

# Utilização de dados indiferenciados em detecção remota

Criação de mapas de uso e ocupação do solo em áreas periurbanas com  
recurso a dados indiferenciados (*fuzzy*)

**ROCHA, Jorge; TENEDÓRIO, José António; SOUSA, Paulo Morgado**

## RESUMO

*A questão dos dados indiferenciados (fuzzy) mereceu, nos últimos anos, uma atenção considerável por parte da comunidade científica ligada à detecção remota. Reconhecendo-se que os classificadores tradicionais, baseados em classes rígidas e discretas, contribuem em grande parte para a inexactidão dos mapas temáticos produzidos por classificação de imagens de satélite, a noção de que um pixel pode pertencer parcialmente a uma classe constitui uma alternativa atractiva à lógica de dois valores implícita na maioria dos processos de classificação.*

*O objectivo deste trabalho é o de comparar o valor informativo de um mapa temático produzido através do tradicional classificador de máxima verosimilhança e um outro produzido através de técnicas de classificação fuzzy. Esta análise comparativa foi realizada utilizando imagens Landsat 7 ETM+ relativas ao ano 2000 e cobrindo uma área teste correspondente a um rectângulo com 2300 m de altura por 4000 m de largura, conduzindo a uma área um pouco superior a 9 km<sup>2</sup>. A área de teste situa-se na Área Metropolitana de Lisboa, mais especificamente no concelho de Oeiras e constitui um exemplo típico de ocupação periurbana.*

*Os resultados deste estudo comparativo revelaram que a abordagem fuzzy produz uma classificação mais detalhada e precisa, sugerindo que a indiferencialidade pode efectivamente expandir a utilidade dos mapas desenvolvidos com técnicas de detecção remota.*

**PALAVRAS-CHAVE:** *Detecção Remota, Uso e Ocupação do Solo, Dados indiferenciados (fuzzy)*

## I - INTRODUÇÃO

A classificação de imagens de satélite implica a imposição de uma escala nominal de categorias para representar os padrões espectrais de resposta contidos num conjunto de dados multiespectrais. A natureza do sistema de classificação seleccionado para relacionar as características espectrais de um pixel com uma classe específica, como por exemplo uma classe de ocupação do solo, é por si só, parte constituinte do problema da classificação, pois diferentes classificadores podem conduzir a resultados bastante diversos.

Questões como a resolução espectral, radiométrica e espacial dos sensores utilizados na classificação, a existência e/ou criação de *mixels*, e a eficiência computacional do algoritmo escolhido para proceder à classificação, são factores que normalmente condicionam o processo de classificação, contribuindo para o resultado final com erros e incertezas. No entanto, enquanto que estas limitações são bastante conhecidas da comunidade científica operante na área da detecção remota, tendo encorajado um grande número de investigações com o intuito de melhorar as metodologias e as questões técnicas, outros problemas, não menos importantes, tem sido um pouco esquecidos. Um exemplo, é a questão

relacionada com o significado e a clareza linguística das categorias nominais inerentes ao sistema de classificação e a inexactidão introduzida nesse mesmo sistema em função da categorização utilizada.

Numa classificação, ao desviar-se a atenção para o sistema utilizado e para o significado das várias categorias que constituem a sua estrutura, o problema (da classificação) expande-se de forma a incluir considerações sobre com que grau as categorias de informação representam, não só a imagem, mas também o contexto cultural e físico que esta reflecte. Neste caso, o problema da classificação resume-se à questão de quanto as variáveis que formam o sistema são representativas da natureza da superfície representada na imagem.

Efectivamente, a maioria dos algoritmos tradicionalmente utilizados em detecção remota partem do princípio que as áreas em análise são compostas por um número de classes únicas e internamente homogéneas que podem ser identificadas com informação espectral, auxiliar e recolha de informação no terreno. Mas, na realidade, esta assunção não se mostra válida para áreas com grande variedade de usos e ocupações (*fuzzy areas*). O termo *fuzzy* aplica-se devido à presença de *mixels* (pixels que não são completamente compostos por uma classe única e homogénea) e estes, são por sua vez, o resultado de uma resolução espacial insuficiente para fazer frente às solicitações da aplicação (quando as características da superfície variam continuamente).

