

Classificação de imagens AWiFS com uma abordagem combinada *pixel/objecto*

Hugo Costa¹
Mario Caetano^{1,2}

¹Instituto Geográfico Português (IGP), Grupo de Detecção Remota (GDR)
Rua Artilharia Um, 107, 1099 - 052 Lisboa, Portugal
mario.caetano@igeo.pt
hugo.costa@igeo.pt

²CEGI, Instituto Superior de Estatística e Gestão de Informação, ISEGI, Universidade Nova de Lisboa
Campus de Campolide, 1070-312 Lisboa, Portugal

Abstract. This paper shows the work developed with three Advanced Wide Field Sensor (AWiFS) scenes from three intra-annual time periods within a research project of the Remote Sensing Unit (GDR) from the Portuguese Geographic Institute (IGP). The goal was to produce a land cover map using an approach that combines the per-field classification and the object oriented image analysis. First, the AWiFS scenes were segmented to produce objects to be used as classification units. Second, per-pixel classification was performed with decision trees. The training observation collection consisted in a deterministically identification of single pixels spread across the study area concerning a 15-class nomenclature. Third, each object was classified with the modal class provided by the previous per-pixel classification. Four, the combined pixel/object classification was generalized to a minimum mapping unit of 10 ha with an in-house developed software. Finally, the land cover map was evaluated based on a probabilistic accuracy assessment. The methodology was tested on a study area located in Tagus and Sado watersheds. This study area was selected due to its characteristics, such as land cover variety and landscape heterogeneity, that are representative of the Portuguese territory. The land cover map produced with the developed approach has an overall accuracy of 66.9%.

Palavras-chave: Land cover, decision trees, per-field classification, object, AWiFS, ocupação do solo, árvores de decisão, classificação por parcelas, objecto, AWiFS.

1. Introdução

A produção de cartografia de ocupação do solo é essencial para diversas áreas, como o ordenamento do território, monitorização ambiental e outras. Em Portugal existe cartografia de ocupação do solo com especificações diversas. A Carta de Ocupação do Solo de 1990 (COS'90) e CORINE Land Cover 2000 (CLC2000) são as mais conhecidas e continuam ainda a ser usadas como informação temática de referência em inúmeras aplicações, estando em curso a actualização de ambas (Caetano et al, 2008; EEA, 2007). Contudo, estes produtos não são actualizados de forma frequente porque são projectos de escala e nomenclatura detalhadas, realizados por interpretação visual de imagens aéreas e de satélite, respectivamente, o que exige recursos humanos significativos e tempo para a sua realização.

Para fazer face ao problema da actualidade da informação de ocupação do solo, impõe-se pensar em estratégias que complementem a informação oferecida pelos grandes projectos de escala nacional já existentes (COS'90 e CLC2000). Como não é possível a realização de cartografia de ocupação do solo detalhada em menores períodos de tempo, uma solução viável é o desenvolvimento de um novo produto menos detalhado (mais barato e rápido de produzir), realizável regularmente, que ofereça informação actual e seja útil para diversas aplicações. Esta solução está a ser explorada no âmbito do projecto COSMIC da responsabilidade do Grupo de Detecção Remota (GDR) do Instituto Geográfico Português (IGP). O objectivo principal é o desenvolvimento de metodologias automáticas para produção anual de cartografia de ocupação do solo para Portugal Continental com base em dados multitemporais dos sensores MERIS (Carrão et al., 2008a) e AWiFS. Esta iniciativa do IGP para Portugal Continental segue outras iniciativas já implementadas noutros países.

A abordagem ao nível do *pixel* é o método mais convencional e comum na classificação de imagens de satélite para produção de cartografia de ocupação do solo. Nesta abordagem, a cada *pixel* é atribuída uma classe de ocupação do solo com base na informação espectral que incorpora e independentemente da classificação atribuída aos seus vizinhos. Neste âmbito, recentemente têm sido desenvolvidos classificadores de forma a ultrapassar alguns problemas colocados pelas abordagens paramétricas mais tradicionais. Os classificadores não paramétricos não fazem suposições acerca da distribuição dos dados e têm sido descritos como mais exactos (Friedl e Brodley, 1997; Xu et al., 2005; Pal e Mather, 2003; Rogan et al., 2002). As árvores de decisão, já usado em programas operacionais, são um destes classificadores e têm sido descritos como vantajosos devido a várias características, nomeadamente: a estrutura de classificação relativamente simples, explícita e intuitiva (Friedl e Brodley, 1997); a capacidade de lidar com relações não lineares entre os dados de classificação (Friedl e Brodley, 1997; Xu et al., 2005), com dados representados em diferentes escalas de medida (Pal e Mather, 2003) e com dados contínuos e discretos de forma simultânea (Homer et al., 2004); maior rapidez na fase de treino (Gahegan e West 1998 in Pal e Mather, 2003; Homer et al., 2004) e no cálculo computacional (Pal e Mather, 2003; Homer et al., 2004).

