EP | EU | KIA | EG | EP | EU |
| 1. Água | 0,94 | 98,5 | 94,9 | 98,6 | 0,99 | 99,9 | 99,9 | 99,9 |
| 2. Militar | 0,30 | 38,8 | 31,6 | 40,8 | 0,90 | 90,9 | 90,9 | 90,9 |
| 3. Floresta | 0,75 | 23,4 | 80,3 | 80,1 | 0,65 | 75,0 | 70,2 | 75,0 |
| 4. Mato | 0,36 | 86,6 | 42,6 | 90,6 | 0,54 | 75,9 | 65,1 | 75,9 |
| 5. Vias | 0,17 | 28,8 | 25,4 | 30,8 | 1,00 | 100,0 | 100,0 | 100,0 |
| 6. Solo a Nu | 0,20 | 20,8 | 35,1 | 24,6 | 0,60 | 71,7 | 63,2 | 71,9 |
| 7. Indústria | 0,50 | 62,6 | 70,9 | 58,7 | 0,99 | 99,9 | 99,9 | 99,9 |
| 8. Comércio e Serviços | 0,17 | 20,0 | 21,5 | 20,0 | 0,97 | 97,5 | 99,1 | 98,5 |
| 9. Núcleo Urbano Antigo | 0,52 | 60,7 | 57,0 | 62,7 | 0,99 | 99,9 | 99,7 | 998,9 |
| 10. Habitação Plurifamiliar | 0,14 | 23,0 | 18,0 | 23,0 | 0,75 | 85,0 | 80,2 | 85,0 |
| 11. Habitação Unifamiliar | 0,25 | 35,4 | 33,1 | 35,4 | 0,64 | 85,9 | 75,1 | 85,9 |
| 12. Área Agrícola | 0,18 | 22,3 | 22,6 | 21,2 | 0,26 | 34,2 | 26,9 | 34,3 |
| 13. Grandes Equipamentos | 0,12 | 24,6 | 14,6 | 24,6 | 0,96 | 96,3 | 95,4 | 97,8 |
| 14. Praia | 0,19 | 12,8 | 21,6 | 12,8 | 0,99 | 99,0 | 98,6 | 99,0 |

Tabela 5.8 – Índice KIA, exactidão global (EG), exactidão do produtor (EP) e exactidão do utilizador (EU) por classe

Noutras classes, como a “Habitação Plurifamiliar” (10) e a “Habitação Unifamiliar” (11) a melhoria deveu-se ao facto de na zona de validação a grande maioria dos edifícios afectos à primeira classe apresentarem cobertura de betão e os adstritos à segunda serem cobertos por telha; como tal, estas classes são espectralmente mais homogéneas do que na área de teste onde, principalmente no caso da “Habitação Plurifamiliar”, existia uma grande mistura de materiais. Por fim, refira-se que a classificação das “Áreas Agrícolas” foi bastante mais exacta na imagem de verificação do que na imagem inicial porque o tipo de cultura que ocorria nesta última (cereais e vegetais) é diferente do que se verificava na primeira (pomares), o qual se confundia espectralmente com a classe 3 (“Floresta”). Outras classes, como a “Praia” (14) e o “Solo a Nu” (6), também apresentaram melhores resultados na classificação da imagem de verificação, não necessariamente porque foram melhor classificados, mas porque a sua importância relativa na imagem diminuiu, face à realidade existente na imagem inicial.

5.6 CONSIDERAÇÕES FINAIS

Numa primeira perspectiva, a exactidão global obtida (principalmente na área teste) pode parecer insuficiente para considerar o método desenvolvido como uma opção válida. No entanto, há que ter em consideração que todos os factores incidiam no sentido de prejudicar a prestação do

Integração de Dados Estatísticos na Classificação de Imagens de Satélite

IDECIS. Com efeito, o mapa de uso do solo que serviu para validar os resultados corresponde ao ano de 1998 e as imagens de satélite são apenas de 1997 (Landsat) e 1995 (SPOT), havendo logo aí uma margem de erro a considerar, decorrente de possíveis alterações de uso durante esse desfasamento temporal.

Um outro problema que esta metodologia pode apresentar prende-se com o carácter cíclico (dez em dez anos) dos censos podendo estar-se a trabalhar, numa situação óptima, com dados do próprio ano ou, em oposição, com dados que apresentam um desfasamento de 10 anos relativamente à fase de recolha. No presente caso, a informação apresenta diferenças que vão de 4 a 7 anos, aproximando-se da situação mais crítica. A distância, em anos, entre os dados estatísticos e as imagens a classificar assume uma faceta crítica em casos de grandes renovações urbanas, como a que teve lugar aquando da EXPO '98, podendo apenas minimizar-se os danos provocados por esta situação com o auxílio do PDM, caso este preveja a situação (o que em Lisboa se verificava).

Para além da condicionante temporal, também há que contar com a qualidade dos Censos, pois certamente que esta informação não está isenta de erros, os quais serão incluídos no processo de classificação, com todos os efeitos nefastos que daí advêm para o resultado final. Também os PDM influenciam bastante a classificação, pois algumas regras de pós-classificação dependem deles e, por sua vez, há classes cuja exactidão da classificação depende quase integralmente dessas regras. Uma vez que não há uma legislação que forneça directivas eficazes do modo como se devem elaborar estes estudos, é possível encontrar, de concelho para concelho, várias formas de entender a figura legal que um PDM representa, verificando-se uma grande incompatibilidade de conceitos, metodologias e sobretudo conteúdos. Este factor conduz a outro dos problemas do IDECIS: as limitações geográficas. Com efeito, o método assenta nas subsecções estatísticas, estas fazem parte das secções, as secções das freguesias e assim sucessivamente. Logo, qualquer análise relativa a uma área que não corresponda a uma área delimitada estatisticamente envolve um grau de erro acrescido nas áreas limítrofes, onde seriam usadas subsecções incompletas.

As classes escolhidas também funcionam como entrave a uma melhor classificação. A opção por uma carta de ocupação e uso do solo é, no mínimo, arriscada, tendo em atenção que o conceito de uso do solo está ligado à carga social (e económica) associada à noção de território; só existe uso do solo quando existe uma sociedade organizada; caso contrário, falar-se-á de ocupação do solo, que não implica “usufruto” dos espaços funcionais (na acepção mais lata do termo). A grande maioria das aplicações cinge-se unicamente ao plano da ocupação do solo, operando assim unicamente ao nível da reflectância onde a informação proveniente das imagens

Classificação de Imagens com Recurso a Informação não Espectral

de satélite é suficiente. Na prática, isto significa que é relativamente fácil distinguir entre edifícios com cobertura de telha e de betão, mas tudo se complica quando a divisão se refere a edifícios plurifamiliares e unifamiliares, onde os segundos têm unicamente cobertura de telha mas os primeiros podem apresentar qualquer um dos dois tipos de cobertura.

Por fim, para terminar este rol de condicionantes, refere-se novamente a base de validação. Efectivamente, esta foi realizada sobre um ortofotomapa à escala 1:10 000, a qual permite um nível de detalhe bastante superior ao das imagens de satélite; por outro lado, a análise foi manual, o que implicou uma interpretação por parte do operador, traduzida numa generalização implícita à noção de área mínima cartografada. Em termos globais, o que se passa é que o foto-intérprete ao analisar, por exemplo, uma área edificada de 5000 km² com um espaço verde de 300 m² incluso, tem tendência a considerar tudo como mancha urbana, enquanto na classificação automática de imagens de satélite, mesmo que exista um só pixel com reflectância diferente, ele é adjudicado à outra classe.

6

CONCLUSÕES

As áreas urbanas englobam classes de uso espectralmente heterogéneas, inviabilizando uma classificação (correcta) com recurso unicamente a algoritmos de classificação pixel-por-pixel, sem ter em atenção as características dos pixels vizinhos.

Uma das hipóteses adiantadas para resolver este problema foi a utilização de classificadores contextuais (espaciais) que representam um método relativamente simples de examinar a variação espacial da ocupação do solo nas imagens de satélite, sendo portanto de fácil implementação. Estes modelos utilizam o contexto espacial de cada elemento de imagem no processo de reconhecimento, ou seja, utilizam a relação espacial entre elementos de imagens adjacentes para classificar um determinado elemento. Mesmo assim, nenhum desses métodos conseguiu resolver de forma satisfatória os problemas apresentados pela classificação de imagens de satélite em meio urbano. Deste modo, os analistas e investigadores que se debruçam sobre esta matéria tentaram desenvolver métodos ainda mais eficientes. É neste contexto que surge a integração entre SIG e teledeteção, permitindo maximizar a quantidade de informação disponível e as capacidades de análise, e possibilitando a combinação entre dados espectrais e

dados não espectrais, viabilizando a utilização de informação auxiliar nos processos de classificação.

Neste trabalho apresenta-se precisamente uma nova metodologia de integração de informação não espectral na classificação de imagens de satélite. Esta metodologia assenta numa classificação por níveis, fazendo uso da informação auxiliar nas três fases do processo de classificação: estratificação de pré-classificação, aplicação dos classificadores, discriminação de pós-classificação. Depois de concluídos todos os processos de investigação e experimentação retiraram-se algumas conclusões, que podem ser esquematizadas em quatro pontos:

1) A **estratificação pré-classificação** permitiu uma clara separação das classes terra/água e urbano/não urbano, ao passo que a utilização do **classificador de Bayes** possibilitou, *per si*, a obtenção de melhores resultados do que os classificadores clássicos. Por fim, com este conjunto de dados foi possível estabelecer **regras de pós-classificação** que, mediante a sua aplicação, permitiram uma zonagem mais eficaz. Ao nível da cidade estas regras consistem em definir restrições que apontam para um determinado uso.

