

Classificação de imagens de satélite com recurso a informação não espectral

Jorge ROCHA

Centro de Estudos Geográficos
Universidade de Lisboa

Alameda da Universidade, 1600-214 LISBOA (PORTUGAL)

Tel.: +351 217940218 Fax: +351 217938690 e-mail:jrocha@aml.pt

Resumo

A principal finalidade da metodologia apresentada neste documento é o desenvolvimento e a validação, através da aplicação a um caso de estudo, de uma forma eficiente de classificação de imagens de satélite, que integra informação auxiliar (dados dos Censos, do Plano Director Municipal e a rede viária) e dados provenientes de Detecção Remota, num Sistema de Informação Geográfica. O procedimento desenvolvido segue uma estratégia de classificação por níveis, sendo composto por três estágios principais: 1) Estratificação pré-classificação; 2) Aplicação dos classificadores de Bayes e da Máxima Verosimilhança (MV); 3) Aplicação de regras de pós-classificação. As abordagens comuns incorporam os dados auxiliares antes, durante ou depois da classificação. No método proposto recorre-se a esse tipo de informação em todas as etapas. O método consegue, globalmente, melhores resultados que os classificadores clássicos: Mínima Distância, Paralelepípedo e Máxima Verosimilhança. Além disso, melhora substancialmente a exactidão das classes onde o processo de classificação faz uso da informação auxiliar.

Palavras-chave: Detecção Remota, Sistemas de Informação Geográfica, informação auxiliar, recenseamentos.

Abstract

The main purpose of the research presented in this paper is the development and validation, through the application to a case study, of an efficient form of satellite image classification that integrates ancillary information (Census data; the Municipal Master Plan; the Road Network) and remote sensing data in a Geographic Information System. The developed procedure follows a layered classification approach, being composed by three main stages: 1) Pre-classification stratification; 2) Application of Bayesian and Maximum-likelihood classifiers; 3) Post-classification sorting. Common approaches incorporate the ancillary data before, during or after classification. In the proposed method, all the steps take the

auxiliary information into account. The proposed method achieves, globally, much better classification results than the classical, one layer, Minimum Distance and Maximum-likelihood classifiers. Also, it greatly improves the accuracy of those classes where the classification process uses the ancillary data.

Key words: Remote Sensing, Geographic Information System, ancillary data, census data.

Résumé

Le principal objectif de la méthodologie présentée dans ce document est le développement et la validation, à travers l'application d'un cas d'étude, d'une façon efficace de classification d'images satellite, qui intègre de l'information auxiliaire (données du recensement, données du Schéma Directeur de la Municipalité et données de la voirie) et des données provenant de la Télédétection, dans un Système d'Information Géographique.

Le processus développé suit une stratégie de classification par niveaux: 1) Stratification pré-classification; 2) Classification de Bayes et de vrai ressemblance 3) Application de règles après classification. Les approches courantes incorporent des données auxiliaires d'avant, de durant ou d'après la classification. Dans la méthode proposée nous avons recours à ce type d'information dans toutes ses étapes. La méthode atteint, globalement, des meilleurs résultats que les classifications classiques. En plus, elle améliore substantiellement l'exactitude des classes où le processus de classification utilise l'information auxiliaire.

Mots-clés : Systèmes d'information géographique, Télédétection, information auxiliaire, recensements.

1. Introdução

As imagens de satélite são tidas, 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. O seu formato de dados permite a utilização de algoritmos de classificação automática e/ou semi-automática viabilizando, assim, uma análise mais célere, menos dispendiosa e espectralmente mais abrangente.

Várias abordagens têm sido levadas a efeito para identificar e medir, de forma automática ou semi-automática, as diferentes características do espaço urbano, tendo-se chegado a resultados muito diversos. De facto, se para os estudos que incidem sobre áreas agrícolas o processamento digital de imagens tem provado o seu valor, quando se faz a transposição para áreas construídas os resultados já não são tão eloquentes (Sadler, 1990) A resolução espacial das imagens funcionou inicialmente como justificação para todos os problemas encontrados, sendo indicada como o principal factor limitativo em diversos estudos (Welch, 1982).

Contudo, alguns autores (Tenedório, 1998) têm feito notar que, paradoxalmente, o aumento da resolução espacial pode conduzir a maiores problemas no tratamento numérico de imagens, em função da grande heterogeneidade espectral do meio urbano, que conduz implicitamente a um aumento da variabilidade e, conseqüentemente, do designado “ruído”. Dito de outra forma, à medida que a resolução espacial aumenta, os detalhes da imagem (ex. estradas, casas) vão tomando forma e adquirindo uma certa predominância na resposta espectral de cada pixel, promovendo um tratamento erróneo e confuso, comprometendo a extracção de informação global e tornando problemática uma classificação coerente e homogénea da imagem. Na realidade, as áreas urbanas envolvem classes de uso espectralmente heterogéneas, tornando impraticável uma correcta classificação das imagens, com base unicamente em informação espectral (Martin, 1988).

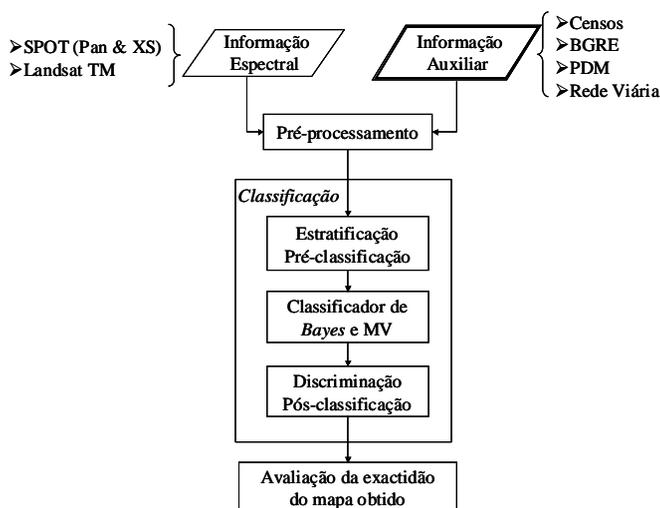
Os Sistemas de Informação Geográfica (SIG) permitem a fácil integração de informação proveniente de diversas fontes. Este facto pode ser explorado na classificação de imagens de satélite, através da utilização de informação não espectral auxiliar ou colateral. Neste contexto, propõe-se a apresentação dos resultados de um projecto que teve por objectivo o desenvolvimento e validação, por experimentação numa área teste, de uma forma melhorada de classificação de imagens que integra, em ambiente SIG, dados provenientes dos Censos e de Detecção Remota. O IDECIS (nome atribuído ao método proposto) 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), geo-referenciados à subsecção estatística através da “Base Geográfica de Referenciação Espacial” (BGRE), e ao “Plano Director Municipal” (PDM) da região em estudo.