A metodologia aplicada em projectos operacionais reflecte a evolução que tem ocorrido na classificação de imagens de satélite por métodos automáticos. O Mapa de ocupação do solo da Grã-Bretanha (Fuller et al., 1994) ou o CORINE Land Cover da Suécia (Hagner e Reese, 2007) são exemplos de abordagens ao nível do *pixel* para a produção de cartografia de ocupação do solo numa base operacional. Em ambos foram usadas imagens Landsat e um classificador paramétrico, o classificador da máxima verosimilhança, mas no caso sueco, com probabilidades a priori. Na Austrália, um programa de cartografia de uso do solo foi desenvolvido com base na modelação probabilística de séries temporais do *Normalized Difference Vegetation Index* (NDVI) de imagens de baixa resolução espacial (BRS, 2006). Classificadores não paramétricos, nomeadamente, árvores de decisão, foram também já aplicados em programas operacionais, apesar do seu uso relativamente mais recente com dados de detecção remota. Por exemplo, no âmbito do programa norte-americano *National Land-Cover Database project* (NLCD 2001), foi derivado um mapa de ocupação do solo com árvores de decisão e imagens Landsat 5/7 (Homer et al., 2004). Na Índia, igualmente com árvores de decisão, estão a ser produzidos anualmente mapas de ocupação do solo com imagens AWiFS do âmbito do programa NR-Census (NRSA, 2005).

Têm sido identificados problemas com as abordagens ao nível do *pixel*, como o resultado ruidoso relacionado com a variedade espacial da paisagem. Esta abordagem ignora o impacto dos *pixels* mistos e é insuficiente para ultrapassar a dificuldade em identificar classes espacialmente heterogéneas resultantes de paisagens heterogéneas. Têm sido propostas alternativas à classificação ao nível do *pixel*, nomeadamente a classificação por parcelas e a análise de imagens orientada por objectos. Conceptualmente estas abordagens são semelhantes, mas diferem na forma como as parcelas/objectos são originados. No primeiro caso, é integrada informação vectorial pré-existente que divide a imagem de satélite em parcelas que são usadas como unidade de classificação. No segundo caso, a informação vectorial é substituída por objectos criados a partir da segmentação das próprias imagens (Lu e Weng, 2007). A vantagem destas abordagens, principalmente a da análise orientada por objectos, é que se pode tirar partido da informação semântica importante e necessária para interpretar uma imagem em objectos significativos e nas suas relações mútuas (Gamanya et al., 2007).

Este artigo descreve o trabalho desenvolvido com imagens AWiFS no seguimento dos estudos desenvolvidos no âmbito do projecto COSMIC (Costa et al., 2008a; Costa et al., 2008b) para o desenvolvimento de métodos automáticos de produção de cartografia de ocupação do solo. Neste artigo explora-se uma abordagem combinada *pixel/objecto* que é

também uma combinação da classificação por parcelas e da análise orientada por objectos na medida em que a unidade de classificação consistiu em objectos derivados da segmentação das imagens AWiFS e a sua classificação baseou-se na classificação ao nível do *pixel*.

2. Metodologia

A metodologia consistiu numa abordagem combinada *pixel/objecto* para classificar três imagens AWiFS relativas a três épocas do ano (Abril, Julho e Outubro de 2006). As imagens AWiFS caracterizam-se por uma resolução espacial de 60 m e quatro bandas, nas regiões do verde, vermelho, infra-vermelho próximo e infra-vermelho médio.

A metodologia integrou as seguintes fases: i) definição da área de estudo; ii) definição da nomenclatura de ocupação do solo; iii) segmentação das imagens; iv) classificação ao nível do *pixel*; v) classificação dos objectos; vi) generalização; e vii) avaliação da exactidão dos mapas. Cada uma das fases da metodologia é desenvolvida nas próximas subsecções.