2) O **resultado final** do método desenvolvido conduziu a uma melhoria de cerca de 34% na exactidão geral da classificação, medidos através do índice *Kappa*, relativamente a outros processos de classificação (mínima distância e máxima verosimilhança). Além disso, provou-se não ser dependente da área de trabalho pois ao ser aplicado a uma outra área de teste obtiveram-se ainda melhores resultados, correspondendo a um aumento de cerca de 45% na exactidão global, relativamente ao desempenho demonstrando pelos classificadores tradicionais na mesma área e 20% face ao que o mesmo método conseguiu na primeira zona.

3) O **principal problema** centrou-se na **integração SIG-Teledeteção**, na medida em que o primeiro opera preferencialmente em formato vectorial e o segundo é eminentemente matricial, obrigando a uma conversão entre formatos que, apesar dos avanços que se têm feito sentir, ainda coloca alguns problemas, nomeadamente ao nível da perda de informação e/ou precisão. Um outro aspecto que poderá condicionar a implementação desta metodologia prende-se com a **(in)disponibilidade da informação** e com o seu **custo**; se no caso dos dados dos censos, a informação está disponível mas é demasiado cara para o comum dos utilizadores já a planta do PDM é pertença de cada município e só poderá ser utilizada mediante autorização (que pode não ser concedida). Foi ainda, possível constatar, que o método está muito dependente da qualidade da informação auxiliar, como provam os resultados obtidos na área de verificação.

Conclusão

4) Em termos de **futuro**, prevê-se que a inclusão da informação não espectral nas suas três vertentes (pré-processamento, classificação e pós-classificação) continuará na vanguarda, já a vertente espectral tenderá a ser avaliada através da aplicação de classificação com incerteza (**fuzzy**), em detrimento dos métodos até aqui mais usados, como o da mínima distância e máxima verosimilhança. Por fim, toda a informação disponível, bem como as regras de pós-classificação serão integradas com tecnologia proveniente do campo dos **sistemas periciais**, sejam modelos de bases de conhecimento (lógica de predicados) ou redes neuronais.

7

BIBLIOGRAFIA

- [1] Achen, M. – “Landsat TM Data for Municipal Environment Planning. Studies of Vegetation Indices on Urban Areas”, *Proceedings of the XVII ISPRS congress*, vol. 19, Washington, 1992.
- [2] Angel, S. – “Bangkok Land Management Study”, *The Land and Housing Markets of Bangkok-strategies for Public Sector Participation*, National Housing Authority, Bangkok, 1987.
- [3] Atkinson, P. M. e Tatnall, A. R. L. – “Neural Networks in Image Classification”, *International Journal of Remote Sensing*, n° 18, 1997, pp. 699-551.
- [4] Ball, G. H. e Hall, D. J. – *A Novel Method of Data Analysis and Pattern Classification*, Stanford Research Institute, California, 1965.
- [5] Barnsley, M. J. e Barr, S. L. – “Inferring Urban Land Use From Satellite Sensor Images Using Kernel-Based Spatial Reclassification”, *Photogrammetric Engineering and Remote Sensing*, vol. 62, n° 8, 1996, pp. 949-958.

- [6] Barnsley, M. J. et al – “Analytical tools to monitor urban areas”, *Geographical Information Handling – Research and Applications*, Edited by P. Mather, Chichester, John Wiley & Sons, 1993, pp. 147-184.
- [7] Bezdek, M. et al – “The fuzzy C-Means Clustering Algorithm”, *Computer and Geosciences*, nº 10, 1984, pp. 191-203.
- [8] Bruzzone, S. et al “Multisource Classification of Complex Rural Areas by Statistical and Neural Network Approaches”, *Photogrammetric Engineering and Remote Sensing*, nº 63, 1997, pp. 523-533.
- [9] Bryant, J. – “Applications of Clustering in Multi-image Data Analysis”, NASA Report nº 18, Contract NAS-9-14689-8S, Johnson Space Centre, Houston, NASA, 1978.
- [10] Caetano, M., Santos, J. P. e Navarro, A. – “Uma Metodologia Integrada para Produção de Cartas de Uso do Solo Utilizando Imagens de Satélite e Informação Geo-referenciada não Espectral”, *Cartografia e Cadastro*, nº 6, 1997, pp. 71-78.
- [11] Campbell, J. B. – *Introduction to Remote Sensing*, New York, Guilford, 1987.
- [12] Casaca, J., Matos, J. e Baio, M. – *Topografia Geral*, Lisboa, Lidel, 2000.
- [13] Chehdi, K. e Liao, Q. M. – “Segmentation Method for Satellite Image Interpretation Application to the Forest of Paimpont (Brittany)”, *Photo Interprétation*, nº 19, 1994, pp. 65-74.
- [14] Cihlar, J. e Protz, R. – “ Perception of Tone Differences from Film Transparencies”, *Photogrammetria*, nº 8, 1972, pp. 131-140.
- [15] Cihlar, J. et al – “Classification by Progressive generalization: A New Methodology for Remote Sensing Multi Channel Data”, *International Journal of Remote Sensing*, vol. 19 nº 14, 1998, pp. 2685-2704.
- [16] Derin, P. et al – “Bayes Smoothing Algorithms for Segmentation of Binary Images Modeled by Markov Radom Fields”, *IEEE Trans. On Pattern anal. Machine Intell*, vol. PAMI-6, nº 6, 1984, pp. 107-720.
- [17] Duda, R. O. e Hart, P. E. – *Pattern Classification and Scene Analysis*, New York, John Wiley & Sons, 1973.
- [18] Ehlers, M. et al – Application of SPOT Data for Regional Growth Analysis and Local Planning”, *Photogrammetric Engineering and Remote Sensing*, vol. 56, nº 2, 1990, pp. 175-180.
- [19] Fisher, P. F. e Pathirana, S. – “Urban Boundary Detection from Landsat Imagery: A GIS and Knowledge-based approach to MSS data. Agenda for the 90’s”, *Technical papers, ASPRS/ACSM Annual Convection*, Bethesda, MD: ASPRS/ACSM, 1989, pp. 93-101.
- [20] Foin, P. – *Cours de Télédétection*, vol. I, ENSG, Paris, 1988.
- [21] Fonseca, A. M. – *Aquisição de Informação Geográfica por Sensores Remotos Orbitais, seu Processamento e Exploração*, Lisboa, LNEC, 1993.

Bibliografia

- [22] Fonseca, A. M. – *Análise Quantitativa de Imagens: Utilização de Imagens Numéricas Multiespectrais no Controlo do Desenvolvimento Urbano*. Dissertação de Doutoramento. Edição I&D, Teses - Barragens, Lisboa, LNEC, 1999.
- [23] Foody, G. M. e Arora, M. K. – “An Evaluation of Some Factors Affecting the Accuracy of Classification by an Artificial Neural Network”, *International Journal of Remote Sensing*, nº 18, 1997, pp. 799-810.
- [24] Foody, G. M. et al – “Derivation and applications of Probabilistic Measures of Class Membership from Maximum-likelihood Classification”, *Photogrammetric Engineering and Remote Sensing*, nº 58, 1992, pp. 1335-1341.
- [25] Foody, G. M. – “Cross-entropy for the Evaluation of the Accuracy of a Fuzzy Land Cover Classification with Fussy Ground Data”, *ISPRS Journal of Photogrammetry and Remote Sensing*, nº 50, 1995, pp. 2-12.
- [26] Forster, B. C. – “An Examination of Some Problems and Solutions in Monitoring Urban Areas from Satellite Platforms”, *International Journal of Remote Sensing*, nº 6, 1985, pp. 139-151.
- [27] Francos J. M. e Meiri A. Z. – “A 2-D Autoregressive, Finite Support, Casual Model for Texture Analysis and Synthesis ”, *ICASSP*. Glasgow, vol. 3, 1989, pp. 1552-1555.
- [28] Gong, P. e Howarth, P. J. – “The Use of Structural Information for Improving Land-Cover Classification Accuracies at the Rural-Urban Fringe”, *Photogrammetric Engineering & Remote Sensing*, nº 56, 1990, pp. 67-73.
- [29] Gong, P. e Howarth, P. J. – “Frequency-Based Contextual Classification and Gray-Level Vector Reduction for Land-Use Identification”, *Photogrammetric Engineering and Remote Sensing*, nº 58, nº 4, 1992, pp. 423-437.
- [30] Gong, P. et al– “Application of satellite and GIS Technologies for Land-Cover and Land-Use at the Rural Urban Fringe: A Case Study”, *Photogrammetric Engineering and Remote Sensing*, nº 58, nº 4, 1992, pp. 439-448.
- [31] Haack, B., Bryant, N. e Adams, S. – “An Assessment of Landsat MSS and TM Data for Urban and Near-Urban Land-Cover Digital Classification”, *Remote Sensing of Environment*, nº 21, 1987, pp. 201-213.
- [32] Haralick, R. M. e Shapiro, L. – “Survey-Image Segmentation Techniques”, *Computer Vision, Graphics, and Image Processing*, vol. 29, 1985, pp. 100-132.
- [33] Haralick, R. M. – “Statistical and Structural Approaches to Texture”, *Proceedings IEEE*, Vol. 67, nº 5, 1979, pp. 786-804.
- [34] Harris P. e Ventura, J. – “The Integration of Geographic Data With Remotely Sensed Imagery to Improve Classification in an Urban Area”, *Photogrammetric Engineering and Remote Sensing*, nº 61, nº 8, 1995, pp. 993-998.