Até ao 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 (Caetano, 1997) 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 classificação para a pós-classificação. Em 1998, foi apresentado outro trabalho (Mesev, 1998) 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 comunicação pode considerar-se um desenvolvimento destes dois trabalhos. A figura 1 apresenta as principais etapas da metodologia de classificação hierárquica aplicada neste trabalho. Como foi referido, o método incorpora informação espectral e auxiliar (não espectral) – ambas são descritas na Secção 2. Na fase de pré-processamento, que é descrita no ponto 3, esta informação é compatibilizada depois de corrigidos os erros de aquisição. Utilizando

exclusivamente informação auxiliar, foi criada uma máscara binária, que subdivide a área em dois clusters – terra e água – introduzindo *a priori* a probabilidade de ocorrência de algumas classes urbanas. No ponto 3 são apresentadas as três fases principais: pré-classificação da estratificação, aplicação dos classificadores de *Bayes* e *Máxima Verosimilhança*, e pós-classificação. A informação será compatibilizada, após correcção das três fases anteriormente descritas, e o processo de classificação será apresentado no ponto 4. No ponto 5 é descrita a classificação experimental de resultados, juntamente com a classificação dos erros produzidos. Também é feita uma comparação com as estratégias de classificação clássicas, que recorrem apenas a um nível de informação (Mínima Distância e Máxima Verosimilhança).

Figura 1 – Esquema da metodologia aplicada na classificação de imagens



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 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 pela Base Geográfica de Referenciação Espacial (BGRE) e que corresponde à delimitação espacial das unidades de recolha, por outro, a informação estatística propriamente dita, 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 retiraram-se os campos considerados como fundamentais na persecução dos objectivos propostos. Seleccionaram-se os campos apresentados no quadro 1.

Quanto à rede viária e à planta de Ordenamento do PDM, estas foram seleccionadas porque, no caso da primeira, já existia em formato vectorial e portanto não fazia sentido recorrer às imagens de satélite para extrair uma informação que já havia e que podia ser inserida na classificação final com uma exactidão de 100%. Para além disso, a inclusão da rede viária permite abstrair da classificação das imagens de satélite uma classe (rede viária) que tem grandes semelhanças (valores digitais idênticos) com a habitação plurifamiliar, e que, ao ser retirada, permite calcular com melhor exactidão esta última (pois deixa de haver confusão entre as duas). Relativamente ao PDM, este foi seleccionado porque, muito embora as classes de ordenamento que nele estão representadas sejam predominantemente indicadoras do que é, ou não é, permitido fazer, 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 das imagens de satélite.

Quadro 1 – Informação estatística seleccionada em primeira instância

Campos	Significado
Número de Alojamentos Familiares	Todos os que se 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)	A sua estrutura e materiais empregues são de natureza não precária (duração prevista de pelo menos 10 anos)
Edifícios por data de construção	Edifícios por data de construção
Edifícios por Número de Pavimentos	Edifícios por Número de Pavimentos
Edifícios Exclusivamente Residenciais	Destinados exclusivamente a habitação
Edifícios Principalmente Residenciais	Destinados principalmente a habitação
Edifícios Principalmente não Residenciais	Destinados principalmente a actividades que não a habitação

Relativamente aos dados espectrais, optou-se por utilizar todas as bandas SPOT (1 pancromática e 3 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. Esta opção deve-se ao facto de se pretender juntar a melhor resolução espacial das imagens SPOT (todas), com a superior resolução espectral do Landsat. Na grande maioria dos estudos até agora desenvolvidos, é usual utilizar-se apenas as bandas Landsat TM e a SPOT Pan, visto que existe uma certa sobreposição da resolução espectral das bandas Landsat TM e SPOT XS. Contudo, embora a inclusão da banda pancromática permita, através da fusão de imagens, dar uma ideia

de se obter uma maior resolução espacial nas bandas multiespectrais, tal não corresponde à realidade. Efectivamente, a referida fusão não altera os valores digitais dos pixels das imagens multiespectrais, continuando estes a reportar-se a uma área de 900 m² (Landsat TM), ao passo que os dados SPOT XS têm uma abrangência espacial de 400 m².

3. Pré-processamento da informação

3.1. Optimização da informação espectral e auxiliar

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 que posteriormente irão ser parte integrante do processo de classificação.

A segunda etapa corresponde à geo-referenciação 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 e ao seu geoposicionamento.

Pelas suas características, o método do vizinho mais próximo é o mais utilizado em teledeteção, sendo também o escolhido para proceder à interpolação das imagens utilizadas neste estudo. 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 dados provenientes de diferentes plataformas orbitais.

Assim sendo, começou por se geo-referenciar 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 geo-referenciação, a discrepância entre o ficheiro de referência e a imagem corrigida não deve ser superior a 5 m sobre o terreno, ou seja, o equivalente a metade de um pixel da imagem em questão. O processo foi depois repetido para as imagens SPOT XS e Landsat TM, verificando-se que para estas últimas o erro foi um pouco superior ao máximo estabelecido (quadro 2), em virtude da sua resolução espacial (30 m) condicionar fortemente a identificação de correspondências na imagem de referência (ortofotomapa).

Quadro 2 – Parâmetros do processo de geo-referenciação

IMAGENS	Número de Pontos de Controlo	Graus de Liberdade	Erro Médio (m)	Ponto com Maior Erro (m)
SPOT Pan	34	62	2,249	2,3
SPOT XS	18	30	5,850	9
Landsat TM	9	12	19,220	20

Antes de se poder avançar com qualquer procedimento relativamente à informação auxiliar, também esta foi objecto de um pré-processamento. Assim, foi necessário preparar a base gráfica (BGRE) à qual a informação alfanumérica está referenciada, a qual apresentava alguns problemas de exactidão posicional, devido a um processo de digitalização (mesa digitalizadora) pouco preciso, que actualmente se encontra já em desuso. Assim, foi necessário corrigir a BGRE sobre um ortofotomapa, deslocando os limites das subsecções para os locais onde eles realmente pertencem (figura 2). Não seria correcto terminar este apontamento sem referir que, na altura da elaboração da BGRE, a opção tomada pelo INE era a mais avançada e foi o desenvolvimento tecnológico e o conseqüente aumento das exigências em termos de qualidade que o tornou preterido face a outros. Contudo, a nova base geográfica que serviu de suporte aos Censos 2001 foi elaborada segundo os métodos mais avançados, nomeadamente digitalização no computador sobre ortofotomapas.

