

Avaliação do desempenho de sete algoritmos na
classificação da ocupação do solo a distintas resoluções
espaciais

Actions 3.3 & 3.4 - Task 3

Relatório de execução do Projecto LANDAU
- Metodologia geoestatística para a caracterização da incerteza espacial e
actualização de cartas de ocupação do solo -

Joel Dinis, Rita Nicolau

Março 2013

ÍNDICE

1	Introdução.....	5
2	Métodos.....	5
2.1	Dados e área de aplicação.....	5
2.2	Nomenclatura.....	7
2.3	Algoritmos de classificação ensaiados.....	7
2.4	Amostragem de treino e de validação.....	8
2.5	Avaliação do desempenho na classificação do uso do solo.....	9
3	Resultados.....	10
3.1	Desempenho global dos algoritmos de classificação a diferentes escalas de análise.....	14
3.2	Desempenho dos algoritmos na identificação de classes da nomenclatura LANDAU a diferentes escalas de análise.....	17
3.2.1	Desempenho do algoritmo ML.....	24
4	Conclusões.....	25
5	Referências Bibliográficas.....	28

1 Introdução

O presente relatório dá continuidade à descrição das actividades desenvolvidas no âmbito das *Actions 3.3 & 3.4* - Task 3 do projecto LANDAU.

Com recurso a sete algoritmos de classificação e dados de satélite de três resoluções espaciais distintas (imagens MERIS, LANDSAT e QUICKBIRD), procedeu-se anteriormente à classificação automática da ocupação do solo de Portugal Continental de acordo com a nomenclatura LANDAU (Dinis *et al*, 2012a; 2012b; 2012c; 2012d).

Os mapas de ocupação do solo desenvolvidos a partir de dados MERIS cobrem a totalidade do território continental, mas para as escalas de maior detalhe (LANDSAT e QUICKBIRD) a classificação da ocupação do solo circunscreveu-se a três áreas de estudo (E, J e A) previamente seleccionadas (Nicolau *et al*, 2011), com base em critérios que asseguram a representatividade dos diferentes padrões de ocupação/uso do solo e da variabilidade da paisagem do Continente.

Face ao exposto, obtiveram-se múltiplas classificações da ocupação do solo que dependem do algoritmo de classificação utilizado e da escala de análise.

O principal objectivo do actual estudo é a comparação do desempenho das sete metodologias de classificação automática ensaiadas na produção de mapas de ocupação de solo a três escalas de análise distintas.

2 Métodos

No presente ponto descrevem-se os dados, a área de aplicação, a nomenclatura e as metodologias empregues na classificação automática da ocupação do solo a partir de dados de satélite.

2.1 Dados e área de aplicação

A classificação automática da ocupação do solo foi independentemente desenvolvida a partir de dados de satélite de distintas resoluções espaciais: uma resolução espacial média (pixeis de 300 metros) proporcionada por dados do sensor MERIS relativos ao ano de 2005, uma resolução espacial intermédia (pixeis de 30 metros) facultada por imagens LANDSAT relativas ao ano de 2007, e uma resolução espacial muito elevada (pixeis de 2.4 metros), disponibilizada por imagens QUICKBIRD relativas ao período 2004-2005.

O facto do presente estudo ter sido desenvolvido por recurso exclusivo a imagens de satélite gratuitas e/ou disponíveis no IGP, inviabilizou a adopção de uma referência

temporal comum às três escalas de análise empregues. Devido a esta situação, os autores optaram por desenvolver um teste comparativo das classes de espaço atribuídas à mesma amostra de validação (559 pontos/ observações) com base numa imagem Quickbird (2005) e com base numa imagem LANDSAT (2007). Os resultados deste teste indicaram que:

- 75.8% dos pontos amostrados não evidenciaram uma alteração da classe de espaço entre 2005 e 2007;
- Nos pontos/ observações remanescentes (24.2%) a discordância na classificação das classes de espaço entre 2005 e 2007, deveu-se a transformações que foram atribuídas a modificações na estrutura da paisagem (15.9%) ou à alteração da escala da imagem (8.2%).

Na adopção da escala de menor detalhe (MERIS) procedeu-se à classificação da ocupação do solo da totalidade do território Continental, mas na adopção das escalas mais detalhadas (LANDSAT e QUICKBIRD) a classificação da ocupação do solo circunscreveu-se a três áreas de estudo, E, J e A (vide Figura 1), consideradas representativas da diversidade paisagística do Continente (Nicolau *et al.*, 2011).



Figura 1 - Áreas de estudo LANDAU: E, J e A

A decisão de alargar o estudo ao território Continental na classificação da ocupação do solo a partir de dados MERIS, fundamentou-se na convicção de que a aplicação da escala de análise associada a estes dados às três áreas representadas na Figura 1 inviabilizaria o reconhecimento e classificação de todas as classes de espaço de interesse para o projecto.

2.2 Nomenclatura

A nomenclatura de ocupação do solo adoptada foi anteriormente proposta no contexto do projecto (Dinis *et al.*, 2012a), sendo por isso designada de LANDAU. A sua proposta emergiu da necessidade de obtenção de uma nomenclatura compatibilizada com o sistema de classificação Land Cover Classification System (LCCS) que fosse funcional às três escalas de análise utilizadas no projecto. Trata-se de uma nomenclatura hierárquica que na sua versão mais desagregada inclui 15 classes de ocupação/uso do solo (vide Quadro 1).