- [35] Jähne, B. – *Digital Image Processing – Concepts, Algorithms and Scientific Applications*, 4th Edition, Berlin, Springer, 1997.
- [36] Jayamanna, S. B. – “Relation Between Social and Environmental Conditions in Colombo, Sri Lanka and the Urban Index Estimated by Satellite Remote Sensing Data”, *Proceedings of the XVIII ISPRS congress*, Austria, 1996.
- [37] Jeng F. C. e Woods J. W. – “Texture Discrimination Using Doubly Stochastic Gaussian Random Fields”, *ICASSP*, Glasgow, vol. 3, 1989, pp. 1675-1678.
- [38] Jensen, J. R. e Toll, D. L. – “Detecting Residential Land Use Development at the Urban Fringe”, *Photogrammetric Engineering and Remote Sensing*, n° 48, 1982, pp. 629-643.
- [39] Kanellopoulos, I. e Wilkinson, G. G. – “Strategies and Best Practice for Neural Network Image Classification”, *International Journal of Remote Sensing*, n° 18, 1997, pp. 711-725.
- [40] Kavzoglu, T. e Mather, P. M. – “Pruning Artificial Neural Networks: An Example Using Land Cover Classification of Multi-Sensor Images”, *International Journal of Remote Sensing*, vol. 20, n° 14, 1999, pp. 2787-2809.
- [41] Langford, M. et al – “The aerial interpolation problem: estimating population using remote sensing in a GIS framework”, *Handling Geographical Information: Methodology and Potential Applications*, Edited by I. Masser and M. Blakemore, Harlow, Langman, 1991 pp. 55-77.
- [42] Lillesand, T. M. e Kiefer, R. W. – *Remote Sensing and Image Interpretation*, John Wiley & Sons, New York, 1994.
- [43] Machado, J. R. et al – “Os Planos Directores Municipais da Área Metropolitana de Lisboa. Emergência de uma Futura Base de Dados para um novo Planeamento Regional”, *Proceedings do ESIG/97*, Junho, Lisboa, 1997.
- [44] Mannan, J. et al – “Fuzzy ARTMAP Supervised Classification of Multi-Spectral Remotely-Sensed Images”, *International Journal of Remote Sensing*, vol. 19, n° 4, 1998, pp. 767-774.
- [45] Martin, L. R. G., Howarth, P. J. e Holder, G. – “Multispectral Classification of Land Use at the Rural-Urban Fringe Using SPOT Data”, *Canadian Journal of Remote Sensing*, n° 14, 1988, pp. 72-79.
- [46] Mather, P. – “A computationally-efficient maximum likelihood classifier employing prior probabilities for remotely-sensed data”, *International Journal of Remote Sensing*, n° 6, 1985, 369-376.
- [47] Matos, J. L. – “Fundamentos de Informação Geográfica”, Lisboa, Lidel, 2001.
- [48] Matsuyama, T., Saburi, K. e Nagao, M. – “A Structural analyser for Regularly Arranged Textures”, *G.G.I.P.*, n° 18, 1982, pp. 259-278.
- [49] Messev, T. – “The Use of Census Data in Urban Classification”, *Photogrammetric Engineering and Remote Sensing*, n° 64, 1998, pp. 431-438.

Bibliografia

- [50] Messev, T., Longley P. e Batty, M. – “RS/GIS and the Morphology of Urban Settlements”, *Spatial Analysis: Modelling in a GIS Environment*, Edited by P. Longley e M. Batty, Cambridge, GeoInformation International, 1996, pp. 123-148.
- [51] Moller-Jensen, M. – “Knowledge-Based Classification of an Urban Area Using Texture and Context Information in Landsat-TM Imagery”, *Photogrammetric Engineering and Remote Sensing*, vol. 56, nº 6, 1990, pp. 899-904.
- [52] Navarro, A., Caetano, M., Santos, J. – “Cartografia de áreas urbanas com base em dados de Detecção Remota”, *Actas da conferência de Cartografia e Geodesia*, Faculdade de Ciências da Universidade de Lisboa, 1996.
- [53] Nellis, J. et al – “Interfacing Geographic Information Systems and Remote Sensing for Rural Land-Use Analysis”, *Photogrammetric Engineering and Remote Sensing*, vol. 56, nº 3, 1990, pp. 329-331.
- [54] Paola, J. D. e Schowengerdt, R. A. – “The effect of Neural- Network Structure on a Multispectral Land Use/Land Cover Classification”, *Photogrammetric Engineering and Remote Sensing*, nº 63, 1997, pp. 535-544.
- [55] Peixoto, J. P. – “A Radiação Solar e o Ambiente”, Comissão Nacional do Ambiente, Lisboa, 1981.
- [56] Quarmby, N. A. e Cushine, J. L. – “Monitoring Urban Land Cover Changes at the Urban Fringe from SPOT HRV Imagery in South East England”, *International Journal of Remote Sensing*, nº 10, 1989, pp. 953-963.
- [57] Rees, W. G. – *Physical Principles of Remote Sensing*, 2nd Edition, Cambridge, Cambridge University Press, 2001.
- [58] Richards, J. A. e Jia, X. – *Remote Sensing Digital Image Analysis: An Introduction*, 3rd Edition, Berlin, Springer, 1999.
- [59] Robinson A. H. et al – “Elements of Cartography”, 6th Edition, New York, John Wiley & Sons, 1995.
- [60] Rocha, J. et al – “Teledetecção e Ambiente: Integração de Informação Geográfica Proveniente de Sensores Remotos Orbitais no Estudo da Rede de Corredores Verdes na Área Metropolitana de Lisboa”, *Inforgeo*, nº 12 & 13, APG/Edições Colibri, Lisboa, 1998, pp. 551-558.
- [61] Rocha, J. – “Classificação de imagens de satélite com recurso a informação não espectral”, *GeoINova*, número 4, DGPR – FCSH – UNL, Lisboa, 2001, pp. 159-186.
- [62] Rocha, J. e Tenedório, J. A. – “Integrating Demographic GIS and Multisensor Remote Sensing Data in Urban Land Use/Cover Maps Assembly”, *IEEE/ISPRS Joint Workshop on Remote Sensing and Data Fusion over Urban Areas*, Rome, 2001, pp. 46-51.
- [63] Rocha, J. e Queluz, M. P. – “Integration of Census Data, Remote Sensing and GIS Techniques for Land Use and Cover Classification”, *SPIE – 8th International Symposium*

Integração de Dados Estatísticos na Classificação de Imagens de Satélite

- on Remote Sensing, Remote Sensing for Environmental Monitoring, GIS Applications, and Geology*, Toulouse, 2001, pp. 73-83.
- [64] Rocha, J. e Tenedório, J. A. – “Producing Land Use/Cover Maps with the Integration of Remote Sensing and Ancillary Data in a GIS Environment” *12th European Colloquium on Theoretical and Quantitative Geography*, St Valery-en-Caux (França), 2001.
- [65] Rocha, J., Queluz, M. P. e Tenedório, J. A. – “Classificação de Imagens de Satélite com Recurso a Informação Multi-fonte e Multi-resolução.”, *IV Congresso da Geografia Portuguesa*, Lisboa, 2001.
- [66] Rollet, J. et al – “Image Classification algorithm based on the RBF Neural Networks and K-Means”, *International Journal of Remote Sensing*, vol. 19, nº 15, 1998, pp. 3003-3009.
- [67] Sabins, F. F. – *Remote Sensing, principles and Interpretation*, 3rd Edition, New York, W. H. Freeman and Company, 1997.
- [68] Sadler G. J. e Barnsley, M. J. – “Use of Population Density Data to Improve Classification Accuracies in Remotely-Sensed Images of Urban Areas”, *Proceedings of the First European Conference on Geographical Information Systems (EGIS’90)*, Amsterdam, The Netherlands, 10-13 April, Utrecht, EGIS Foundation, 1990, pp. 968-977.
- [69] Santos, J. et al – “Integração da Informação Contextual na Identificação de Classes de Uso do Solo em Dados de Imagens de Satélite”, *Actas da Conferência de Cartografia e Geodesia*”, Faculdade de Ciências da Universidade de Lisboa, Lisboa, 1996.
- [70] Srinivas C. e Srinath M. D. – “Compound Gauss Markov Random Field Model for Image Segmentation and Restoration”, *ICASSP*, Glasgow, vol. 3, 1989, pp. 1586-1589.
- [71] Strahler, A. – “The use of prior probabilities in maximum likelihood classification of remotely-sensed data”, *Remote Sensing of the Environment*, nº 10, 1980, pp. 135-163.
- [72] Sunar, F. e Musaoglu, N. – “Merging Multiresolution SPOT P and Landsat TM data: The effects and Advantages”, *International Journal of Remote Sensing*, vol. 19, nº 2, 1998, pp. 219-224.
- [73] Tan, T. N. et al – “Texture Feature Extration Based on Primitive Analysis”, *ICASSP*, Glasgow, vol. 3, 1989, pp. 1683-1686.
- [74] Tenedório, J. A. et al – "Uma cadeia de tratamento rápido de informação geográfica proveniente dos satélites SPOT HRV e LANDSAT TM, ao serviço da rede de corredores verdes para a Área Metropolitana de Lisboa", *Proceedings ESIG/97*, Lisboa, 1997.
- [75] Tenedório, J. A. – *Télé-détection en Milieu Périurbain – Détection et Localisation de Changement de l’Occupation du Sol par Intégration des Données-Satellite SPOT HRV dans un Système d’Information Géographique*. Tese de Doutoramento, Universidade de Paris XII, 1998, p. 254, (dados não publicados).