Figura 2 – Correção da base de geo-referenciação espacial do INE

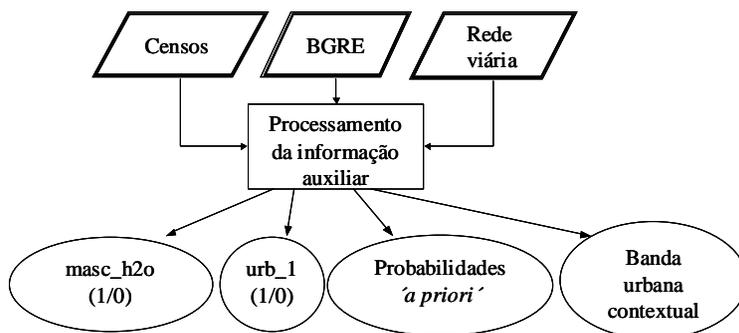


Como se pode constatar pela imagem anterior, existem diversas incoerências no mapa disponibilizado ao público pelo INE, existindo mesmo subsecções que estendem o seu raio de acção pelo Rio Tejo. Contudo, os problemas com a BGRE não terminaram com a eliminação destes pontos de fricção, também ao nível 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, pois claramente a informação não tinha sido armazenada na perspectiva de ser posteriormente integrada num destes sistemas.

3.2. Processamento da informação auxiliar

Corrigida a BGRE, realizaram-se, nesta fase do trabalho (figura 3), todas as operações relacionadas com o tratamento estatístico dos dados, incluindo o cálculo das probabilidades de ocorrência '*a priori*'. Os dados apurados permitiram ainda a criação de uma banda contextual a introduzir futuramente na classificação das imagens de satélite, possibilitaram a definição de um primeiro mapa binário traduzindo os usos urbano e não urbano (urb_1) e viabilizaram a criação de uma máscara que permitiu segmentar todas as imagens em água e não água (masc_h2o).

Figura 3 – Entrada e saída de informação no bloco correspondente ao processamento de informação auxiliar



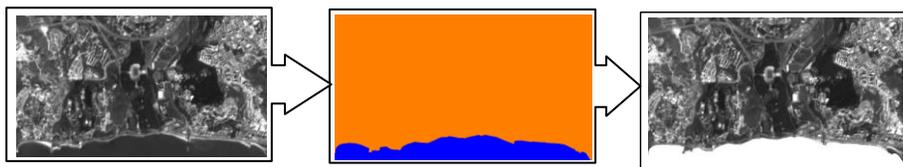
Para atingir um dos objectivos propostos para esta subsecção (criação da masc_h2o) optou-se por uma segmentação hierárquica, de forma a individualizar a mancha urbana. Começou por se retirar a área da imagem que corresponde ao Rio Tejo, ou seja, a parte identificada como água. Foi neste passo que se fez pela primeira vez uso da interacção com o informação não espectral (integração pré-processamento), na medida em que, muito embora os classificadores tradicionais consigam quase sempre identificar os pixel em questão com uma precisão de 100%,

não resolvem o problema dos que apresentam uma mistura de vários usos (nomeadamente junto à costa), conhecidos habitualmente como mixels.

Nestas situações, é comum pixels da linha de costa serem classificados como água, e vice-versa; esta questão foi resolvida, neste caso, com o recurso ao ficheiro gráfico (corrigido) da delimitação das subsecções, que apresenta o limite de costa perfeitamente definido (não existem subsecções estatísticas dentro de água) e que foi transformado num ficheiro *raster* binário, em que a área ocupada por água tinha valor 0 e a restante 1. Assim, recorrendo às leis da álgebra linear foi possível, multiplicando todas as imagens por esta máscara, extrair todas as áreas de água (figura 4).

No passo seguinte, e tendo em atenção a figura 3, procedeu-se a uma análise mais cuidada da informação estatística seleccionada (quadro 1), tendo em atenção os objectivos a atingir. Com efeito, na primeira escolha realizada tinha sido recolhida informação relativa aos indivíduos e aos alojamentos; no primeiro caso a opção tomada teve por base o trabalho de Weber e Hirsch (1992), 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, seguiu-se uma das regras de pós-classificação utilizadas no projecto DREU 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).

Figura 4 – Aplicação de uma máscara para isolar as áreas acima do nível do mar



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 nessa função (ver adiante informação sobre a criação de banda contextual).

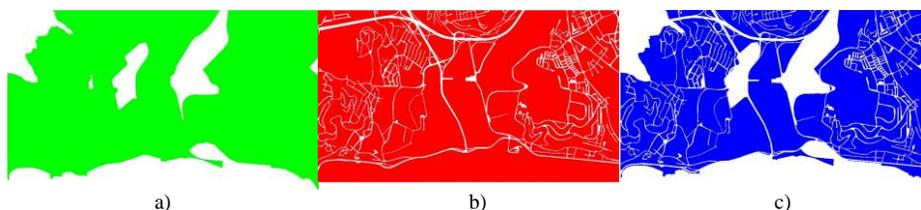
Quanto ao método utilizado no projecto DREU, este não poderia ser adaptado ao presente trabalho porque esta informação (alojamentos) se reporta ao interior dos edifícios; assim pode saber-se através dela que existem edifícios afectos, por exemplo à hotelaria, mas não se consegue saber qual é o seu número e, conseqüentemente, qual o seu peso no número total de edifícios. Logo, como o classificador de *Bayes* utiliza como parâmetros as probabilidades (entre outras) estatísticas 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 no quadro 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 também, 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 sua ordenação de forma crescente, que permitiu deste logo identificar as subsecções onde não existiam edifícios e, que, portanto, não são urbanas. Assim, estas subsecções não urbanas foram imediatamente excluídas da BGRE, uma vez que como se pretendia aplicar o algoritmo de *Bayes* apenas às áreas urbanas, não fazia sentido elas estarem representadas no mapa (BGRE) que iria servir de base ao cálculo das probabilidades estatísticas.