O problema fundamental ao elaborar mapas de área periurbanas 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 que uma classe temática. Face a esta constatação têm sido propostas diversas abordagens para adaptar os classificadores à realidade do espaço periurbano [1][3], considerando-se como indiferenciados (*fuzzy*) aqueles que permitem atribuir a cada pixel propriedades múltiplas ou parciais relativamente à hipotética classe em que se enquadram. Assim considera-se que o conceito de conjunto de dados indiferenciados (ou indistintos) é preponderante para este tipo de classificação. Pode-se então afirmar que as classes não têm limites abruptos, a transição entre pertencer-lhes e não lhes pertencer é gradual, embora, em casos excepcionais, possam existir classes com limites abruptos.

O objectivo deste trabalho é o de comparar o valor informativo de um mapa temático produzido através do tradicional classificador de máxima verosimilhança e um outro produzido através de técnicas de classificação *fuzzy*. O primeiro passo na persecução deste objectivo centrou-se na escolha da área teste, onde a metodologia foi aplicada. Optou-se por seleccionar uma área correspondente a um rectângulo com 2300 m de altura por 4000 m de largura, conduzindo a uma área um pouco superior a 9 km<sup>2</sup>. Em termos geográficos, a escolha recaiu no concelho de Oeiras e, particularmente, na zona envolvente ao Estádio Nacional. 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.

Com efeito, no município de Oeiras ainda se fazem sentir os efeitos da periurbanização, entendida como uma progressão urbana processada de forma difusa, sobre extensas áreas, inserindo-se a actividade residencial e/ou algumas actividades económicas de tipo urbano no meio rural, não anulando a actividade agrícola, embora cause amplas alterações culturais e sociais na fronteira urbano-rural, assistindo-se a uma confluência de espaços florestais, agrícolas, expectantes (livres), industriais, comerciais e habitacionais, uni e plurifamiliares, com alguns focos (cada vez menos) de clandestinos.

## II - A TEORIA DOS DADOS INDEFERENCIADOS (*FUZZY*)

Um vasto grupo de algoritmos utilizados em detecção remota parte do principio que as áreas em análise são compostas por um número de classes únicas e internamente homogéneas, o que por diversas vezes se tem provado que não corresponde à realidade [2]. Face a esta constatação têm sido propostas diversas abordagens para adaptar os classificadores aos fenómenos naturais, considerando-se que são indiferenciados (*fuzzy*) porque permitem atribuir a cada pixel propriedades múltiplas ou parciais relativamente à hipotética classe em que se enquadram. Assim considera-se que o conceito de conjunto de dados indiferenciados (ou indistintos) é preponderante para este tipo de classificação. Pode-se então afirmar que as classes não têm limites abruptos (figura 1), a transição entre pertencer-lhes e não lhes pertencer é gradual, embora, em casos excepcionais, possam existir classes com limites abruptos. A esta característica, diga-se de inclusão (também conhecida como probabilidade), são atribuídos valores de 0 a 1.




Figura 1 - Comparação entre uma transição abrupta e a fuzzy

A partição dos dados levada a efeito pelo classificador indiferenciado pode ser descrito através de uma matriz:

$$\begin{bmatrix} f_{F_1}(X_1) & f_{F_1}(X_2) & \Lambda & f_{F_1}(X_n) \\ f_{F_2}(X_1) & f_{F_2}(X_2) & \Lambda & f_{F_2}(X_n) \\ M & M & O & M \\ f_{F_m}(X_1) & f_{F_m}(X_2) & \Lambda & f_{F_m}(X_n) \end{bmatrix} \quad (1)$$

com  $f_{F_i}$  a corresponder à função de propriedade (pertença) do conjunto de dados indiferenciados  $F_i$  ( $1 \leq i \leq m$ ),  $n$  é o número de pixels e  $X_i$  é o vector de medição do pixel  $i$  ( $1 \leq i \leq n$ ).

A lógica de dados indiferenciados pode ser utilizada para calcular a média indiferenciada e as matrizes de covariância indiferenciada. Por exemplo a média indiferenciada pode ser calculada através de:

$$\mu_c = \frac{\sum_{i=1}^n f_c(X_i) X_i}{\sum_{i=1}^n f_c(X_i)} \quad (2)$$

onde  $n$  é o número total de vectores de medição dos pixels de amostra,  $f_c$  é a função de propriedade da classe  $c$  e  $X_i$  é o vector de medição de um pixel de amostra ( $1 \leq i \leq n$ ). A covariância indiferenciada é dada por:

$$V_c = \frac{\sum_{i=1}^n f_c(X_i) (X_i - \mu_c) (X_i - \mu_c)^T}{\sum_{i=1}^n f_c(X_i)} \quad (3)$$

Ao calcular-se a média indiferenciada para a classe  $c$ , o vector de medição do pixel de amostra é multiplicado pelo seu grau de pertença a  $c$ ,  $f_c(X)$ , antes de ser adicionado ao somatório. Do mesmo modo, ao estimar-se a matriz de covariância indiferenciada para a classe  $c$ ,  $(X_i - \mu_c) (X_i - \mu_c)^T$  é multiplicado por  $f_c(X)$  antes de ser adicionado.