Bibliografia

- [76] Tenedório, J. A. et al – "Delimitação de corredores verdes por integração Detecção Remota-SIG", *Actas do ESIG'99 - V Encontro sobre Sistemas de Informação Geográfica*, USIG, Oeiras, 1999.
- [77] Tenedório, J. A. et al – "Integração Detecção Remota - Sistemas de Informação Geográfica: Para Quê? Como?", *Actas do VIII Colóquio Ibérico de Geografia*, Volume II, DGPR-UNL, Lisboa, 1999, pp. 702-710.
- [78] Townshend, P. et al – "The 1 Km Resolution Global Data Set: Needs of the International Geosphere Biosphere Programme", *International Journal of Remote Sensing*, nº 15, 1994, pp. 3417-3441.
- [79] Van der Meer, F. – "What Does Multisensor Image Fusion Add in Terms of Information Content for Visual Interpretation?", *International Journal of Remote Sensing*, vol. nº 18, nº 2, 1997, pp. 445-452.
- [80] VanderZee, D. e Ehrlich, D. – "Sensitivity of ISODATA to Changes in Sampling Procedures and Processing Parameters When Applied to AVHRR Time-series NDVI data", *International Journal of Remote Sensing*, nº 16, 1995, pp. 673-686.
- [81] Wang, F. – "Improving Remote Sensing Image Analysis Through Fuzzy Information Representation", *Photogrammetric Engineering and Remote Sensing*, nº 56, 1990 pp. 1163-1169.
- [82] Weber, C. e Hirsch, J. – "Some Urban Measurements from SPOT Data: Urban Life Quality Indices", *International Journal of Remote Sensing*, nº 13, 1992, pp. 3251-3261.
- [83] Welch, R. – "Spatial Resolution Requirements for Urban Studies", *International Journal of Remote Sensing*, nº 2, 1982, pp. 139-146.
- [84] Wood, T. F. e Foody, G. M. – "Using Cover-type likelihood's and Typicality's in a Geographic Information System Data Structure to Map Gradually Changing Environments" *Landscape Ecology and GIS*, Edited by R. Haines Young, D. R. Green and S. H. Cousins, London, 1993, pp. 141-146.
- [85] Zhang, J. e Foody, G. M. – "A Fuzzy classification of sub-urban Land Cover from Remotely Sensed Imagery", *International Journal of Remote Sensing*, vol. 19, nº 14, 1998, pp. 2721-2738
- [86] Zhang, Y. – "A New Merging Method and its Spectral and Spatial Effects", *International Journal of Remote Sensing*, vol. 20, nº 10, 1997 pp. 2003-2014.



ANEXO 1

POSIÇÃO DO SATÉLITE NA ÓRBITA

A posição de um satélite na sua órbita, especificada pela **anomalia verdadeira** (entre $-\pi/2$ e $+\pi/2$), está relacionada com o tempo (t) desde que o satélite passou pelo perigeu (T) através da equação:

$$\frac{t}{T} = \frac{1}{\pi} \arctan \frac{(1-e) \tan \frac{A(t)}{2}}{\sqrt{1-e^2}} - \frac{e}{2\pi} \frac{\sqrt{1-e^2} \sin A(t)}{1+e \cos A(t)}. \quad (1)$$

No entanto, a equação (1) apresenta o inconveniente de fornecer o tempo em função da posição e os analistas estão, normalmente, mais interessados em saber a posição em função do tempo. Infelizmente, esta equação não é analiticamente invertível, ou seja, não pode ser rescrita em função de $A(t)$. Pode, no entanto, ser invertida numa expansão em série que é bastante útil

Anexo I

quando se trabalha com baixos valores de excentricidade, como se encontra representado na equação (2):

$$A(t) = \frac{2\pi t}{T} + 2e \operatorname{sen}\left(\frac{2\pi t}{T}\right) + \frac{5e^2}{4} \operatorname{sen}\left(\frac{4\pi t}{T}\right) + \dots \quad (2)$$

A utilização dos três primeiros termos da equação (3.11) resulta num erro máximo de $A(t)$ na ordem dos $4e^3/3$ radianos.

A maioria dos satélites artificiais utilizados em teledetecção são colocados em órbitas nominalmente circulares. Essas órbitas apresentam valores de excentricidade bastante baixos, tipicamente inferiores a 0,01, o que permite assumir (para simplificar os cálculos) que $e = 0$. Assim sendo, as equações (1) e (2) mostram que T aumenta uniformemente com o tempo.

A posição do satélite no espaço costuma ser especificada por seis variáveis, também conhecidas como os **elementos Keplerianos da órbita**. Destas, as três primeiras (Ω , i , Φ) são ângulos e determinam a posição da órbita face ao sistema de coordenadas celestes (figura 3.8), pelo que são denominados ângulos de orientação. Os quarto (a) e quinto (e) parâmetros (semieixo maior e primeira excentricidade, respectivamente) determinam as dimensões da órbita e o sexto (T) indica o período orbital [12]. Para órbitas circulares, o número de parâmetros necessários para determinar a posição do satélite na sua órbita passa a ser quatro, pois a excentricidade é zero e a órbita não tem perigeu. Assim, e tendo sido já definido o período orbital (T), resta definir a **ascensão recta do nodo ascendente** (Ω), a **inclinação orbital** (i) e o **argumento do perigeu** (Φ).

Para definir com clareza os ângulos de orientação torna-se necessário introduzir alguns conceitos de astronomia. Desta forma, a circunferência resultante da intersecção entre o plano orbital terrestre e a esfera celeste¹, a qual corresponde ao caminho aparente do Sol na esfera celeste ao longo do ano, segundo o qual este se desloca do hemisfério sul para o hemisfério norte, será doravante referida como **eclítica** (assim chamada por que os eclipses ocorrem quando a Lua, cheia ou nova, se encontra sobre essa linha).

¹ Considera-se a esfera celeste um modelo de céu formado pela superfície de uma esfera, imaginária, centrada na Terra. Todos os astros (Sol, Lua, planetas, estrelas, cometas, etc.) estão localizados sobre a esfera celeste. O seu raio é considerado muito maior do que as dimensões da Terra. Apesar das distâncias de diferentes astros à Terra variarem, todos são considerados como situados sobre a esfera, tendo, portanto, uma posição aparente sobre esta.

O plano da eclíptica faz um ângulo de aproximadamente $23,5^\circ$ ($23^\circ 29'$) com o **equador celeste** (intersecção do plano do equador terrestre com a esfera celeste). Este ângulo varia ligeiramente ao longo do tempo, sendo designado por **obliquidade da eclíptica** (ε). A intersecção entre os dois planos referentes ao equador celeste e à eclíptica forma uma recta de direcção aproximadamente constante ao longo de cada período orbital da Terra, vulgarmente conhecida por **linha dos equinócios** (figura 1). Os dois pontos de intersecção entre a linha dos equinócios e a esfera celeste são chamados **pontos equinociais**. O ponto obtido através da intersecção no sentido da constelação de Áries (Carneiro) é conhecido por **primeiro ponto de Áries**, por **equinócio vernal**, ou ainda por **ponto vernal** (γ). A intersecção da linha dos equinócios com a esfera celeste, no sentido oposto ao do ponto vernal é vulgarmente designada por **ponto Libra** (Ω). A linha aproximadamente paralela à linha das áspides da órbita terrestre, perpendicular à linha dos equinócios e que passa pelo centro de massa da Terra, é chamada de **linha dos solstícios**. Por fim, para a definição dos parâmetros orbitais é ainda necessário entrar em consideração com a **linha dos nodos da órbita**, que não é mais que a linha que une os pontos de intersecção do plano equatorial celeste com o plano da órbita do satélite. Estes pontos de intersecção chamam-se **nodos da órbita**, diferenciando-se em **nodo ascendente e descendente**, onde o satélite passa para de Norte para Sul e de Sul para Norte do equador, respectivamente.

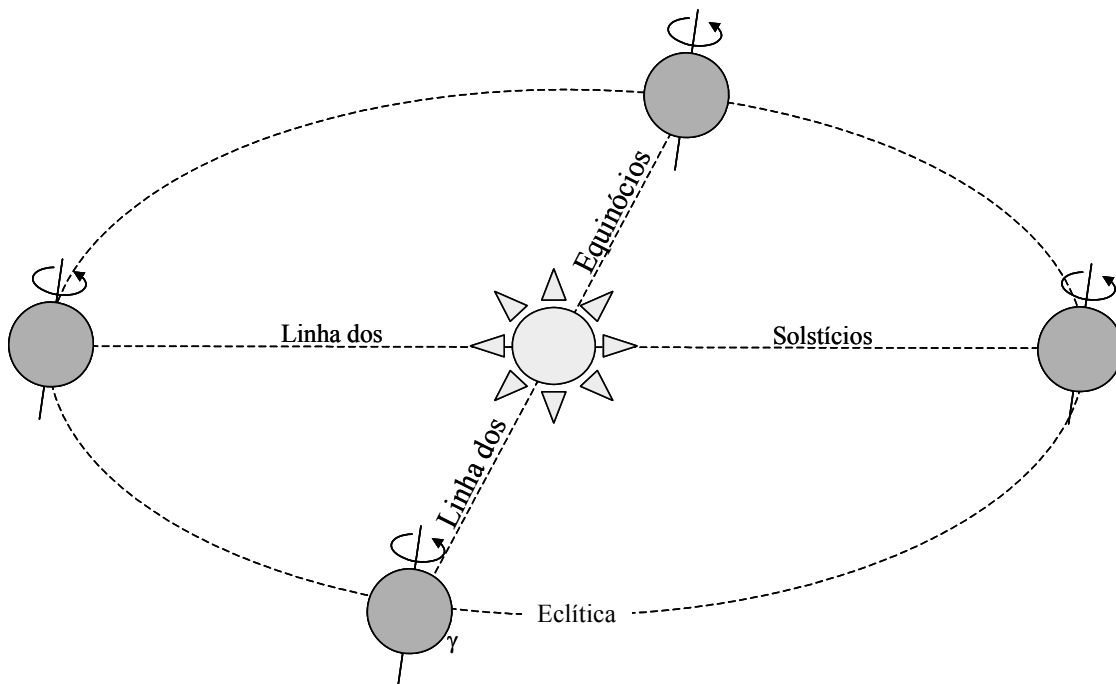


Figura 1 – Órbita terrestre

Posto isto, é agora possível definir os três ângulos de orientação de uma forma mais pormenorizada. Assim tem-se (figura 2):

Anexo 1

1) **Ascensão recta do nodo ascendente** (Ω) – ângulo medido no plano equatorial entre o eixo dos xx (linha dos equinócios) e o nodo ascendente. É pois o ângulo contado positivamente e no sentido inverso ao dos ponteiros do relógio entre o ponto vernal e a direcção do nodo ascendente.