Retirando da BGRE 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). O ficheiro com as subsecções rurais (figura 5a) foi intersectado com a rede viária (figura 5b), que está integrada no tecido urbano, mas efectivamente não o é, dando origem à primeira máscara urbano-rural (figura 5c), indicada no esquema metodológico como urb_1 (figura 3). De seguida seleccionaram-se as classes que poderiam ser calculadas com recurso ao classificador de *Bayes*, já que as suas probabilidades estatísticas de ocorrência também podiam ser estimadas. As classes consideradas foram “Núcleo Antigo”, “Comércio e Serviços”, “Habitação Unifamiliar” e “Habitação Plurifamiliar”. Posto isto, foi necessário estabelecer as fórmulas de cálculo das probabilidades de ocorrência das quatro classes acima mencionadas, o que obrigou à definição de alguns conceitos iniciais.

Figura 5 – Criação da máscara urb_1 (na imagem final (c) a área presumivelmente urbana corresponde ao azul e a branco está a que de certeza é não urbana)

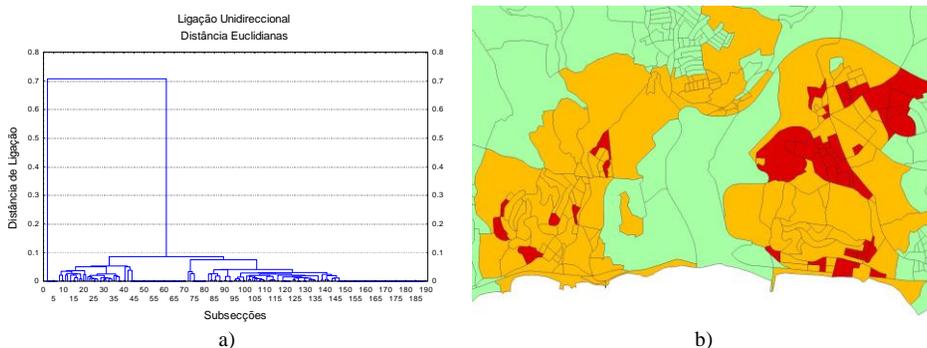


Assim, os edifícios com mais de dois pisos (pavimentos) foram considerados habitação plurifamiliar, e os de 1 ou dois pisos habitação unifamiliar. O núcleo antigo foi estabelecido como o conjunto de edifícios construídos até 1945, inclusivamente. Esta opção deveu-se ao facto de ser esta a data utilizada 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). Depois de calculadas estas quatro probabilidades para todas as subsecções (excepto aquelas que tinham 0 edifícios), passou-se à fase final deste bloco de operações. Nesta fase, foi possível, recuperando alguma informação que tinha sido descartada no processo de cálculo das probabilidades (densidade populacional, densidade de edifícios, percentagem de edifícios unifamiliares e plurifamiliares) e através de uma análise de *clusters* (dendograma na figura 6a) criar uma imagem que traduz as grandes áreas estruturantes do território em análise, constituindo uma banda de informação contextual.

No entanto, e face a algumas condicionantes (dendograma pouco expressivo), esta nova banda apenas foi criada de forma a estabelecer três grandes grupos (figura 6b) de subsecções (vermelho - subsecções fortemente urbanizadas, laranja - subsecções pouco urbanizadas e verde - subsecções com pouca probabilidade de terem edifícios). Por fim, para que esta classificação em *clusters* fosse útil ao processo de classificação espectral, os pixels de cada uma das três classes foram substituídos pelos valores médios das classes espectrais correspondentes.

**Figura 6 – a) Dendograma da classificação dos índices através de cluster
b) Banda contextual proveniente do processo de clustering**



Resta ainda referir que, devido ao facto da informação utilizada neste processo possuir características diferentes (densidades e percentagens), foi necessário normalizar os dados, de modo a torná-los compatíveis entre si e com o processo de *clustering* propriamente dito. Assim a variável normalizada (Z) foi calculada através da expressão:

$$Z = \frac{n - \mu}{\sigma} \quad (1)$$

com n a corresponder ao valor inicial do registo, μ à média da variável e σ ao desvio padrão da variável.

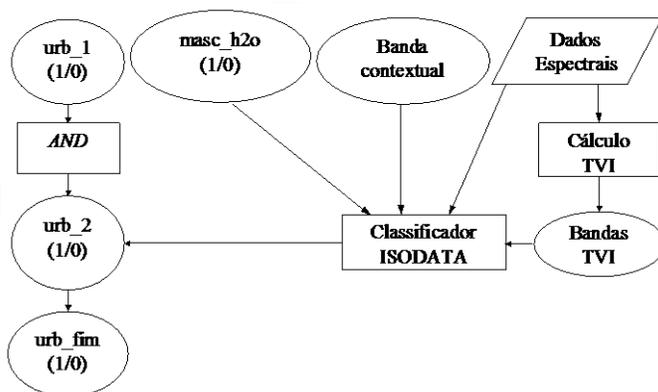
4. Metodologia de classificação

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

4.1. Estratificação pré-classificação

A informação auxiliar pode ser usada antes da classificação propriamente dita da imagem, de maneira a subdividir a imagem em estratos, que posteriormente serão processados individualmente. O objectivo é aumentar a homogeneidade das imagens estratificadas a serem classificadas, impedindo que determinados pixels sejam catalogados como pertencentes a uma classe à qual se sabe ‘*a priori*’ que não pertencem. Seguindo-se esta linha de acção, a estratificação geográfica foi efectuada de modo a obter três *layers* fundamentais - “água”, “urbano” e “não urbano” – que serão processados individualmente. Na fase de pré-processamento (secção 3) já tinham sido produzidas uma máscara binária (*masc_h2o*), que permitiu isolar em todas as bandas (as provenientes de satélites e a contextual) o uso “água”, e uma outra, também binária, que constituiu uma primeira aproximação à máscara “urbano/não urbano” (*urb_1*). O principal objectivo desta secção é produzir uma segunda máscara “urbano/não urbano” (*urb_fim*) ainda mais exacta que a primeira (figura 7).

Figura 7 – Diagrama dos processos efectuados na fase de estratificação pré-classificação



O primeiro passo correspondeu ao cálculo de índices de vegetação para as bandas SPOT e Landsat, nomeadamente o NDVI (*Normalised Vegetation Index*) e o

TVI (*Transformed Vegetation Index*), que, como todos os do género, registam a quantidade de biomassa existente à superfície, apresentando uma forte correlação com a densidade de construção (Jayamanna, 1996) e, conseqüentemente, permitindo uma maior diferenciação entre o espaço construído e não construído.