2.1 Área de estudo

A metodologia foi testada numa área de estudo que consiste num dos 13 estratos definidos para Portugal Continental (Costa et al. 2008a). A sua selecção deveu-se às suas características, como a variedade de tipos de ocupação do solo e a heterogeneidade da paisagem. A extensão da área de estudo é cerca de 1 223 890 ha e cobre grande parte dos vales dos rios Tejo e Sado. A intenção desta escolha foi garantir que os problemas que surgissem na classificação da área de estudo fossem demonstrativos do restante território. Posteriormente, a metodologia desenvolvida será aplicada e ajustada em cada um dos estratos.

2.2 Nomenclatura de ocupação do solo

A nomenclatura de ocupação do solo foi definida através da adopção de uma versão adaptada da nomenclatura LANDEO. Esta é uma nomenclatura hierárquica, detalhada e multiescala, desenvolvida pelo GDR do IGP com o propósito de ser usada em mapas de ocupação do solo derivados de métodos automáticos (Araújo e Caetano, 2006). A nomenclatura original foi adaptada ao longo do desenvolvimento do trabalho com base na capacidade das imagens em identificar cada classe de ocupação do solo. Como resultado deste processo foi definida uma nomenclatura de 15 classes (Tabela 1).

Tabela 1. Nomenclatura de ocupação do solo

Código	Classe	Código	Classe
1	Áreas artificiais contínuas	9	Áreas agro-florestais
2	Áreas artificiais descontínuas	10	Matos
3	Culturas de sequeiro	11	Vegetação herbácea natural
4	Culturas de regadio	12	Cortes florestais
5	Arrozais	13	Zonas húmidas
6	Vinhas	14	Solo nu
7	Floresta de folhosas	15	Água
8	Floresta de resinosas		

2.3 Segmentação das imagens AWiFS

A segmentação das imagens AWiFS teve como objectivo a delimitação de unidades de paisagem em que a ocupação do solo é tendencialmente homogénea. A segmentação das imagens produziu objectos, que posteriormente foram usados como unidade de classificação. Os objectos foram delimitados com recurso à aplicação comercial eCognition© através da segmentação das imagens de Abril, Julho e Outubro. Foram realizadas várias experiências de onde se chegou à conclusão que eram adequados os seguintes parâmetros de segmentação: *color*, 0.8, *shape*, 0.5, *smoothness*, 0.5 e *compactness*, 0.5. Com estes parâmetros, a

segmentação das imagens deram origem a 88356 objectos na área de estudo, em média com 14.51 ha e desvio padrão de 18.18 ha.

2.4 Classificação ao nível do *pixel*

As imagens AWiFS foram sujeitas a uma classificação ao nível do *pixel* com árvores de decisão para criar a base de informação que posteriormente serviu para se classificar os objectos resultantes da segmentação.

A construção da amostra de treino consistiu na identificação determinística de *pixels* isolados e distribuídos ao longo da área de estudo para evitar efeitos de autocorrelação espacial (Campbell, 1981; Labovitz, 1986). Foi seguido um protocolo de amostragem convencional mediante a recolha de observações puras de cada classe de ocupação do solo. Como informação auxiliar foram usadas ortoimagens de muito grande resolução espacial (50 cm) obtidas entre 2004 e 2006 e ainda um mosaico de imagens LISS e SPOT de 2006. No total, foram recolhidas 1405 observações.

Com base na amostra de treino, as árvores de decisão foram construídas com recurso à aplicação comercial See5© e classificadas as imagens AWiFS. Foram realizados vários testes com diferentes abordagens de classificação e características da amostra de treino. Chegou-se à conclusão que o desempenho das árvores de decisão não é afectado por alterações na fase de treino, o que permite abreviar o processo de classificação (Costa et al., 2008a). Daqui resultou um mapa de ocupação do solo ao nível do *pixel*, ou seja, com uma unidade mínima cartográfica de 0.36 ha.

2.5 Classificação dos objectos

Nesta fase operou-se a combinação da classificação ao nível do *pixel* com os objectos. Tendo em conta que a segmentação das imagens identifica as unidades de paisagem de interesse, os objectos foram usados como unidades de classificação. Isto é, cada objecto foi usado na delimitação das classes de ocupação do solo. A identificação das classes foi realizada com o resultado produzido pela classificação das imagens com árvores de decisão ao nível do *pixel*. Assim, a cada objecto foi atribuída a classe de ocupação do solo que ocupava maior percentagem de área no seu interior ao nível do *pixel*.