2) **Inclinação orbital** (i) – ângulo formado pelo plano da órbita (normal à órbita orientada de forma a que se veja o satélite a avançar no sentido directo) e o plano do equador (linha dos pólos), contado positivamente a partir do equador e podendo variar entre 0° e 180° . Este valor será inferior a 90° se a órbita do satélite se processar no sentido directo (mesmo sentido que a direcção da Terra – **órbita progressiva**) e superior caso a órbita se efectue no sentido inverso (**órbita retrógrada**). Uma órbita polar exacta, em que o satélite passa exactamente sobre os pólos terrestres, tem uma inclinação de 90° . As órbitas equatoriais exactas são aquelas com uma inclinação de 0° , considerando-se como quase equatoriais as que têm uma inclinação inferior a 40° e quase polares as cuja inclinação varia entre 50° e 130° . As órbitas quase polares são as que permitem uma maior cobertura da superfície da Terra, sendo frequentemente associadas a órbitas de baixa altitude. Contudo, é normalmente mais dispendioso colocar um satélite numa órbita quase polar do que numa órbita progressiva, porque neste último caso se pode tirar vantagem (durante a fase de lançamento) do efeito de rotação da Terra.

3) **Argumento do perigeu** (Φ) – ângulo observado sobre o plano orbital entre a linha dos nodos e a linha das áspides da órbita, ou seja é contado positivamente na mesma direcção do movimento orbital (movimento do satélite) e está compreendido entre o nodo ascendente e o perigeu, variando entre 0 e 360° .

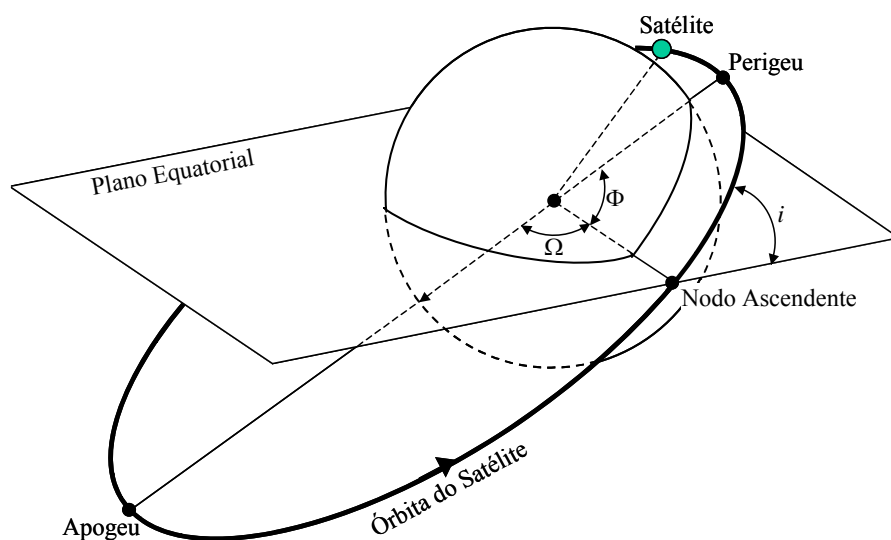


Figura 2 – Parâmetros orbitais

Integração de Dados Estatísticos na Classificação de Imagens de Satélite

Para calcular o ponto da superfície terrestre que se encontra exactamente por baixo do satélite (**nadir**), recorre-se frequentemente à trigonometria esférica (considerando-se para tal a Terra como uma esfera perfeita). Assim, considerando como ϕ o ângulo formado pelo centro de massa das terra, o nodo ascendente e o satélite, a latitude (φ) e a longitude (λ) do nadir será dada por:

$$\text{sen } \varphi = \text{sen } \phi \text{ sen } i \quad (3)$$

$$\text{e } \lambda = \lambda_0 + \text{atan2}\left(\frac{\cos \phi}{\cos \varphi}, \frac{\tan \phi}{\tan i}\right), \quad (4)$$

onde λ_0 corresponde à longitude instantânea do nodo ascendente e atan2 é uma função trigonométrica inversa que evita a ambiguidade subjacente à utilização de senos, cosenos e tangentes inversas. Esta função inversa é definida de forma a que $\text{atan2}(x, y)$ corresponda ao ângulo cujo coseno seja $x/(x^2 + y^2)^{1/2}$ e o seno $y/(x^2 + y^2)^{1/2}$.

No entanto, mesmo que o plano da órbita do satélite fosse fixo no espaço, devido ao movimento de rotação da Terra o **traço do satélite** (linha imaginária traçada sobre a superfície terrestre ao longo de uma órbita do satélite e definida pela união de todos os pontos nadir dessa mesma órbita) não descreve um círculo. Efectivamente, quando o satélite completa uma órbita, a Terra terá rodado em direcção Este de modo que a órbita parecerá deslocar-se para Oeste, tanto para órbitas progressivas como para órbitas retrógradas. O efeito de rotação da Terra pode ser tido em conta na equação (4) atendendo-se a que corresponde a uma taxa constante de alteração de λ_0 .

Até este momento tem sido assumido que a Terra possui uma forma esférica perfeita, quando na realidade ela é achatada nos pólos. A forma mais conveniente de descrever matematicamente o efeito desta “não esfericidade” no movimento de um satélite é expressar o potencial gravitacional como um somatório (possivelmente infinito) de funções harmónicas esféricas. Como seria de esperar, as variações longitudinais são diminutas quando comparadas com as latitudinais, o que faz com que normalmente sejam desprezadas para simplificar os cálculos. Nesses casos o potencial gravitacional - $V(t)$ - por unidade de massa é dado por:

$$V(t) = -\frac{GM}{r(t)} \left(1 - \frac{a_e^2 J_2}{2r(t)^2} (3\text{sen}^2 \varphi - 1) + \dots \right), \quad (3.5)$$

onde a_e representa o raio equatorial da Terra ($a_e \approx 6\,378\,135$ km), e o termo adimensional J_2 , vulgarmente designado de **factor dinâmico da forma da Terra**, expressa o bulgo equatorial ($J_2 \approx 0,00108263$).

Anexo I

O factor dinâmico de forma tem três efeitos importantes na órbita do satélite. Em primeiro lugar, aumenta o período orbital relativamente ao valor T dado pela equação (1). Nestas circunstâncias o período nodal (tempo medido entre sucessivos nodos ascendentes os descendentes) é dado por:

$$T_n = 2\pi \sqrt{\frac{a^3}{GM}} \left(1 + \frac{3J_2 a_e^2}{4a^2} \left\{ 1 - 3\cos^2 i + \frac{1 - 5\cos^2 i}{(1 - e^2)^2} \right\} \right), \quad (6)$$

o que implica que nem mesmo o tempo em que uma órbita circular é descrita seja uniforme. Em segundo lugar, faz com que o plano orbital do satélite rode em torno do eixo polar da Terra (efeito conhecido por **precessão**), de modo a que o plano não é fixo no espaço. A precessão ocorre a uma velocidade angular de:

$$P = -\frac{3J_2 \sqrt{GM} a_e^2 a^{-7/2} \cos i}{2(1 - e^2)^2}, \quad (7)$$

onde valores positivos indicam uma precessão progressiva. Devido ao sinal negativo no início da equação a precessão progressiva apenas se verifica quando o $\cos i$ é negativo, ou seja, quando a órbita é retrograda. Por fim, em terceiro lugar, se a órbita for elíptica a não esfericidade da Terra vai obrigar a elipse a rodar sobre o seu próprio plano. A velocidade angular desta precessão é dada por:

$$P\omega = -\frac{3J_2 \sqrt{GM} a_e^2 a^{-7/2} (1 - 5\cos^2 i)}{4(1 - e^2)^2}, \quad (8)$$

onde tal como no caso anterior valores positivos indicam uma precessão progressiva.

Como seria de supor, a precessão vai ter efeitos sobre a órbita dos satélites e, conseqüentemente, sobre as suas posições (coordenadas). Relativamente aos três ângulos de orientação, fundamentais para localizar o satélite na sua órbita, a variação da ascensão recta do nodo ascendente da órbita por período orbital, designada **precessão orbital**, é dada por:

$$\Delta\Omega = -3\pi J_2 \left(\frac{a}{a(1 - e^2)} \right)^2 \cos i + 3\pi e J_3 \left(\frac{a}{a(1 - e^2)} \right)^3 \left(1 - \frac{15}{4} \sin^2 i \right) \cot i \sin \Phi + \dots \quad (9)$$

A variação da inclinação da órbita por período orbital é dada por:

$$\Delta i = 3\pi e J_3 \left(\frac{a}{a(1-e^2)} \right)^3 \left(1 - \frac{15}{4} \text{sen}^2 i \right) \cot i \text{sen } \Phi + \dots \quad (10)$$

A variação do argumento do perigeu por período orbital é dada por:

$$\begin{aligned} \Delta \Phi = 6\pi J_2 \left(\frac{a}{a(1-e^2)} \right)^2 \left(1 - \frac{5}{4} \text{sen}^2 i \right) \cos i + \\ + 3\pi e J_3 \left(\frac{a}{a(1-e^2)} \right)^3 \left(1 - \frac{5}{4} \text{sen}^2 i \right) \text{sen} i \text{sen } \Phi + \dots \end{aligned} \quad (11)$$

Por fim, é possível obter da variação da inclinação orbital a variação da excentricidade por período orbital, através de:

$$\Delta e = -\frac{1-e^2}{e} \Delta i \tan i . \quad (12)$$



ANEXO 2

CARACTERÍSTICAS ORBITAIS DOS LANDSAT 1, 2 E 3

Na figura 1 apresenta-se a configuração esquemática dos Landsat 1, 2 e 3. Estes satélites, em forma de borboleta, tinham três metros de altura e 1,5 m de diâmetro, apresentando dois painéis solares com cerca de quatro metros de altura. O seu peso era de 815 kg e foram lançados em órbitas circulares a uma altitude nominal de 900 km (o valor real varia entre 880 e 940 km), que passam a 9° dos Pólos. Relativamente ao período orbital, este é de 103 minutos, o que equivale a 14,5 órbitas diárias e a uma velocidade na superfície terrestre de 6,46 km/s.