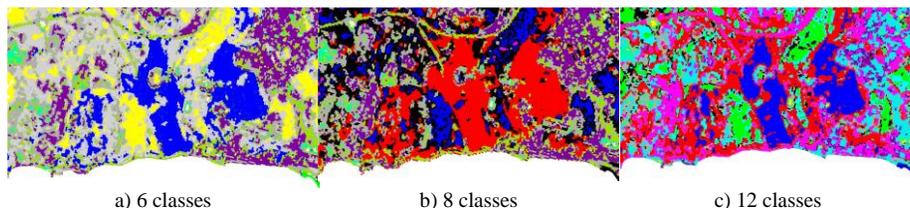
$$NDVI(LANDSAT) = \frac{TM4 - TM3}{TM4 + TM3} \quad (2), \quad NDVI(SPOT) = \frac{XS3 - XS2}{XS3 + XS2} \quad (3)$$

$$e \quad TVI = \sqrt{NDVI + 0.5} \quad (4)$$

O TVI foi calculado, pois ao adicionar 0,50 aos valores de NDVI e extrair-lhes a raiz quadrada evita a ocorrência de valores negativos (adição) e corrige os valores de NDVI de forma a deixarem de se assemelhar a uma distribuição de *Poisson* e passarem a constituir uma distribuição normal (raiz quadrada). Para que as bandas TVI pudessem ser utilizadas em conjugação com as bandas espectrais, tiveram ainda de ser sujeitas a uma expansão linear do contraste, para que os seus valores adoptassem uma amplitude de 256 valores.

No segundo passo, foi aplicado o algoritmo de classificação não dirigida ISODATA para classificar as bandas espectrais, as imagens correspondentes ao TVI SPOT e Landsat e a banda contextual (o propósito das masc_h2o é meramente o de excluir de todas estas imagens a região ocupada por água) em diversas classes (figura 8), tendo sempre como objectivo bem definido a estratificação “urbano/não urbano”.

Figura 8 – Exemplos de classificações obtidas pelo ISODATA

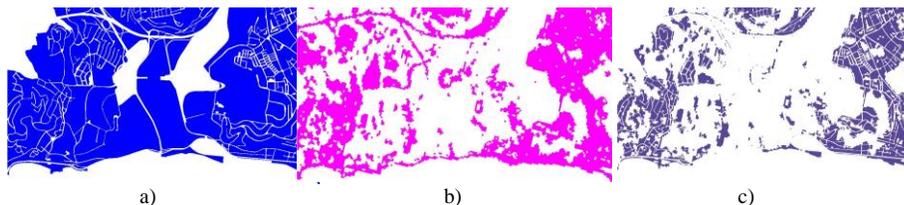


A razão para a escolha do algoritmo ISODATA para esta classificação prendeu-se com dois factores principais: 1 – a intenção de, nesta fase, não definir classes de uso e ocupação do solo; 2 – o conhecimento de trabalhos anteriores, afirmando que a conjugação deste algoritmo com uma banda contextual (semelhante à utilizada neste trabalho) pode melhorar os resultados da classificação em 10%. O melhor resultado (tendo em consideração a discriminação entre as áreas urbanas e não urbanas) foi obtido pela classificação em oito classes (figura 8b).

Reclassificando a imagem 8b 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 9b), que, ao ser intersectada (operação SIG – AND) com a urb_1 (figura 9a), deu origem ao mapa de

espaços urbanos (urb_fim) que serve de base à aplicação do algoritmo de *bayes* (figura 9c).

Figura 9 – Criação da máscara urb_fim (na imagem final (c) a cor azul corresponde à classe ‘urbano’)



As três máscaras criadas permitiram um incremento positivo na diferenciação urbano/rural, como se pode observar pelas medidas de exactidão expressas no quadro 3, 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, tornou-se, de uma maneira geral, mais fácil distinguir entre o urbano e o não urbano, mas perdeu-se algum pormenor em certas áreas o que fez baixar a precisão do consumidor (PC). A última máscara (urb_fim) apresenta uma melhoria de resultados em relação à 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 o não 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 na imagem que estava classificado como urbano na urb_2 e que foi praticamente banido da urb_fim.

Quadro 3 – Erros de omissão (EO), erros de comissão (EC), precisão do produtor (PP), precisão do consumidor (PC), KIA (*Kappa Index of Agreement*), índice *Kappa* e exactidão global (EG).

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

Ainda relativamente à qualidade dos dados, refira-se que a urb_2, calculada sem a banda contextual atingiu uma exactidão de 83,4%, e a mesma máscara estimada sem recurso às duas bandas TVI alcançou apenas 76,2%. Daqui se retira que a

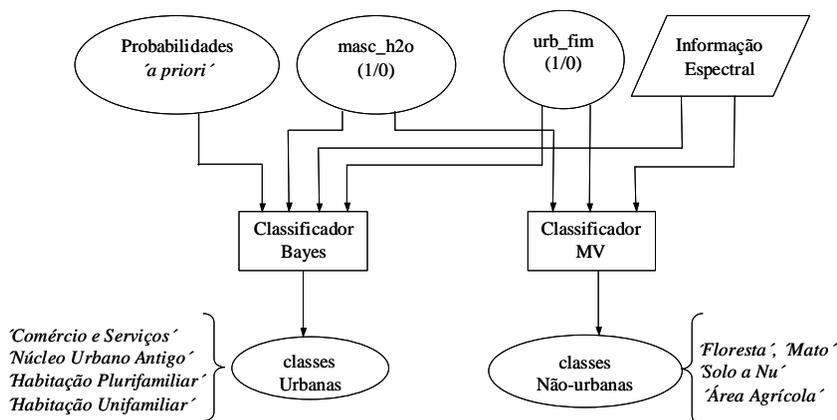
utilização do índice de vegetação constitui efectivamente uma mais valia para a metodologia desenvolvida (8,5%), e que a banda contextual, embora introduzindo alguns melhoramentos (1,3%), pode não constituir uma opção válida quando se entra em consideração com a dualidade tempo de (pré)processamento/qualidade dos resultados. De qualquer maneira, a decisão fica sempre a cargo do analista.

4.2. Operações de classificação

Na segunda fase da metodologia de classificação proposta, esquematicamente representada na figura 10, as máscaras binárias correspondentes aos usos água (*masc_h2o*) e urbano (*urb_fim*), são cruzadas com todas as bandas espectrais, dando origem a duas novas imagens por cada inicial; uma com os usos não urbanos (Mata, Mato, Solo a Nú, Agricultura, Vias, Praia, Grandes Equipamentos) e outra com os urbanos (Comércio e Serviços, Núcleo Urbano Antigo, Habitação Plurifamiliar, Habitação Unifamiliar, Indústria, Grandes Equipamentos).