2.6 Generalização da classificação dos objectos

Devido à segmentação das imagens AWiFS, o mapa que resulta da classificação híbrida *pixel/objecto* tem uma apresentação mais próxima da preferência da maioria dos utilizadores, em formato vectorial e sem o efeito *salt and pepper*, característico dos mapas em formato *raster* derivados de classificação ao nível do *pixel*. No entanto, a segmentação, em certas áreas de paisagem mais fragmentada, continua a produzir objectos de tamanho muito reduzido e sem uma unidade mínima cartográfica definida (ao contrário dos mapas em formato *raster*, que corresponde à área do *pixel*). Este facto levou à necessidade de submeter o mapa a uma generalização. Esta operação foi realizada com a aplicação MapGen (Carrão et al., 2001). Esta aplicação, desenvolvida no GDR do IGP, executa a eliminação de unidades de ocupação do solo inferiores à unidade mínima cartográfica definida através de dois processos: i) exagero, quando a superfície da pequena unidade é artificialmente aumentada para criar uma nova unidade preservada no mapa final; ii) agregação, quando a pequena unidade é unida a, ou dividida por, unidades vizinhas até a unidade resultante ter uma área igual ou superior à unidade mínima cartográfica (Carrão et al., 2001). Neste caso, foi definida uma unidade mínima cartográfica de 10 ha.

2.7 Avaliação da exactidão dos mapas

Construiu-se uma amostra de validação através de uma amostragem aleatória estratificada com base em testes preliminares, com 30 observações por classe (565 observações no total) e o objecto como unidade de amostragem. Como informação de referência usaram-se ortoimagens de muito grande resolução espacial (50 cm) adquiridas entre 2004 e 2006 e um mosaico de imagens LISS e SPOT de 2006. A informação de referência foi interpretada visualmente e a cada observação foi atribuído um código principal de ocupação do solo da nomenclatura e ainda um código alternativo, quando necessário. Foi construída a matriz de confusão em que cada observação da amostra de validação foi considerada bem classificada se um dos dois códigos (principal ou alternativo) correspondia com a classe do mapa. Foram depois calculados os índices de exactidão global (EG), do utilizador (EU) e do produtor (EP) e avaliada a exactidão temática do mapa produzido.

3. Resultados e discussão

O mapa produzido através da classificação combinada *pixel/objecto* (Figura 1) tem uma exactidão global de 66.9% (Tabela 1).

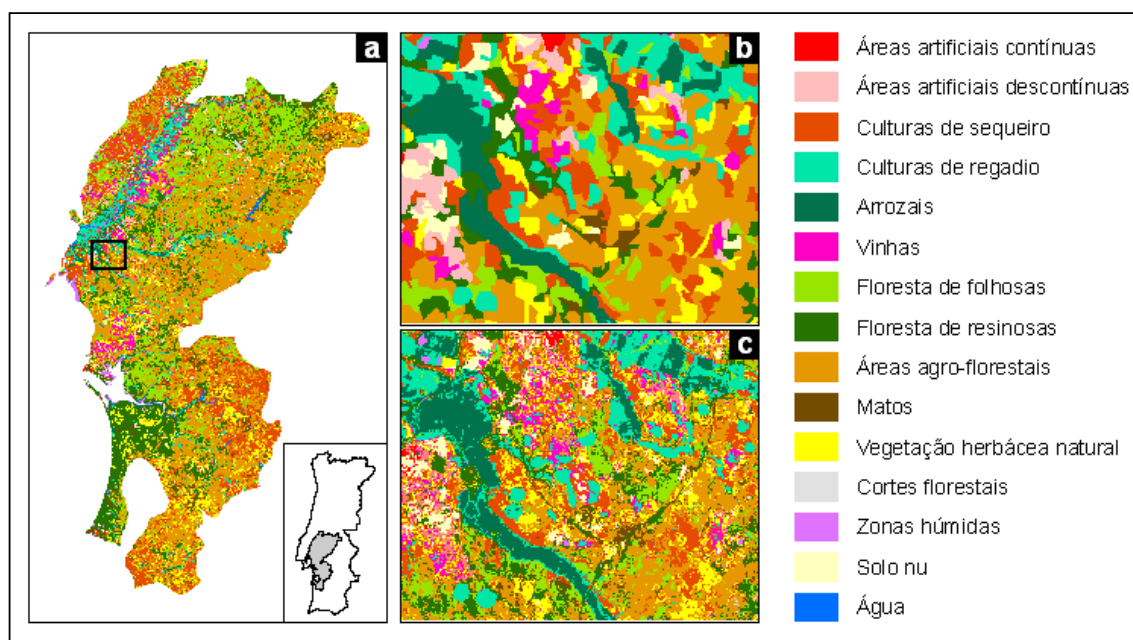


Figura 1. Mapa de ocupação do solo produzido para a área de estudo (a) e pormenor comparativo entre as classificações combinada *pixel/objecto* (b) e ao nível do *pixel* (c).