Para operar uma partição indiferenciada do espaço é preciso, em primeiro lugar, definir uma função de propriedade para cada uma das classes. Uma das formas de calcular estas probabilidades é, assumindo a normalidade dos dados, considerar o classificador da máxima verosimilhança com base na estimação duma função de probabilidade de densidade ( $P$ ), para cada uma das classes em consideração e utilizando a média e a covariância indiferenciadas em substituição das originais. A função de propriedade da classe  $c$  é dada por:

$$f_c(X) = \frac{P_c(X)}{\sum_{i=1}^m P_i(X)} \quad (4)$$

onde

$$P_i(X) = \frac{1}{(2\pi)^{N/2} |V_i|^{1/2}} \times \exp\left[-\frac{1}{2}(X - \mu_i)^T V_i^{-1}(X - \mu_i)\right] \quad (5)$$

com  $N$  a representar a dimensão dos vectores do pixel,  $m$  o número de classes e  $i$  está contido entre 1 e  $m$ . Os graus de pertença do vector  $X$  de um pixel de pendem da sua posição no espaço espectral;  $f_c(X)$  aumenta exponencialmente com o decréscimo de  $(X - \mu_i)^T V_i^{-1}(X - \mu_i)$ , ou seja a distância de Mahalanobis medida entre  $X$  e a classe  $c$ . O valor

$$\sum_{i=1}^m P_i(X) \quad (6)$$

funciona como factor de normalização. A cada pixel é depois atribuída uma classe em função das probabilidades à posteriori ( $L$ ), onde a possibilidade de o pixel  $x$  pertencer à classe  $i$  pode ser determinada pela equação. Como exemplo da utilidade desta metodologia observe-se a tabela 1 onde oito hipotéticos pixels (catalogados de A a H) estão ordenados segundo as probabilidades de pertencerem a uma determinada classe (grau de pertença). Os pixels homogéneos e os *mixels* podem ser facilmente diferenciados através da análise da tabela de incerteza (indiferenciada), por exemplo, os pixels C, F, G e H são considerados *mixels*, enquanto que os A, B, D e E são relativamente homogéneos.

	A	B	C	D	E	F	G	H
<b>Água</b>	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
<b>Indústria</b>	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
<b>Residencial</b>	0,00	0,00	0,00	0,00	0,99	0,63	0,38	0,23
<b>Floresta</b>	0,99	0,77	0,53	0,00	0,00	0,13	0,00	0,00
<b>Relva</b>	0,00	0,33	0,35	0,87	0,00	0,22	0,17	0,00
<b>Pasto</b>	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,13
<b>Solo a Nu</b>	0,00	0,00	0,00	0,12	0,00	0,00	0,35	0,62

**Tabela 1 - Classificação indiferenciada de oito pixels em sete classes**

Os graus de pertença permitem estimar a percentagem de cada classe de uso e ocupação do solo que compõe o pixel. Pode-se assim, estimar que o pixel A é composto em 99% por floresta, o B por floresta (77%) e relva (33%) e o D por relva (87%) e solo a nu (12%). Esta informação reveste-se de grande utilidade e pode ser utilizada para produzir um mapa, ou uma série de mapas, que contenha(m) informação mais robusta, na medida em que se assemelha(m) mais com o “mundo real”. Com estes dados, um analista pode aplicar uma lógica booleana simples para produzir novos mapas, mostrando apenas, por exemplo, todos os pixels com uma percentagem de floresta e de relva superiores a 70% e 20%, respectivamente (o pixel B satisfaz este critério). Por outro lado, estes dados podem ser utilizados para produzir uma classificação rígida, atribuindo-se à probabilidade mais alta de cada coluna o valor um e às outras zero. O mapa rígido seria criado atribuindo o pixel à classe cujo valor de probabilidade seria agora de um.