Figura 1 – Representação esquemática dos Landsat 1 , 2 e 3

Na figura 2 podem observar-se as órbitas diárias (de Norte para Sul) do satélite. Estas órbitas cruzam o equador com um ângulo de 9° graus relativamente à normal e órbitas sucessivas distam, sobre o Equador, 2760 km umas das outras. Como os sensores a bordo destes satélites têm um campo de visão de apenas 185 km, conclui-se que entre as órbitas diárias existem enormes extensões de terreno que não são cobertas. No entanto, a cada dia que passa a órbita do satélite desloca-se ligeiramente para Oeste sobrepondo-se ligeiramente ao padrão orbital do dia anterior.

Esta sobreposição (figura 3) atinge o valor máximo de 85% a latitudes superiores a 81° (Norte e Sul) e o valor mínimo sobre o Equador (14%). Desta forma, é possível obter uma cobertura completa de todo o globo a cada 18 dias (20 vezes por ano). As órbitas do satélite são corrigidas ocasionalmente para compensar os efeitos causados pelo movimento de precessão, assegurando-se assim que os centros das imagens se encontram a uma distância máxima de 37 km dos centros de imagens equivalentes, mas obtidas noutras datas.




Figura 2 – Percurso da órbita heliosíncrona diária do Landsat

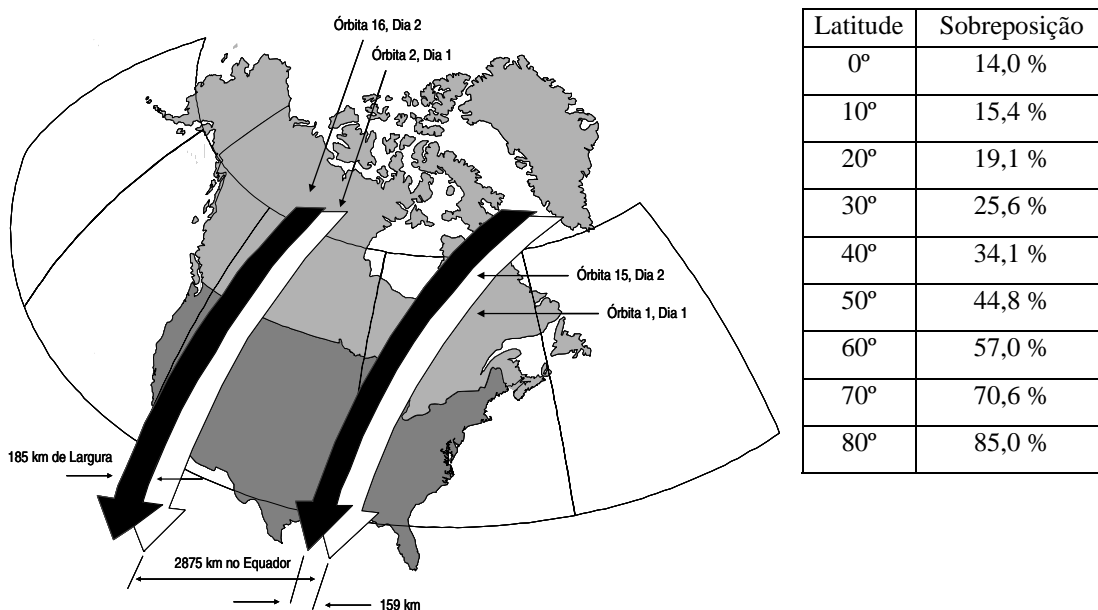


Figura 3 - Cobertura das imagens Landsat

O período orbital de 103 min e a distância entre órbitas de 2760 km no equador fazem com que o satélite acompanhe com precisão o movimento de rotação da Terra, cruzando o equador exactamente à mesma hora solar (as horas variam de acordo com a zona do globo), sendo por isso que este tipo de órbitas são designadas de heliosíncronas. Os Landsat 1, 2 e 3 foram colocados em órbitas que atravessam o equador às 9h 42min, hora local, mas este valor pode ser ligeiramente alterado em virtude das perturbações que afectam a órbita dos satélites. Esta hora foi escolhida para tirar partido do céu matinal, que se encontra normalmente mais límpido (sem nuvens) que o do fim de tarde.

Anexo 2

A importância da órbita heliossíncrona tem a ver com a manutenção das condições de iluminação durante períodos específicos, o que se torna fundamental quando o objectivo é criar mosaicos de imagens ou comparar imagens de datas diferentes.

SENSORES A BORDO DOS LANDSAT 1, 2, E 3

Os satélites Landsat 1 e 2 foram lançados com dois sensores idênticos a bordo (tabela 1); um sistema de três canais RBV e um MSS de quatro canais. O sistema RBV consistia em três televisões, semelhantes às utilizadas em televisão, projectadas para observar simultaneamente a mesma porção de terreno (185 x 185 km). A resolução espacial destas câmaras era de cerca de 80 m e a resolução espectral situava-se nos 0,475 a 0,575 μm (verde) para a banda 1, nos 0,580 a 0,680 μm (vermelho) para a banda 2 e 0,690 a 0,830 μm (infravermelho próximo) para a banda 3. O sistema RBV não utilizava um filme. As imagens eram adquiridas através de uma superfície fotossensível existente em cada câmara, que eram por sua vez analisadas com recurso a um feixe de electrões interno, produzindo um sinal de vídeo idêntico ao criado pelas câmaras convencionais.

| Sensor | Resolução Espectral | Resolução Espacial | Faixa de Varrimento | Resolução Radiométrica | Resolução Temporal |
|--|-----------------------------|--------------------|---------------------|------------------------|--------------------|
| RBV | 0,475 – 0,575 μm | 80 m | 185 km | - | 18 dias |
| <i>Return Beam</i> | 0,58 – 0,68 μm | 80 m | 185 km | - | 18 dias |
| <i>Vidicon</i> | 0,69 – 0,83 μm | 80 m | 185 km | - | 18 dias |
| MSS <i>Multispectral Scanner</i> | 0,5 – 0,6 μm | 80 m | 185 km | 6 bits (64 níveis) | 18 dias |
| | 0,6 – 0,7 μm | 80 m | 185 km | 6 bits (64 níveis) | 18 dias |
| | 0,7 – 0,8 μm | 80 m | 185 km | 6 bits (64 níveis) | 18 dias |
| | 0,8 – 1,1 μm | 80 m | 185 km | 6 bits (64 níveis) | 18 dias |

Tabela 1 – Características dos sensores a bordo dos Landsat 1 e 2

Como o sistema RBV obtinha uma imagem completa instantaneamente, as suas imagens continham uma maior precisão geométrica do que as adquiridas pelo sistema MSS. Além disso, o RBV continha uma grelha de correcção no seu plano de imagem, de forma a facilitar o processo de correcção geométrica (cf. 4.3.1). O resultado prático desta grelha é uma matriz de cruces distribuídas por toda a imagem e com uma localização precisa. Conhecendo a localização da imagem observada e a posição teórica das referidas cruces, é possível, durante o processo de georreferenciação eliminar praticamente todas as distorções.

Integração de Dados Estatísticos na Classificação de Imagens de Satélite

As câmaras RBV instaladas no Landsat 1 captaram, entre 23 de Julho e 5 de Agosto de 1972, um total de 1690 imagens. Findo este período, um problema no sistema de troca de gravadores provocou a inoperacionalidade do sistema. Quanto às câmaras RBV a bordo do Landsat 2, estas foram concebidas primordialmente com o intuito de avaliar problemas de engenharia, sendo raramente utilizadas para fins cartográficos e apenas em regiões remotas. No Landsat 3 (tabela 2), foram introduzidos dois grandes melhoramentos no sistema RBV: o sistema passou a captar informação numa única banda (0,505 a 0,750 μm – do verde ao infravermelho próximo) e não em modo multiespectral como anteriormente, e a resolução espacial foi melhorada num factor de cerca de 2,6 (passou a cifrar-se nos 30 m) relativamente à dos sensores a bordo dos Landsat 1 e 2. A melhoria da resolução espacial foi obtida através da duplicação do comprimento focal do sistema de lentes da câmara, diminuindo o tempo de exposição e reduzindo o movimento da imagem durante esse período, e garantindo uma exposição adequada e estável, graças à remoção dos filtros espectrais que equipavam os sistemas anteriores.

| Sensor | Resolução Espectral | Resolução Espacial | Faixa de Varrimento | Resolução Radiométrica | Resolução Temporal |
|--|--|---------------------------|----------------------------|-------------------------------|---------------------------|
| RBV <i>Return Beam</i> <i>Vidicon</i> | 0,5 – 0,75 μm | 40 m | 185 km | - | 18 dias |
| MSS <i>Multispectral</i> <i>Scanner</i> | 0,5 – 0,6 μm | 80 m | 185 km | 6 bits (64 níveis) | 18 dias |
| | 0,6 – 0,7 μm | 80 m | 185 km | 6 bits (64 níveis) | 18 dias |
| | 0,7 – 0,8 μm | 80 m | 185 km | 6 bits (64 níveis) | 18 dias |
| | 0,8 – 1,1 μm | 80 m | 185 km | 6 bits (64 níveis) | 18 dias |
| | 10,4 – 12,6 μm (térmico) | 120 m | 185 km | 6 bits (64 níveis) | 18 dias |

Tabela 2 - Características dos sensores a bordo do Landsat 3

Para compensar a diminuição da área de terreno coberta, provocada pelo aumento da distância focal, optou-se por uma configuração de duas câmaras, colocadas lado a lado. Estas câmaras estavam alinhadas de modo a registarem duas imagens adjacentes (figura 4) com 98 km de lado e uma sobreposição lateral de 13 km, o que se traduz num par de imagens com 183 x 98 km.