A matriz de confusão revela comportamentos distintos das classes de ocupação do solo. Como se pode ver nos valores de exactidão do utilizador, as classes 8 e 10 apresentam elevados erros de comissão (EU<50%) enquanto as classes 1, 2, 4, 5, 7, 12 e 15 apresentam baixos erros de comissão (EU>75%). Relativamente aos erros de omissão, os valores de exactidão do produtor demonstram que as classes 2, 11 e 12 foram as classes classificadas com maior erro (EP<50%) e as classes 5, 9, 13 e 14 as classes classificadas com menor erro (EP>75%). De uma forma geral, a classe 10 (Matos) foi a classe pior classificada e a classe 5 (Arrozais), a melhor.

Tabela 1. Matriz de confusão do mapa de ocupação do solo

		Informação de referência														Total	EU(%)	
		1	2	3	4	5	6	7	8	9	10	11	12	13	14			15
Classes de ocupação do solo do mapa	1	7	1														8	88
	2	1	12							1							14	86
	3			32	1			1		2	2	6	2				46	70
	4			1	21	4		1	1								28	75
	5				6	18											24	75
	6		3	1	2		10			1							17	59
	7			2		1		72	9	2	1	1					88	82
	8	2	4		1			10	42	4	4	11	3		1	3	85	49
	9		3	4			2	15	2	69		18	2		1		116	59
	10							2	1	3	2	2					10	20
	11		4	3	1		1		2	2		32			1	1	47	68
	12							1					12				13	92
	13					1								14		11	26	54
	14	3	1	1			1					1			9		16	56
	15													1		26	27	96
Total	13	28	44	32	24	14	102	57	84	9	71	19	15	12	41	565		
EP(%)	54	43	73	66	75	71	71	74	82	22	45	63	93	75	63		66.9%	

A matriz revela confusão entre classes espectralmente próximas, por exemplo, entre as classes Floresta de folhosas e Floresta de resinosas, e as classes Culturas de sequeiro e Vegetação herbácea natural ou Áreas agro-florestais. A confusão entre as classes Floresta de folhosas e Floresta de resinosas é expectável porque são ambas classes de floresta. A confusão entre a classe Culturas de sequeiro e Vegetação herbácea natural pode ser explicada pelo tipo de vegetação ser muito semelhante e pela dependência directa que esta tem da precipitação, em ambas as classes. Por sua vez, a confusão destas com a classe Áreas agro-florestais pode ser explicada pelo seu subcoberto (com presença de herbáceas ou culturas de sequeiro), o que acaba por confundir classes claramente diferentes no ponto de vista paisagístico (devido à presença e ausência de vegetação arbórea).

A questão da influência do sobcoberto das classes com vegetação arbórea parece ser também a causa da exactidão do produtor da classe Floresta de resinosas. Esta classe existe sob a forma de povoamento bastante homogéneos e densos, até povoamentos mais abertos com matos ou sem matos. A grande variabilidade intra-classe torna mais difícil a sua amostragem e a consequente classificação. O mesmo se poderá afirmar acerca da classe Matos, o que acabou por originar o seu mau comportamento.

Também se observa dificuldades na classificação da classe Áreas artificiais descontínuas. Esta dificuldade está relacionada com a heterogeneidade conceptual da classe que engloba construção dispersa com áreas naturais ou agrícolas. Isto dificulta a sua identificação ao nível do *pixel*, o que tem repercussões na classificação dos objectos.