### III - AQUISIÇÃO DE DADOS E CLASSIFICAÇÃO

Antes de iniciar o processo de classificação foi necessário otimizar toda a informação de modo a maximizar o seu potencial informativo. Neste contexto, as imagens de satélite foram sujeitas a um melhoramento do contraste, sendo posteriormente geo-referenciadas utilizando um ortofotomapa da região em estudo (escala 1: 10000). O processo de reclassificação assegurou que a resolução espacial das diferentes bandas igualasse o da banda de máxima resolução (Landsat ETM+ Pancromática, 15m x 15 m).

#### 1- Melhoramento 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 radiancia 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, originando um contraste pouco perceptível entre tipos de ocupação distintos. 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 método utilizado para alterar o contraste da imagem foi o da expansão linear do contraste. Neste método, o mais utilizado em detecção remota visto não alterar os níveis radiométricos dos pixels, o conjunto de valores digitais da imagem inicial é uniformemente expandido, de forma a preencher toda a gama de valores da imagem de saída. 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.

## 2- Geo-referenciação

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.

Considerando que há todo o interesse em que, no processo de geo-referenciação, a base de referência seja uma imagem com resolução espacial igual ou superior à das imagens a registar, e para evitar que as imagens registadas adquirissem, 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 Landsat Pancromática (resolução espacial de 15 m) existem evidentes analogias visuais, o mesmo já não acontece em relação às bandas Landsat Multiespectrais (resolução espacial de 30 m, à excepção da térmica – 60m).

Assim sendo, começou por se geo-referenciar a imagem Landsat pancromática, na medida em que esta é a que apresenta uma maior resolução espacial (15 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 7,5 m sobre o terreno, ou seja, o equivalente a metade de um pixel da imagem em questão. O processo foi depois repetido para as restantes imagens Landsat ETM+ (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 2, apresentam-se o número de pontos de controlo utilizados para as várias operações de geo-referenciação, bem como o erro médio de cada uma destas operações e o erro máximo encontrado.

IMAGENS	Número de Pontos de Controlo	Erro Médio (m)	Ponto com Maior Erro (m)
Landsat ETM+ Pancromática	34	2,249	2,3
Landsat ETM+ Multiespectral	18	5,850	9

Tabela 2 – Parâmetros do processo de georeferenciação

Inerente ao processo de geo-referenciação está um outro que visa alterar verdadeiramente a geometria da imagem, de modo a que ela fique compatível com a base cartográfica. Isso significa transformar (distorcer) a imagem de maneira a que a sua matriz se torne quadrática, com as linhas e as colunas a adoptarem uma orientação vertical e horizontal, respectivamente. Quando isso acontece, pode recorrer-se a vários métodos de interpolação, também conhecidos como métodos de reamostragem. Pelas suas características (não altera os valores dos pixels), o método do vizinho mais próximo é o mais utilizado em detecção remota, 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 (15 m), viabilizando assim a compatibilização entre as bandas multiespectrais e pancromática.

## 3- Fusão entre as a banda pancromática e as bandas multiespectrais

Constatando-se a incapacidade dos classificadores clássicos lidarem com as especificidades do espaço periurbano, a primeira justificação para o facto incidiu sobre as características – leia-se capacidades - dos sensores, mais especificamente, sobre a sua resolução espacial. A informação recolhida pelos sensores a bordo do Landsat foi considerada como inadequada para uma classificação precisa e consistente, muito embora permitisse detectar as características urbanas e viabiliza-se a divisão entre edificado e não edificado; por outro lado SPOT, apesar de conduzir a resultados satisfatórios em

diversas aplicações como a detecção de alterações, mostrou-se, menos eficaz numa divisão em classes. Como se não bastasse, as imagens multiespectrais SPOT apresentam ainda fortes condicionalismos em termos de resolução espectral, face às especificidades inerentes ao meio periurbano.

Na tentativa de resolver estes problemas, têm sido levadas a efeito algumas experiências de forma a produzir uma imagem híbrida, que conjugue as capacidades espectrais do sensor TM com a resolução espacial da banda pancromática SPOT, e mais recentemente com a Landsat ETM+ pancromática. Tendo em vista o aumento da resolução espacial, diversas técnicas têm sido testadas para fundir imagens com diferentes características. Estas técnicas assentam basicamente em dois métodos que, por serem aqueles que até à data apresentaram os melhores resultados, têm sido os mais utilizados. As abordagens referidas são a conversão entre espaços de cor RGB (*Red, Green, Blue*) - *IHS (Intensity, Hue, Saturation)* - RGB e a Substituição de Componentes Principais (PCS - *Principal Component Substitution*).