Ao longo desta secção calculam-se as probabilidades espectrais de ocorrência de todas as classes de uso e ocupação, sendo as correspondentes a usos urbanos conjugadas com as suas correspondentes estatísticas. Assim, os usos Mata, Mato, Solo a Nú e Agricultura, pertencentes às imagens não urbanas, foram extraídos com recurso a um classificador de máxima verosimilhança. O passo seguinte na persecução dos objectivos propostos correspondeu à aplicação de um algoritmo de máxima verosimilhança sobre o conjunto das imagens urbanas, de forma a serem obtidas as probabilidades espectrais de cada classe de uso urbano. Para esse efeito, recorreu-se a uma opção que permite transformar este classificador num algoritmo flexível, ou seja, em vez de produzir uma classificação rígida e final de cada pixel, fornece várias imagens correspondentes ao grau de confiança (espectral) com que um pixel é atribuído a uma determinada classe.

Figura 10 – Esquema metodológico dos processos de classificação



Por sua vez, as probabilidades estatísticas (*'a priori'*) são apresentadas como uma imagem e referindo-se à área geográfica delimitada pelo *urb_fim*, existindo

uma para cada classe de uso urbano. Neste processo, os edifícios exclusivamente ou principalmente destinados a fins residenciais, com mais de dois pisos, foram considerados alojamentos multi-familiares. Os edifícios exclusivamente ou principalmente considerados para fins residenciais, com um ou dois pisos, foram considerados alojamentos unifamiliares. Os núcleos antigos urbanos foram incluídos nos edifícios construídos até 1945, inclusive. De facto, nos anos 40 ocorreu uma alteração no tipo de materiais utilizados na construção, facto que é perceptível nas imagens de satélite, o que permite uma correlação bastante significativa entre dois tipos de dados (espectrais e estatísticos). Os edifícios de comércio e serviços foram considerados como estando incluídos nos edifícios destinados para fins não residenciais, independentemente do ano de construção ou número de pisos.

As designações utilizadas para cada subsecção foram as seguintes:

- MFB_t: número de edifícios plurifamiliares;
- SFB_t: número de edifícios unifamiliares;
- CS: número de edifícios principalmente destinados para fins não residenciais;
- TB: número total de edifícios;
- MFB: número de edifícios plurifamiliares construídos depois de 1945;
- SFB: número de edifícios unifamiliares construídos depois de 1945;
- AUN: número de edifícios exclusiva ou principalmente residenciais, construídos antes de 1945.

As probabilidades de ocorrência ‘a priori’ serão dadas por:

$$p(\text{'Habitação Plurifamiliar'}) \equiv p(\text{MFB}) = \text{MFB}/\text{TB}$$

$$p(\text{'Habitação Unifamiliar'}) \equiv p(\text{SFB}) = \text{SFB}/\text{TB}$$

$$p(\text{'Núcleo Urbano Antigo'}) \equiv p(\text{AUN}) = \text{AUN}/\text{TB}$$

$$p(\text{'Comércio e Serviços'}) \equiv p(\text{CS}) = \text{CS}/\text{TB}$$

Como é evidente, a soma das quatro probabilidades tem de ser 1. Contudo, alguns dos índices (nomeadamente MFB, SFB e AUN) não estão disponíveis directamente na tabela 1. Por exemplo, esta tabela dá-nos o número de alojamentos multi-familiares e o número de edifícios construídos depois de 1945, mas não o número de edifícios multi-familiares construídos depois de 1945. Assim, foi adoptada a seguinte estratégia para o processamento das probabilidades ‘a priori’.

1. Compute $p(\text{CS}) = \text{CS}/\text{TB}$

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

$$p(\text{AUN}) = \text{AUN}/\text{TE}$$

$$p(\text{MFB}) = (\text{MFB}_t - \alpha \text{AUN})/\text{TE}$$

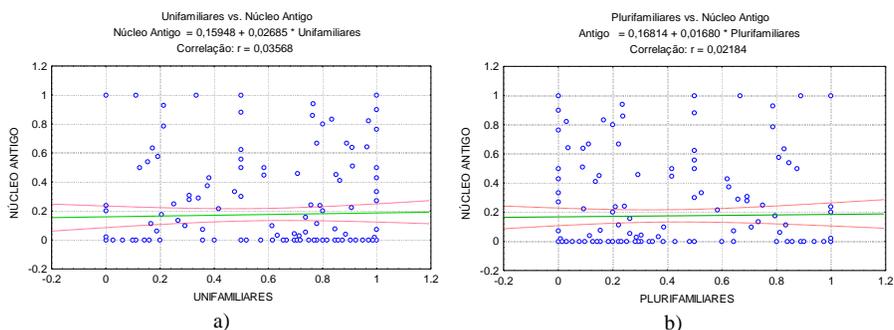
$$p(\text{SFB}) = (\text{SFB}_t - \beta \text{AUN})/\text{TE}$$

Os parâmetros α e β ($\alpha + \beta = 1$) dizem respeito aos edifícios antigos que são pluri e unifamiliares, respectivamente. Para obter estes resultados, tendo em atenção que não havia uma correlação significativa (figura 11) entre as variáveis, utilizou-se: $\alpha = \beta = 0.5$.

As bandas de probabilidades estatísticas, conjuntamente com as imagens de probabilidades espectrais, constituem a base para a aplicação do algoritmo de *Bayes*.

A utilização das probabilidades estatísticas permite diferenciar quatro classes urbanas – Comércio e Serviços, Núcleo Urbano Antigo, Habitação Plurifamiliar e Habitação Unifamiliar – que, devido às suas similaridades espectrais seriam, caso se utilizasse um algoritmo de máxima verosimilhança, erradamente classificadas. As áreas de treino (necessárias a ambos os classificadores utilizados) foram delimitadas sobre a composição colorida que melhor permitia diferenciar os diversos usos e na qual foi incorporada a banda SPOT pancromática através da transformação entre espaços de cor RGB-IHS-RGB.

Figura 11 – Regressão linear e correlação entre os edifícios unifamiliares e os edifícios plurifamiliares com os edifícios anteriores a 1945



Por sua vez, as probabilidades espectrais correspondentes aos usos urbanos foram integradas com as probabilidades estatísticas através do classificador de *Bayes*, utilizando-se para o efeito um pequeno programa desenvolvido e baptizado de IDECIS (Integração de Dados Estatísticos na Classificação de Imagens de Satélite). A aplicação em questão está estruturada em dois módulos, sendo o primeiro designado SIG, na medida em que é nele que são apuradas as probabilidades finais de cada pixel pertencer a uma determina classe (classificação com incerteza); o segundo módulo, referenciado como calculadora, transforma o algoritmo numa espécie de classificador rígido, ou seja, numa análise pixel a pixel, vai retribuir a classe com maior probabilidade.