Sem que tenha sido premeditado, os sistemas RBV a bordo dos três primeiros satélites Landsat acabaram por passar para um plano secundário face aos MSS. Dois factores fundamentais contribuíram para esta situação; a panóplia de problemas técnicos que se registavam nos RBV e, principalmente, o facto dos MSS terem sido os primeiros sistemas capazes de recolher informação multiespectral em formato digital (podia ser processada em computador).




Figura 4 – Configuração do sistema RBV a bordo do Landsat 3

Os sensores MSS a bordo dos satélites Landsat 1, 2 e 3 cobriam uma área de terreno com 185 km de largura em quatro bandas (designadas de bandas 4, 5, 6 e 7) do espectro electromagnético: duas no visível, dos 0,5 aos 0,6 μm (verde) e dos 0,6 aos 0,7 μm (vermelho), e duas no infravermelho próximo, dos 0,7 aos 0,8 μm e dos 0,8 aos 1,1 μm . O MSS incorporado no Landsat 3 dispunha ainda de banda térmica (banda 8) que operava entre os 10,4 e os 12,6 μm , mas que devido a problemas operacionais deixou de funcionar logo após o lançamento do satélite. As quatro bandas que nunca tiveram problemas continuaram a ser utilizadas nos Landsat 4 e 5, mas com a designação de banda MSS 1, 2, 3 e 4.

A configuração de operação do sistema MSS encontra-se representada na figura 5. O campo de visão do *scanner* é quadrado e resulta numa resolução espacial equivalente a um pixel com 79 m de lado medido sobre o terreno. O campo de visão é de aproximadamente $11,56^\circ$, o que é muito pouco quando comparado com os valores possíveis em *scanners* montados a bordo de aviões (de 90 a 120°). Para resolver esta desvantagem utilizou-se um espelho de varrimento oscilatório, em substituição do tradicional sistema de rotação. O espelho oscila a cada 33 ms e, em cada oscilação são adquiridas seis linhas contíguas de dados. Esta característica implica a existência de quatro matrizes (uma por cada banda) com seis detectores cada uma (um por cada linha).




Figura 5 – Método de funcionamento do Landsat MSS

O sinal analógico proveniente de cada detector é convertido para formato digital através de quatro conversores analógico-digitais (A/D) internos (um para cada banda), utilizando-se para o efeito 64 níveis discretos de amplitude (6 bits por amostra). Estes valores são posteriormente expandidos para outras amplitudes durante o processamento terrestre da informação; normalmente a banda 7 continua a apresentar valores digitais entre o 0 e o 63, e as bandas 4, 5 e 6 passam a variar entre 0 e 127. Os conversores A/D efectuam uma amostragem dos dados provenientes dos detectores a uma frequência próxima de 100000 amostras por segundo, o que se traduz num espaçamento de 56 m no terreno entre cada leitura e consequentemente numa imagem onde cada pixel apresenta uma dimensão de 56 x 79 m (figura 6). No entanto, o valor de brilho de cada pixel é efectivamente calculado a partir do pixel de 79 x 79 m (área a cinzento na figura 3.10).




Figura 6 – Resolução no solo *versus* tamanho do pixel

O sistema MSS adquire os dados de Oeste para Este, sendo o movimento *along track* providenciado pelo movimento orbital do satélite (Norte-Sul). Cada imagem MSS é retirada dos dados contínuos fornecidos pelos detectores, de maneira a formar uma área de 185 x 185 km com 10% de sobreposição.



ANEXO 3

CÁLCULO DAS PROBABILIDADES *A PRIORI*

Os edifícios com mais de dois pisos (pavimentos) foram considerados habitação plurifamiliar, e os de 1 ou dois pisos habitação unifamiliar. O núcleo antigo foi estabelecido como o conjunto de edifícios construídos até 1945, inclusivamente. Esta opção deveu-se ao facto de ser esta a data utilizada na elaboração da Carta de Uso do Solo da AML para 91 (que poderia servir de ficheiro de validação) e de nesta década ter havido uma alteração no tipo de materiais de construção utilizados, facto que também é perceptível através das imagens de satélite e que, portanto, permite uma grande correlação entre os dois tipos de dados (estatísticos e espectrais).

Anexo3

Na sequência do exposto, os edifícios de mais de 2 pisos (*EMP*) calculam-se, teoricamente, através da equação:

$$EMP = EMP_a^h + EMP_n^h + EMP_a^{h+s} + EMP_n^{h+s} \quad (1)$$

onde:

EMP_a^h = número de edifícios de habitação (número de edifícios exclusivamente e principalmente residenciais) com mais de dois pisos e construídos antes de 1945 (antigos). EMP_n^h = número de edifícios de habitação (número de edifícios exclusivamente e principalmente residenciais) com mais de dois pisos e construídos depois de 1945 (novos).

EMP_a^{h+s} = número de edifícios de habitação, e comércio e serviços (número de edifícios principalmente não residenciais) com mais de dois pisos e construídos antes de 1945 (antigos).

EMP_n^{h+s} = número de edifícios de habitação, e comércio e serviços (número de edifícios principalmente não residenciais) com mais de dois pisos e construídos depois de 1945 (novos).

Da mesma forma o número de edifícios com 1 ou 2 pisos (*EPP*) correspondem a:

$$EPP = EPP_a^h + EPP_n^h + EPP_a^{h+s} + EPP_n^{h+s} \quad (2)$$

onde:

EPP_a^h = número de edifícios de habitação (número de edifícios exclusivamente e principalmente residenciais) com um ou dois pisos e construídos antes de 1945 (antigos).

EPP_n^h = número de edifícios de habitação (número de edifícios exclusivamente e principalmente residenciais) com um ou dois pisos e construídos depois de 1945 (novos).

Integração de Dados Estatísticos na Classificação de Imagens de Satélite

EPP_a^{h+s} = número de edifícios de habitação e, comércio e serviços (número de edifícios principalmente não residenciais) com um ou dois pisos e construídos antes de 1945 (antigos).

EPP_n^{h+s} = número de edifícios de habitação e, comércio e serviços (número de edifícios principalmente não residenciais) com um ou dois pisos e construídos depois de 1945 (novos).

A classe comércio e serviços ($EPNR$) obtém-se através de:

$$EPNR = EMP_a^{nr} + EPP_a^{nr} + EMP_n^{nr} + EPP_n^{nr} \quad (3)$$

onde:

EMP_a^{nr} = número de edifícios com mais de dois pisos, principalmente não residenciais e construídos antes de 1945 (antigos).

EPP_a^{nr} = número de edifícios com um ou dois pisos, principalmente não residenciais e construídos antes de 1945 (antigos).

EMP_n^{nr} = número de edifícios com mais de dois pisos, principalmente não residenciais e construídos depois de 1945 (novos).

EPP_n^{nr} = número de edifícios com um ou dois pisos, principalmente não residenciais e construídos depois de 1945 (novos).

Por seu turno a classe núcleo antigo (ECA) define-se como:

$$ECA = EMP_a^h + EPP_a^h + EMP_a^{h+s} + EPP_a^{h+s} \quad (4)$$

Voltando um pouco atrás, pode retirar-se de 4.4 que:

$$EMP_n^h + EMP_n^{h+s} = EMP - (EMP_a^h + EMP_a^{h+s}) \quad (5)$$

onde $EMP_a^h + EMP_a^{h+s}$ é a quantidade de edifícios com mais de dois pisos antigos, os quais correspondem a uma percentagem (α) de edifícios que fazem parte do núcleo antigo ($EMP_a^h + EMP_a^{h+s} = \alpha ECA$). Assim pode-se simplificar 5:

Anexo3

$$EMP_n^h + EMP_n^{h+s} = EMP - \alpha ECA \quad (6)$$

Continuando nesta linha de raciocínio, é possível estabelecer as equações que permitem calcular a probabilidade (p) de ocorrência dos edifícios plurifamiliares novos (EMP_N), obtendo-se:

$$p(EMP_N) = \frac{EMP - \alpha ECA}{TE} \quad (7)$$

onde:

TE = número total de edifícios.

Da mesma forma consegue-se obter as probabilidades de ocorrência de edifícios unifamiliares novos ($EPPN$), dos edifícios de comércio e serviços novos ($EPNRN$) e dos edifícios antigos (ECA):

$$p(EPPN) = \frac{EPP - \beta ECA}{TE} \quad (8)$$

$$p(EPNRN) = \frac{EPNR - \gamma ECA}{TE} \quad (9)$$

$$p(ECA) = \frac{ECA}{TE} \quad (10)$$

com:

β = percentagem de edifícios unifamiliares que fazem parte do núcleo antigo.

γ = percentagem de edifícios principalmente não residenciais que fazem parte do núcleo antigo.