A PCS foi a escolhida para utilização neste trabalho porque tem a vantagem de operar com um maior número de bandas e permite uma maior qualidade geométrica dos dados, perdendo apenas um pouco das características radiométricas [8]. A PCS funciona nos mesmos moldes que a análise de componentes principais (PCA - *Principal Components Analysis*), conhecida originalmente como transformação de Karhunen-Loève. Esta, corresponde simplesmente a uma combinação linear dos valores originais. O propósito deste procedimento é comprimir toda a informação contida num conjunto de  $n$  bandas num outro de dimensão igual ou inferior a  $n$ . Ou melhor, a PCA é uma transformação ortogonal de um conjunto  $n$ -dimensional de imagens, que produz um novo grupo de imagens (componentes) não correlacionadas entre si e ordenadas relativamente à variância (quantidade de informação) que representam relativamente ao conjunto inicial de imagens. Esta transformação é utilizada para realçar a dimensionalidade escondida dos dados multiespectrais, através da remoção da redundância.

Ao comprimir os dados multiespectrais, calculando os seus valores para um novo sistema de coordenadas, a PCA define dois novos eixos: um orientado ao longo da distribuição ( $Y_1$ ) e outro ( $Y_2$ ) perpendicular a  $Y_1$ . Ou seja, considerando um diagrama de dispersão onde estão esquematicamente representados os pixels das bandas TM1 e TM2, de acordo com os seus números digitais iniciais. Sobrepostos aos eixos das bandas TM1 ( $X_1$ ) e TM2 ( $X_2$ ) estão dois novos eixos ( $Y_1$  e  $Y_2$ ), rodados relativamente aos primeiros, e com origem no centro da distribuição. O eixo  $Y_1$  define a direcção da primeira componente principal e  $Y_2$  a da segunda. Os dados são transformados linearmente do espaço multiespectral para o espaço dos vectores próprios dos dados, através da equação:

$$Y = A^T X \quad (7)$$

onde  $X$  representa o vector ( $n \times 1$ ) de um conjunto de bandas ( $n$ ) e a matriz  $A$  transforma ortogonalmente a matriz de covariância de  $X$ , de forma a que a matriz de covariância de  $Y$  seja diagonal (considerando que  $\lambda_1 > \lambda_2 > \dots > \lambda_n$ ):

$$Cov_Y = ACov_X A^T = \begin{bmatrix} \lambda_1 & 0 & 0 & 0 & 0 \\ 0 & \lambda_2 & 0 & 0 & 0 \\ 0 & 0 & \dots & 0 & 0 \\ 0 & 0 & 0 & \dots & 0 \\ 0 & 0 & 0 & 0 & \lambda_n \end{bmatrix} \quad (8)$$

Deve-se referir que os dados apresentam uma maior variância (ou amplitude dinâmica) ao longo da primeira componente principal do que relativamente aos eixos iniciais, o que já não se verificava (apresenta uma variabilidade bastante mais reduzida) relativamente à segunda componente principal. Esta característica é comum a todas as componentes principais. A análise em componentes principais pode ser realizada para conjuntos multiespectrais de dados  $n$  dimensionais, sendo as coordenadas das direcções adicionais definidas sequencialmente. Cada nova coordenada está perpendicularmente orientada face às orientações previamente definidas e na direcção da máxima densidade de pontos. Para cada pixel, são calculados novos números digitais relativamente a cada um dos novos eixos, sendo determinado um conjunto de números digitais relativos à primeira componente principal. O mesmo se aplica às restantes componentes principais.

Assim, para canais de dados multiespectrais, a primeira componente principal (PC1) inclui a maior percentagem da variância total da cena, dividindo-se a restante de forma estritamente decrescente

pelas componentes que lhe sucedem (PC2, PC3, ..., PCn). Mais, como as sucessivas componentes são ortogonais relativamente a todas as precedentes, a informação que contém não é correlacionada. Ao ser aplicada, por exemplo, às seis bandas TM (excluindo a térmica devido à baixa resolução espacial e à natureza dos dados), esta metodologia vai dar origem a seis componentes principais das quais a primeira contém a informação com um elevado grau de relevância no total das imagens.