A aplicação do IDECIS resultou na criação de quatro bandas (uma para cada classe de uso urbano) de probabilidades *'a posteriori'*, que permitiram uma análise indiferenciada dos dados (*fuzzy*). No entanto, na aplicação em questão, dado a ausência de informação que potenciasses este tipo de abordagem, optou-se por uma classificação rígida, atribuindo-se cada pixel à classe que tinha maior probabilidade de pertencer.

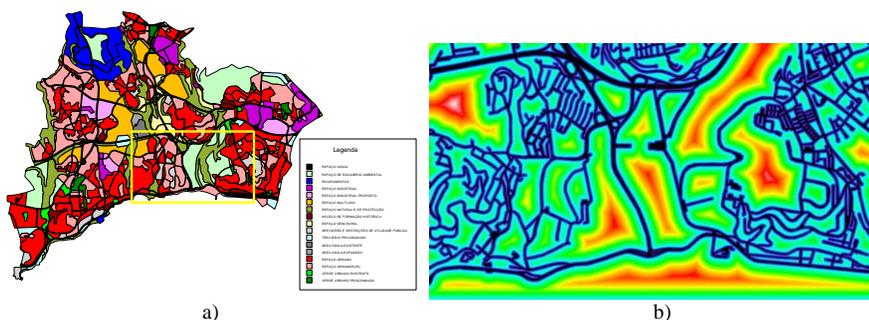
Para terminar, note-se que as vias já existiam em formato vectorial (rede viária), pelo que a sua inclusão na classificação final só dependeu de uma prévia conversão para formato matricial. As classes Praia, Grandes Equipamentos (urbanos e não urbanos) e Indústria serão calculadas na secção seguinte, recorrendo-se para o efeito ao PDM e a regras de pós-classificação.

4.3. Regras de pós-classificação

Esta (última) fase 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 o 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 de 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_fin), mas assinalados com indústria no PDM (figura 12a);
- Equipamentos Desportivos - pixels classificados como mato ou solo a nú, 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 12b). Para este caso ainda se confrontaram os dados 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 um tanto ou quanto abrangentes, de modo que não foi possível otimizar a utilização desta informação. Os restantes grandes equipamentos foram retirados da classe do PDM, “equipamentos existentes”.

Figura 12 – a) Planta de Ordenamento do PDM de Oeiras b) Distâncias relativamente à rede viária



Todas as classes apuradas foram então integradas num mapa de classificação final mediante a aplicação de um algoritmo que assenta no pressuposto que, uma classe não se pode sobrepor a outra já atribuída, redundando este facto na seguinte ordem de operações:

- A classificação das pixels é levada a efeito com base numa perspectiva classe a, sendo preconizada da classe com maior nível de confiança para a com menor, nomeadamente:
 1. Vias (retiradas directamente da rede viária)
 2. Água (retirada da masc_h2o)
 3. Comércio e Serviços e Núcleo 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)

O mapa resultante desta operação foi então sujeito a uma avaliação visual pós-processamento, com base no PDM. Considerava-se, por exemplo, que existindo neste plano uma classe denominada indústria existente, se ela coincidissem com um espaço classificado como urbano então este último teria sido alterado para industrial. Tal não aconteceu pois as classes da planta de ordenamento revelaram-se demasiado generalistas, não beneficiando em nada a classificação final. A título de exemplo refira-se um espaço industrial situado a Nordeste na área de estudo, que por estar incluso no tecido urbano e instalado num edifício de características em tudo idênticas aos destinados à habitação foi classificado como tal. Esperava-se que o PDM se reportasse àquele lugar como indústria existente, mas ao invés, apresenta-se como urbano existente, validando portanto, a classificação do modelo. Posto isto, a carta de uso e ocupação do solo ficou assim organizada (figura 13):

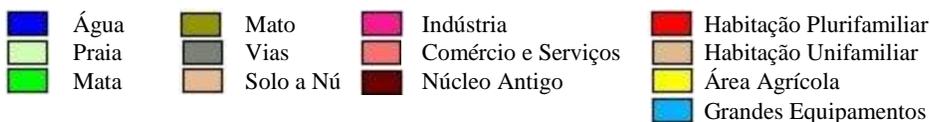
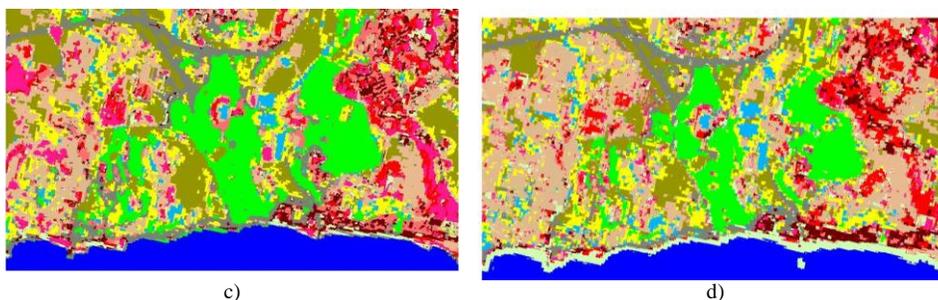
Figura 13 –Uso do solo resultante: a) da aplicação do método proposto; b) da foto-interpretação; c) dos classificadores da mínima distância; d) do classificador de máxima verosimilhança



a)



b)



5. Validação dos Resultados

Chegado ao fim de todo este processo resta apenas aferir a validade da metodologia implementada o que, paradoxalmente, apesar de ser o último procedimento, acaba por se assumir como um dos mais (se não o mais) importantes.

No 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 13b) 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 exaustiva, pixel por pixel, de toda a imagem. Como primeira abordagem comparou-se a realidade do terreno (figura 13b) com o método desenvolvido e os classificadores paramétricos tradicionais, nomeadamente, o da mínima distância com distâncias normalizadas (figura 13c) e da máxima verosimilhança (figura 13d).

Relativamente ao presente estudo, e observando os resultados apresentados pelos classificadores testados (quadro 4) face à exactidão global, ressalva a superior prestação (+ 33%) do algoritmo desenvolvido. Como seria de esperar o método do paralelepípedo foi o que piores resultados apresentou e registou-se um certo equilíbrio entre os da mínima distância (37,8%) e máxima verosimilhança (36,5%), com uma ligeira vantagem para o primeiro, face ao carácter assimétrico da distribuição dos dados.