No entanto, esta situação, tida como ideal, não pode funcionar na prática, na medida em que algumas variáveis, como o número de edifícios (principalmente ou exclusivamente habitacionais) unifamiliares ou plurifamiliares construídos antes de 1945, não podem ser extraídos directamente da tabela 4.1. Isto porque os dados disponibilizados pelo INE embora permitam calcular todas estas variáveis individualmente, não viabilizam o seu cruzamento no nível de desagregação desejado. Para fazer face a este problema adoptou-se a seguinte metodologia de classificação.

Integração de Dados Estatísticos na Classificação de Imagens de Satélite

$$p(\text{'Habitação plurifamiliar'}) \equiv p(\text{MFB}) = \text{MFB}/\text{TE}$$

$$p(\text{'Habitação unifamiliar'}) \equiv p(\text{SFB}) = \text{SFB}/\text{TE}$$

$$p(\text{'Núcleo urbano antigo'}) \equiv p(\text{ECA}) = \text{ECA}/\text{TE}$$

$$p(\text{'Comércio e serviços'}) \equiv p(\text{CS}) = \text{CS}/\text{TE}$$

1. Compute $p(\text{CS}) = \text{CS}/\text{TE}$

2. If

$$p(\text{CS}) > 0.8$$

then

$$p(\text{CS}) = 1,$$

$$p(\text{MFB}) = p(\text{SFB}) = p(\text{AUN}) = 0$$

else

$$p(\text{CS}) = 0$$

3. If

$$p(\text{CS}) = 0$$

then

$$p(\text{ECA}) = \text{ECA}/\text{TE}$$

$$p(\text{MFB}) = (\text{MFB}_t - \alpha \text{ECA})/\text{TE}$$

$$p(\text{SFB}) = (\text{SFB}_t - \beta \text{ECA})/\text{TE}$$

com

MFB_t = número de habitações plurifamiliares;

SFB_t = número de habitações unifamiliares;

CS = número de edifícios predominantemente não residenciais;

TE = número total de edifícios;

MFB = número de habitações plurifamiliares, construídas depois de 1945;

ECA = número de edifícios (exclusivamente ou principalmente) residenciais, construídos antes 1945.

Os parâmetros α e β ($\alpha + \beta = 1$) representam a percentagem de edifícios antigos que são unifamiliares e plurifamiliares. Na fase de processamento, face à idêntica correlação (fraca) apresentada por estas duas variáveis face ao número de edifícios anteriores a 1945 utilizou-se $\alpha = \beta = 0,5$.



ANEXO 4

MÉTODOS DE INTERPOLAÇÃO

1) Vizinho mais próximo – é o processo mais rápido, em termos de cálculo, visto que utiliza apenas o valor do pixel mais próximo, isto é, escolhe o pixel que tenha o centro mais próximo do ponto (p) localizado na imagem inicial (figura 1). Este pixel é depois transferido para a sua posição correspondente na imagem final (georreferenciada). Esta técnica é a ideal quando a imagem geo-referenciada se destina a posterior classificação, pois preserva os valores radiométricos da imagem original, redistribuindo apenas a sua posição, de modo a fornecer uma imagem geometricamente correcta. A desvantagem desta técnica é que introduz distorções geométricas localizadas.

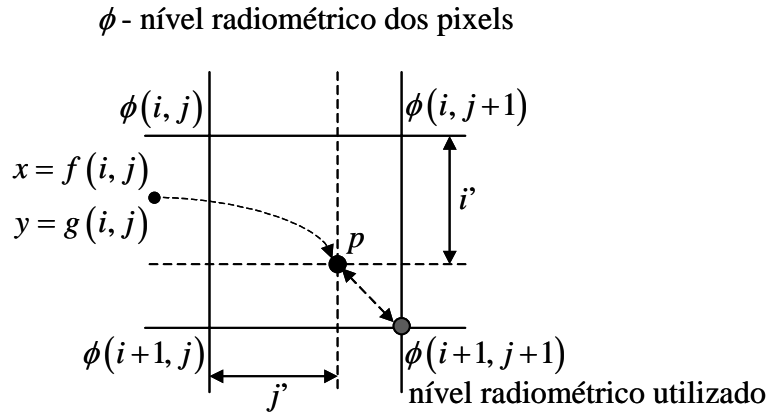


Figura 1 – Interpolação do valor do pixel pelo método do vizinho mais próximo

2) **Interpolação bilinear** – utiliza três interpolações lineares sobre os quatro pixels que circundam o ponto inicial, que é correspondente a uma dada posição de destino (figura 2). O processo encontra-se ilustrado na figura onde se observa que são feitas duas interpolações ao longo das linhas, $\phi(i, j')$ e $\phi(i+1, j')$, as quais são dadas por:

$$\begin{aligned}\phi(i, j') &= j'\phi(i, j+1) + (1-j')\phi(i, j) \\ \phi(i+1, j') &= j'\phi(i+1, j+1) + (1-j')\phi(i+1, j)\end{aligned}\quad (1)$$

onde ϕ é o nível radiométrico do pixel e (i', j') é a posição em que é necessário um valor radiométrico interpolado. Esta posição é medida relativamente a (i, j) e assume um espaçamento da matriz (imagem) equivalente à unidade em ambas as direcções. O passo final consiste em fazer uma interpolação linear entre $\phi(i, j')$ e $\phi(i+1, j')$ de forma a obter:

$$\begin{aligned}\phi(i', j') &= (1-i')\{j'\phi(i, j+1) + (1-j')\phi(i, j)\} \\ &\quad + i'\{j'\phi(i+1, j+1) + (1-j')\phi(i+1, j)\}\end{aligned}\quad (2)$$

A interpolação bilinear corrige com grande eficácia as distorções geométricas mas, de uma forma geral, produz uma imagem final de aparência suavizada, que é bastante utilizada em casos que o seu propósito seja o de servir para foto-interpretção. Por outro lado, como o nível radiométrico atribuído aos pixels da imagem final resulta de uma interpolação dos níveis radiométricos dos pixels da imagem inicial (actua como filtro), este método não é indicado para criar imagens que ainda venham a ser objecto de classificação, na medida em que os níveis

radiométricos dos pixels podem ser ligeiramente diferentes dos níveis de radiância detectados pelos sensores dos satélites. Este método constitui um bom compromisso entre o dispêndio de tempo e a fidelidade dos resultados.




Figura 2 – Reamostragem do nível radiométrico de um pixel por interpolação bilinear

3) Convolução cúbica – utiliza os 16 pixels circundantes do ponto inicial. Neste método são ajustados polinómios cúbicos às linhas correspondentes aos quatro pixels que envolvem o ponto inicial (figura 3), de modo a obter quatro interpolações. De seguida, ajusta-se um quinto polinómio cúbico ao longo dos quatro anteriores, de forma a sintetizar o nível radiométrico da localização correspondente na imagem final. Assim, o algoritmo utilizado para proceder é:

$$\begin{aligned} \phi(i, j') = j' \{ & j' [j' [\phi(i, j+3) - \phi(i, j+2) + \phi(i, j+1) - \phi(i, j)] \\ & + [\phi(i, j+2) - \phi(i, j+3) - 2\phi(i, j+1) + 2\phi(i, j)]] \\ & + [\phi(i, j+2) - \phi(i, j)] \} \\ & + \phi(i, j+1) \end{aligned} \quad (3)$$

Esta expressão é avaliada para cada uma das quatro linhas correspondentes aos quatro pixels mais próximos de maneira traduzindo-se em quatro interpolações: $\phi(i, j')$, $\phi(i+1, j')$, $\phi(i+2, j')$ e $\phi(i+3, j')$. A seguir, os valores obtidos são interpolados verticalmente segundo:

$$\begin{aligned} \phi(i', j') = i' \{ & i' [i' [\phi(i+3, j') - \phi(i+2, j') + \phi(i+1, j') - \phi(i, j')] \\ & + [\phi(i+2, j') - \phi(i+3, j') - 2\phi(i+1, j') + 2\phi(i, j')]] \\ & + [\phi(i+2, j') - \phi(i, j')] \} \\ & + \phi(i+1, j') \end{aligned} \quad (4)$$

Este método é o que apresenta melhores resultados na componente geométrica. No entanto, é bastante mais lento do que os restantes e bastante mais exigente em termos de capacidade de processamento. De resto, partilha dos defeitos e virtudes da interpolação bilinear.

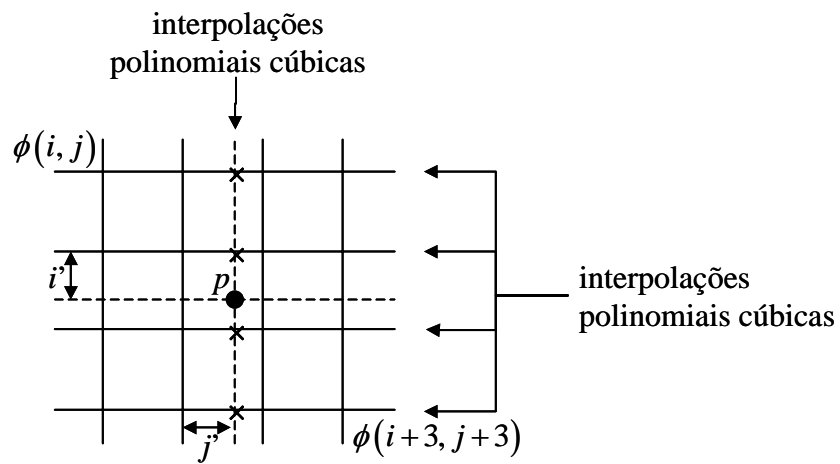


Figura 3 - Reamostragem do nível radiométrico de um pixel por convolução cúbica