Para se fazer uso da análise em componentes principais tendo em vista a fusão de dados com diferentes resoluções espaciais (tome-se uma vez mais como exemplo as bandas Landsat ETM+ multiespectrais e a Landsat ETM+ pancromática) basta, efectuar uma tradicional transformação em componentes principais. Então, a primeira componente principal é substituída pela banda Landsat ETM+ pancromática, não sem que antes, esta sofra uma expansão linear, de modo a adquirir as mesmas média e variância que a primeira componente principal. Por fim, resta apenas derivar a imagem fundida através da transformação inversa. Nestes casos, o processo deixa de ser considerado como análise em componentes principais (PCA) e passa a ser designado como substituição de componentes principais (PCS).

#### **4 – Classificação das imagens e avaliação dos resultados**

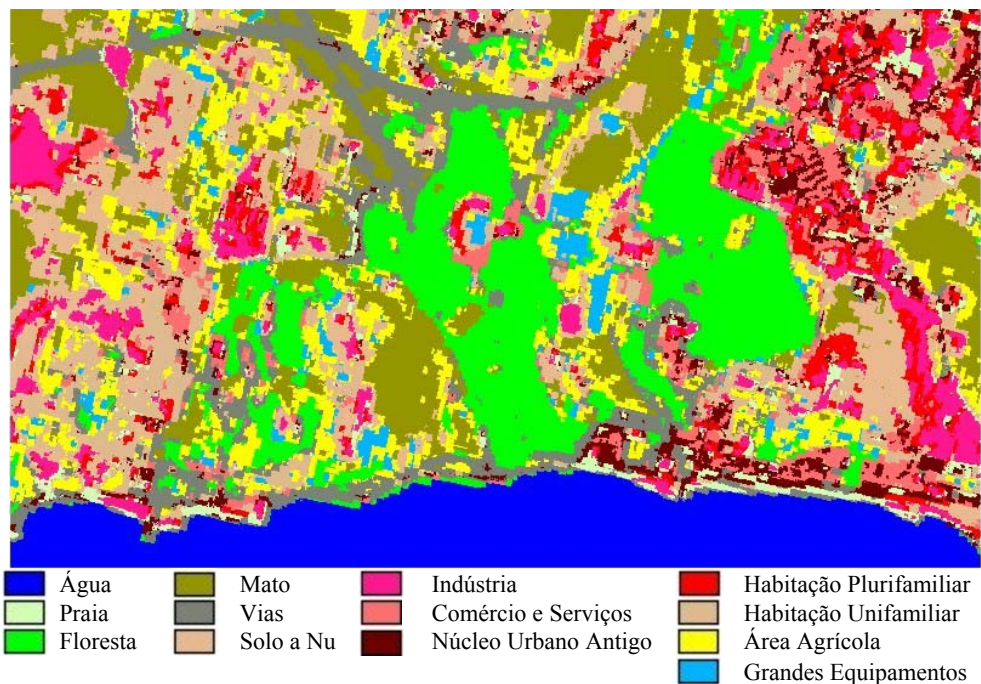
Apesar dos melhoramentos obtidos com a fusão de imagens, o problema da existência de *mixels* não fica automaticamente resolvido. Isto porque, a dimensão óptima do pixel em aplicações periurbanas varia em função da densidade e contraste específicos de cada área, pois estas caracterizam-se por uma diversidade enorme de usos, por vezes coexistentes, e com um elevado grau de detalhe. Para além disso, a densidade de construção varia de acordo com a localização geográfica, ou antes, com o enquadramento cultural da cidade, observando-se, por exemplo, que devido às dimensões mínimas dos elementos urbanos, enquanto para os Estados Unidos um IFOV de 30 metros pode ser suficiente, para o continente Asiático esse valor terá de ser de 5 a 10 metros. No caso específico do Sudão e da China é aconselhável utilizar uma precisão superior a 5 metros.

No caso de Portugal este valor andarà entre os 5 e 10 metros (note-se que a resolução máxima obtida é de 15 m), o que aliado à dificuldade de delinear com precisão as fronteiras entre as diversas classes de uso e ocupação do solo em meio periurbano, obriga a pressupor que o espaço periurbano contém um alto grau de ambiguidade e abstracção, que influencia a sua caracterização espacial. Por isso, a classificação de imagens referentes a áreas periurbanas, requer um método capaz de utilizar conceitos imprecisos, onde uma fronteira precisa entre a probabilidade de pertencer, ou não, a uma classe seja impossível ou impraticável. Nestes casos, pode ser benéfico tratar a variação da probabilidade de pertença a uma determinada classe como gradual e não abrupta.