Apesar das confusões referidas, a metodologia permitiu produzir um mapa com uma exactidão global dentro dos valores correntemente alcançados em projectos similares, entre 50 a 70% (Laba et al., 2002). A metodologia permitiu ainda obter um resultado superior em cerca de 5% relativamente à classificação ao nível do *pixel*, o que está relacionado com a delimitação dos objectos e demonstra que a classificação ganha ao ter em conta uma análise de contexto. Isto quer dizer que existem relações entre *pixels* e padrões paisagísticos passíveis de serem interpretados nas imagens AWiFS que são impossíveis de explorar com uma abordagem ao nível do *pixel*. Mais ainda, o uso de objectos na classificação híbrida permitiu eliminar à partida o efeito de *salt and pepper*, isto é, o aspecto salpicado dos mapas derivados por classificação ao nível do *pixel*. Este aspecto deve-se à classificação de alguns *pixels* isolados em uma classe diferente da mancha onde os mesmos se inserem. Assim, este resultado demonstra que esta abordagem de classificação tem potencialidade para produzir cartografia mais exacta e deverá ser mais desenvolvida.

Verificou-se que a exactidão do mapa final está à partida limitada pelo resultado da classificação ao nível do *pixel*. Por outro lado, o trabalho desenvolvido no âmbito do projecto

COSMIC com imagens MERIS demonstrou ser possível obter valores de exactidão mais elevados (Carrão et al., no 2008a). Neste sentido, Costa et al. (2008b) compararam as imagens MERIS com as imagens AWiFS e os resultados demonstram que os menores valores de exactidão obtidos na classificação de imagens AWiFS podem ser explicados, principalmente, pela sua menor resolução espectral. Este resultado corrobora o estudo de Carrão et al. (2008b) em que se conclui que a resolução espectral é a característica técnica das imagens de satélite mais influente na classificação automática da paisagem portuguesa.

4. Conclusões

A classificação automática ao nível do *pixel*, mesmo aplicada com classificadores recentes que permitem ultrapassar algumas limitações dos classificadores paramétricos, pode não ser suficiente para extrair toda a informação registada em imagens de satélite. Para além da informação espectral ao nível do *pixel* fornecida pelas imagens AWiFS, a sua segmentação e a integração de objectos na classificação permitiu acrescentar relações espaciais ao nível da paisagem e aumentar a exactidão temática da cartografia. Os resultados obtidos neste trabalho impõem o desenvolvimento futuro da metodologia para se aprofundar a extracção de informação ao nível da paisagem. A exactidão temática da cartografia poderá ser ainda melhorada através da integração de regras na classificação dos objectos. Como realizado com sucesso em trabalho similares (e.g. Gonçalves et al., 2008; Plantier e Caetano, 2007), a introdução de regras permite classificar classes de ocupação do solo impossíveis de distinguir ao nível do *pixel* (e.g. mosaicos) e ajustar melhor a definição da nomenclatura de ocupação do solo à paisagem portuguesa, caracterizada em certas áreas pela fragmentação da ocupação do solo e pela pequena propriedade.

Referências bibliográficas

Araújo A.; Caetano, M. **Nomenclatura de ocupação do solo LANDEO**. Lisboa: Instituto Geográfico Português, 2006. 33p.

BSR. **Guidelines for land use mapping in Australia: principles, procedures and definitions**, 3rd edition, Canberra: Australian Government, Bureau of Rural Sciences, 2006, 83 p.

Caetano, M.; Nunes, V.; Araújo, A. Concepção e desenvolvimento das especificações técnicas da nova Carta de Ocupação do Solo de Portugal Continental. In: Encontro de Utilizadores de Informação Geográfica (eSIG'08), 10, 2008, Oeiras, Portugal. **Actas do X Encontro de Utilizadores de Informação Geográfica (eSIG'08)**, CD-ROM não paginado.

Campbell, J. Spatial correlation effects upon accuracy of supervised classification of land cover. **Photogrammetric Engineering & Remote Sensing**, v. 47, n.3, p. 355-363, 1981.

Carrão, H.; Henriques, R.; Nery, F.; Caetano, M. MapGen – Automated Generalisation for Thematic Cartography. In: ESRI EMEA User Conference, 16, Lisbon, Portugal, 2001. **Proceedings of 16th ESRI EMEA User Conference**, CD-ROM não paginado.

Carrão, H.; Gonçalves, P.; Caetano, M. Multitemporal MERIS images for land cover mapping at national scale: the case study of Portugal. **International Journal of Remote Sensing**, in press, 2008a.

Carrão, H.; Gonçalves, P.; Caetano, M. Contribution of multispectral and multitemporal information from MODIS images to land cover classification. **Remote Sensing of Environment**, v. 112, n.3, p. 986-997, 2008b.