Quadro 4 – Índice *Kappa* relativo a cada um dos classificadores para a área teste

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
IDECS	0,67	70,5

Analisando os resultados numa perspectiva classe a classe (quadros 5 e 6), verifica--se que o IDECS obtém constantemente melhores resultados, com a excepção das classes 4 (mato) e 7 (indústria). O método proposto falhou

completamente a classificação das áreas industriais porque, neste caso, dependia exclusivamente das regras de pós-classificação, como a qualidade da informação existente no plano que sustentava essas regras era deficiente, não permitiu identificar as áreas em questão.

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 relativa fidelidade, classes que são “invisíveis” para os satélites (ex. comércio e serviços).

Quadro 5 – Erros de comissão (EC) e omissão (EO) para cada uma das classes

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. Mata	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 Nú	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 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

Quadro 6 – Índice KIA, exactidão global (EG), precisão do produtor (EP) e precisão do consumidor (EC) por classe

Classes	Mínima Distância				IDECIS			
	KIA	EG	PP	PC	KIA	EG	PP	PC
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. Mata	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 Nú	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 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

Antes de dar por terminada esta etapa importa avaliar a adaptabilidade deste encadeado de processos a novas situações, repetindo-se, para o efeito, todos os

passos expostos ao longo deste processo, 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 (Quadro 7), apresentando o IDECIS uma exactidão na ordem dos 92% (melhoria de cerca de 20%).

Quadro 7– Coeficiente Kappa e exactidão global relativos a cada um dos classificadores para a área de verificação

Classificador	Índice <i>Kappa</i>	Exactidão Global (%)
Mínima distância	0,46	47,8
IDECIS	0,89	92,1

A primeira hipótese avançada como justificação para esta nova realidade 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 melhor, esta ao ser mais homogénea 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 (quase 48%), não teve uma melhoria tão evidente. Deste modo, considerando que os cerca de 12% que o método da mínima distância ganhou se deveram à menor diversidade de usos na área de verificação, ainda sobra uma margem de 9% no caso do IDECIS, que pode ser imputada a uma melhoria nas regras de pós-processamento.

Numa observação categoria a categoria (quadro 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 performances aperfeiçoadas em 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.

Noutras classes como a habitação plurifamiliar (10) e 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 promiscuidade de usos. Por fim, refira-se que a classificação das áreas agrícolas foi bastante mais exacta porque o tipo de cultura (cereais e vegetais) é diferente do que se verificava na área situada a Norte (pomares), que se confundia espectralmente com a classe 3 (mata).

Outras classes como a Praia (14) e o Solo a Nú (6) apresentaram resultados melhores, não necessariamente porque foram melhor classificados, mas porque a sua importância relativa na imagem diminuiu.

Quadro 8 – Índice KIA, exactidão global (EG), precisão do produtor (EP) e precisão do consumidor (EC) por classe

Classes	Mínima Distância				IDECIS			
	KIA	EG	PP	PC	KIA	EG	PP	PC
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. Mata	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 Nú	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 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

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 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 uma *decalage* de 10 anos relativamente à fase de recolha. No presente caso a informação apresenta diferenças de 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 toma uma faceta crítica em casos de grandes renovações urbanas, como a que teve lugar aquando da EXPO'98, podendo-se apenas minimizar 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. Ora, uma vez que não há uma legislação que forneça directivas eficazes de 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. Isto porque 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 conectado 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 os satélites estão “mais à vontade”. 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.

Por fim, para terminar este rol de condicionantes enumera-se novamente a base de validação. Efectivamente esta foi realizada sobre um ortofotomapa à escala 1:10000, 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 identificar, por exemplo, uma área de 5000 km² com um espaço verde incluso com 300 m² tem tendência a considerar tudo como mancha urbana enquanto na classificação automática de imagens de satélite, nem que exista um só pixel com reflectância diferente, ele é adjudicado à outra classe. Embora esta situação possa ser atenuada através da aplicação de filtros passa-baixo, nunca é totalmente resolvida, pelo que também deve ser considerada como uma fonte de possíveis erros.

Agradecimentos

O autor agradece à Fundação para a Ciência e a Tecnologia (FCT) que apoiou este trabalho através da atribuição de uma bolsa de Mestrado (Ref. PRAXIS XXI/BM/15182/98).

Bibliografia

- Achen, M. (1992) - “Landsat TM Data for Municipal Environment Planning. Studies of Vegetation Indices on Urban Areas”, *Proceedings of the XVII ISPRS congress*, Washington, USA, vol. 19.
- Caetano, M.; Santos, J. P.; Navarro, A. (1997) - “Uma Metodologia Integrada para Produção de Cartas de Uso do Solo Utilizando Imagens de Satélite e Informação Geo-referenciada não Espectral”, *Cartografia e Cadastro*, 6, pp. 71 – 78, 1997.

- Gong P.; Howarth, P. J. (1990) - "The Use of Structural Information for Improving Land-Cover Classification Accuracies at the Rural-Urban Fringe", *Photogrammetric Engineering & Remote Sensing*, 56, pp. 67-73.
- Jayamanna, S. B. (1996) - "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.
- Martin, L. R. G.; Howarth, P. J.; Holder, G. (1988) - "Multispectral Classification of Land Use at the Rural-Urban Fringe Using SPOT Data", *Canadian Journal of Remote Sensing*, 14, pp. 72-79.
- Mesev T.; Longley, P.; Batty, M. (1996) - "RS/GIS and the Morphology of Urban Settlements", *Spatial Analysis: Modelling in a GIS Environment*, P. Longley e M. Batty, pp. 123-148, John Wiley & Sons.
- Mesev, T. (1998) - "The Use of Census Data in Urban Classification", *Photogrammetric Engineering & Remote Sensing*, 64, pp. 431-438.
- Sadler, G. J.; Barnsley M. J. (1990) "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, pp. 968-977, EGIS Foundation, Utrecht.
- Tenedório, J. A. (1998) - "Télédétection 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 Doutorado, Universidade de Paris XII, p. 254.
- Weber, C.; Hirsch, J. (1992) - "Some Urban Measurements from SPOT Data: Urban Life Quality Indices", *International Journal of Remote Sensing*, 13, pp. 3251-3261.
- Welch, R. (1982) - "Spatial Resolution Requirements for Urban Studies", *International Journal of Remote Sensing*, 2, pp. 139-146, 1982.