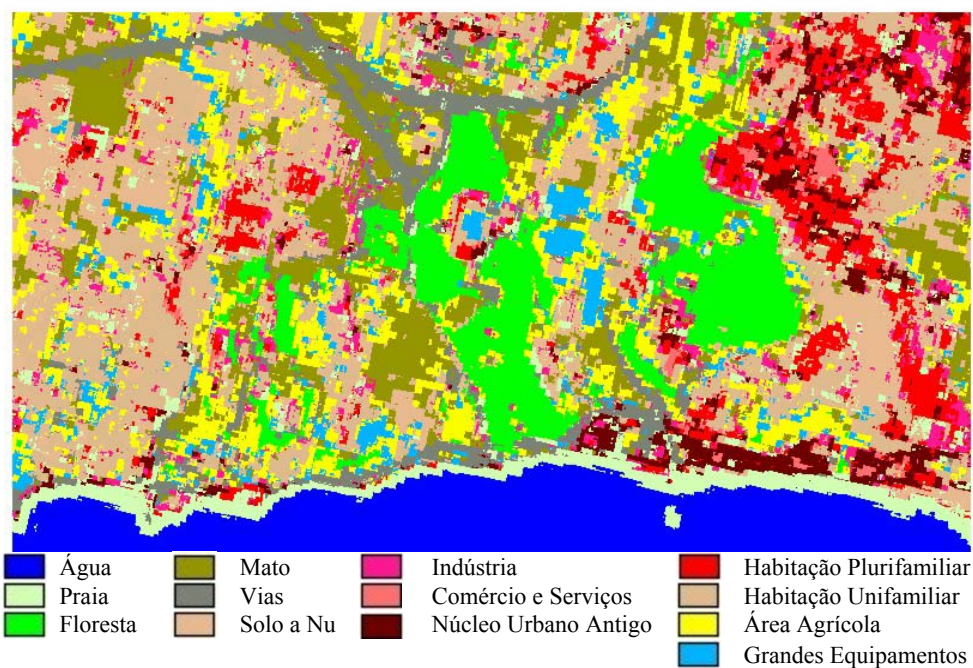
Trabalhos anteriores desenvolvidos por Rocha e Tenedório [4][5][6][7], com o intuito de resolver os problemas de classificação inerentes à classificação de imagens de satélite e particularmente em áreas periurbanas, provaram que as classificações baseadas em fronteiras abruptas e definidas por uma lógica comparativamente simples de dois valores, são insuficientes quando chamadas a relacionar rendilhados de uso e ocupação do solo complexos.

A utilização da teoria dos conjuntos de dados indiferenciados - apresentada pela primeira vez por Zadeh em 1965 [9] - na classificação de imagens permite em primeira instância a obtenção de uma tabela com os parciais de pertença de cada área (ou grupos de) de treino em cada classe. Esta tabela constitui um manancial de informação bastante rico e revela-se essencial para uma correcta medição e monitorização dos usos periurbanos, servindo como informação de entrada para classificadores bastante em voga como os que recorrem à lógica de predicados e às redes neuronais. Contudo, mesmo quando a classificação tem que ser "forçada" (i.e. rígida), atribuindo a cada pixel apenas uma classe (e.g. aquela cuja probabilidade de pertença for maior), este método consegue alcançar resultados ligeiramente melhores que os obtidos pelos métodos tradicionais como o de máxima verosimilhança.

Como prova desse superior desempenho, observe-se a comparação entre a realidade do terreno (imagem anteriormente obtida através de foto-interpretação por Tenedório e Rocha [4][7]) com o resultado obtido pelo método indiferenciado (figura 2) e por um classificador paramétrico tradicional, nomeadamente o de máxima verosimilhança (figura 3), resultado este obtido por Rocha [6] em experimentações prévias.



**Figura 2 - Uso do solo obtido pelo classificador indiferenciado**



**Figura 3 - Uso do solo obtido pelo classificador de máxima verosimilhança**

A tabela 3 apresenta a exactidão global obtida pelos dois métodos, podendo-se observar que o resultado obtido pelos dados indiferenciados é claramente superior ao do classificador de máxima verosimilhança (+ 11,4 %). Os resultados dos dois classificadores (< 50 %) não devem ser considerados preocupantes porque estes são métodos espectrais (e.g. classificam os pixels unicamente com base no seu nível radiométrico) e este tipo de classificadores perde muita da sua eficácia quando se pretende identificar classes de uso do solo em detrimento de classes de ocupação do solo, o que é precisamente o caso.