Costa, H.; Carrão, H.; Bação, F.; Caetano, M. Land cover classification in Portugal with multitemporal AWiFS images: a comparative study. In: EARSeL Symposium "Remote Sensing for a Changing Europe", 28, 2008, Istanbul, Turquia. **Proceedings of the 28th EARSeL Symposium "Remote Sensing for a Changing Europe"**, in press.

Costa, H.; Araújo, A.; Carrão, H.; Caetano, M. Influência das características técnicas das imagens de satélite na produção de cartografia de ocupação do solo: estudo baseado em imagens MERIS e AWiFS. In: Encontro de Utilizadores de Informação Geográfica (eSIG'08), 10, 2008, Oeiras, Portugal. **Actas do X Encontro de Utilizadores de Informação Geográfica (eSIG'08)**, CD-ROM não paginado.

EEA. **CLC2006 technical guidelines, Technical report 17/2007**. Luxemburgo: Office for Official Publications of the European Communities, 2007. 66 p.

Friedl, M.; Brodley, C. Decision tree classification of land Cover from remotely sensed data. **Remote Sensing of Environment**, v.61, n. 3, p. 399-409, 1997.

Fuller, R.; Groom, G.; Jones, A. The Land Cover Map of Great Britain: An automated Classification of Landsat Thematic Mapper Data. **Photogrammetric engineering & Remote Sensing**, vol. 60, n.5, p.553-562, 1994.

Gamanya, R.; De Maeyer, P.; De Dapper, M. An automated satellite image classification design using object-oriented segmentation algorithms: A move towards standardization. **Expert Systems with Applications**, v. 32, n.2, p. 616-624, 2007.

Gonçalves, L.; Fonte, C.; Júlio, E.; Caetano, M. A method to incorporate uncertainty in the classification of remote sensing images. In: Li, D.; Ge, Y.; Foody, G. (Org.). **Accuracy in Geomatics**. Liverpool: World Academic Union, 2008, p. 179-185.

Hagner, O.; Reese, H. A method for calibrated maximum likelihood classification of forest types. **Remote Sensing of Environment**, v. 110, n. 4, p. 438-444, 2007.

Homer, C.; Huang, C.; Yang, L.; Wylie, B.; Coan, M. Development of a 2001 National Land-Cover Database for the United States. **Photogrammetric engineering & Remote Sensing**, vol. 70, n. 7, p. 829-840, 2004.

Laba M.; Gregory, S.; Braden, J.; Ogurcak, D.; Hill, E.; Fegraus, E.; Fiore, F.; DeGloria S. Conventional and fuzzy accuracy assessment of the New York Gap Analysis Project land cover map. **Remote Sensing of Environment**, v. 81, n.1, p. 443-455, 2002.

Labovitz, M. Issues arising from sampling designs and band selection in discriminating ground reference attributes using remotely sensed data. **Photogrammetric Engineering & Remote Sensing**, vol. 52, n. 2, p. 201-211, 1986.

Lu, D.; Weng, Q. A survey of image classification methods and techniques for improving classification performance. **International Journal of Remote Sensing**, vol. 28, n. 5, p. 823-870, 2007.

NRSA. **National land use and land cover mapping using Multitemporal AWiFS data (LULC-AWiFS): project manual**. National Remote Sensing Agency, Department of Space, Government of India, 2005. 110 p. Disponível em: <http://218.248.0.130:15001/images/lulc_manual.pdf>. Acesso em: 25 out. 2008.

Pal, M.; Mather, P. An assessment of the effectiveness of decision tree methods for land cover classification. **Remote Sensing of Environment**, v. 86, n. 4, p. 554-565, 2003.

Plantier, T.; Caetano, M. Mapas do coberto florestal: abordagem combinada pixel/objecto. In: Casaca, J; Matos, J. (Org.). **Cartografia e Geodesia 2007**. Lisboa: LIDEL, 2007, p. 157-166.

Rogan, J.; Franklin, J.; Roberts, A. A comparison of methods for monitoring multitemporal vegetation change using Thematic Mapper imagery. **Remote Sensing of Environment**, v. 80, n. 1, 143-156, 2002.

Xu, M.; Watanachaturaporn, P.; Varchney, P.; Arora, M. Decision tree regression for soft classification of remote sensing data. **Remote Sensing of Environment**, v. 97, n. 3, p. 322-336, 2002.