Classificador	Exactidão Global (%)
Máxima Verosimilhança	36,5
Dados Indiferenciados	47,9

**Tabela 3 - Exactidão Global obtida pelos dois métodos**

## V - CONCLUSÕES

Este estudo explora a aplicabilidade da teoria dos dados indiferenciados à classificação de imagens de satélite, com o intuito de criar um mapa de uso e ocupação do solo, referente a um ambiente periurbano, representando este método um avanço relativamente aos métodos convencionais. Estes últimos conduzem normalmente a análises inexactas e imprecisas, principalmente quando as áreas teledetectadas são de natureza heterogénea.

Muito embora, a análise indiferenciada tenha um interesse limitado em problemas onde a variação do grau de pertença é rígido, ela providencia uma alternativa na tentativa de resolver o problema da pureza interna dos *mixels*; uma fraqueza que à muito que é assumida na formulação das classes de treino. A maior parte dos métodos tradicionais de classificação assume que não existem variações no interior de cada classe, até se chegar à fronteira, quando, na realidade, podem existir variações maiores dentro da classe do que junto à fronteira. Este facto torna-se especialmente verdadeiro em ambientes periurbanos onde uma extensa heterogeneidade de usos se conjuga com uma grande variação na forma, orientação, dimensões dos elementos construídos, bem como a uma enorme diversidade de materiais, fruto de sucessivas vagas de expansão urbana, quase sempre efectuadas de forma desordenada.

Este trabalho realça que a lógica booleana apresenta as categorias de uma forma generalizada e inadequada para aplicações realistas, que incluem informação inexacta como aquela que é encontrada na mistura de classes e condições intermédias. Foi provado que a representação de um ambiente periurbano, visto como um bloco de fronteiras bem definidas, fora do qual não se encontram nenhuma características associadas a este fenómeno é irrealista. A classificação indiferenciada provou que a realidade das zonas periurbanas é de que existe uma variação gradual na ocorrência dos usos.

## VI - REFERÊNCIAS BIBLIOGRÁFICAS

- 1.FISHER, P. F., PATHIRANA, S. (1990) - "The Evaluation of Fuzzy Membership of Land Cover Classes in the Suburban Zone", *Remote Sensing of the Environment*, 34, pp. 121-132.
- 2.PEDCRYZ, W. (1990) - "Fuzzy Sets in Pattern Recognition: Methodology and Methods", *Pattern Recognition*, 23, 1/2, pp. 121-146.
- 3.ROBINSON, V. B., THONGS, D. (1986) - "Fuzzy Set Theory Applied to the Mixed Pixel problem of Multi-spectral Land Cover Databases", *GIS in Government*, 2, Edited by OPITZ, B. K., Washington D. C., A. Deepak Publication.
- 4.ROCHA, J. e TENEDÓRIO, J. A. (2001) - "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).
- 5.ROCHA, J., QUELUZ, M. P. e TENEDÓRIO, J. A. (2001) - "Classificação de Imagens de Satélite com Recurso a Informação Multi-fonte e Multi-resolução.", IV Congresso da Geografia Portuguesa, Lisboa.
- 6.ROCHA, J. (2001) - "Classificação de imagens de satélite com recurso a informação não espectral", *GeolNova*, número 4, DGPR - FCSH - UNL, Lisboa, pp. 159-186.
- 7.ROCHA, J. e TENEDÓRIO, J. A. (2001) - "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, pp. 46-51.
- 8.VAN DER MEER, F. (1997) - "What Does Multisensor Image Fusion Add in Terms of Information Content for Visual Interpretation?", *International Journal of Remote Sensing*, Vol. nº 18, n.2, pp. 445-452.
- 9.ZADEH, L. A. (1965) - " Fuzzy Sets", *Information and Content*, 8, pp. 338-353.

**Centro de Estudos Geográficos**  
**Faculdade de Letras - Universidade de Lisboa**  
Alameda da Universidade  
1600 - 214 LISBOA  
Tel: (+ 351) 21 7940218  
Fax: (+ 351) 21 7938690  
Email: jrocha@mail.doc.fl.ul.pt