Quadro 1 – Nomenclatura LANDAU

LANDAU – Nível 1	LANDAU – Nível 2
1 Artificial Areas (Territórios Artificializados)	1.1 Continuous Artificial Areas (Áreas Artificiais Contínuas)
	1.2 Discontinuous Artificial Areas (Áreas Artificiais Descontínuas)
2 Croplands (Áreas Agrícolas)	2.1 Irrigated Agriculture (Agricultura de Regadio)
	2.2 Non-irrigated Agriculture (Agricultura de Sequeiro)
	2.3 Rice Crops (Arrozais)
3 Natural and Semi-natural Vegetated Areas (Florestas e Meios Naturais e Semi-naturais)	3.1 Broadleaved Forest (Floresta de Folhosas)
	3.2 Coniferous Forest (Floresta de Resinosas)
	3.3 Mixed Forest (Floresta Mista)
	3.4 Grassland (Vegetação Herbácea)
	3.5 Shrubland (Matos)
	3.6 Baren to Sparsely Vegetated Areas (Vegetação Esparsa)
4 Bare Land (Solo Nu)	4 Bare Land (Solo Nu)
5 Burnt Areas (Áreas Ardidas)	5 Burnt Areas (Áreas Ardidas)
6 Wetlands (Zonas Húmidas)	6 Wetlands (Zonas Húmidas)
7 Water bodies (Corpos de Água)	7 Water bodies (Corpos de Água)

2.3 Algoritmos de classificação ensaiados

Os algoritmos ensaiados na classificação da ocupação do solo foram os seguintes: Maximum Likelihood (ML), Linear Discriminant Classifier (LDC), Diagonal Quadratic Discriminant Classifier (DQDC), K-Nearest Neighbours (KNN), Parzen Classifier (PARZEN), Classification and Regression Tree (CART) e Backpropagation Multilayer Perceptron (BMP).

O procedimento de classificação associado a cada algoritmo foi detalhado num

trabalho antecedente (Dinis *et al.*, 2012b).

2.4 Amostragem de treino e de validação

A recolha de amostras destinadas ao treino dos algoritmos testados foi desenvolvida independentemente para cada escala e área de estudo. As amostras de treino foram deterministicamente recolhidas sobre a Cartografia CORINE Land Cover (2006), na sequência da sua reclassificação em classes de nível 2 da nomenclatura LANDAU.

O Quadro 2 disponibiliza informação sobre o número de pontos de treino amostrados por escala de análise, segundo classes de nível 2 da nomenclatura LANDAU. Adicionalmente disponibiliza-se informação sobre a área do território que foi objecto de classificação a cada escala.

Quadro 2 – Número de pontos de treino amostrados por escala de análise, segundo classes da nomenclatura LANDAU

Nomenclatura LANDAU nível 2	Escala de análise:		
	MERIS	LANDSAT	QUICKBIRD
1.1 Áreas Artificiais Contínuas	472	-	-
1.2 Áreas Artificiais Descontínuas	472	993	2394
2.1 Agricultura de Regadio	684	1181	2029
2.2 Agricultura de Sequeiro	2304	1611	9813
2.3 Arrozaís	450	474	750
3.1 Floresta de Folhosas	1060	1204	2151
3.2 Floresta de Resinosas	851	891	2466
3.3 Floresta Mista	839	291	-
3.4 Vegetação Herbácea	979	965	2707
3.5 Matos	2065	1110	2422
3.6 Vegetação Esparsa	574	454	542
4 Solo Nu	118	675	870
5 Áreas Áridas	459	278	295
6 Zonas Húmidas	450	105	190
7 Corpos de Água	180	650	1711
Dimensão da amostra de treino (nº pontos)	11957	10882	28340
Superfície total classificada (Ha)	8 400 861.0	30 271.7	30 265.9

- classe de espaço não representada na área de estudo, à escala de análise indicada

A recolha de amostras destinadas à validação da classificação ocupação do solo produzida por cada algoritmo, também foi realizada independentemente para cada área de estudo e escala de análise. Tratou-se de uma amostragem aleatória, estratificada pelas classes de nível 2 da nomenclatura LANDAU que à escala de análise adoptada

tinham representação em cada área de estudo. A dimensão da amostra foi determinada considerando a significância estatística e o esforço operacional necessário para a sua construção.

O Quadro 3 disponibiliza informação sobre o número de pontos de validação amostrados por escala de análise, segundo classes de nível 2 da nomenclatura LANDAU.

Quadro 3 – Número de pontos de validação amostrados por escala de análise, segundo classes da nomenclatura LANDAU

Nomenclatura LANDAU nível 2	Escala de análise:		
	MERIS	LANDSAT	QUICKBIRD
1.1 Áreas Artificiais Contínuas	50	77	-
1.2 Áreas Artificiais Descontínuas	50	96	150
2.1 Agricultura de Regadio	50	230	150
2.2 Agricultura de Sequeiro	50	184	150
2.3 Arrozais	50	48	50
3.1 Floresta de Folhosas	50	150	150
3.2 Floresta de Resinosas	50	147	150
3.3 Floresta Mista	50	95	-
3.4 Vegetação Herbácea	50	155	150
3.5 Matos	50	209	150
3.6 Vegetação Esparsa	50	93	100
4 Solo Nu	50	95	150
5 Áreas Ardidadas	50	27	50
6 Zonas Húmidas	50	38	50
7 Corpos de Água	50	136	121
Dimensão da amostra de validação (Nº pontos)	750	1780	1571

- classe de espaço não representada na área de estudo, à escala de análise indicada

2.5 Avaliação do desempenho na classificação do uso do solo

As medidas adoptadas para avaliação do desempenho dos algoritmos testados na classificação do uso do solo são a exactidão global (\hat{P}), a exactidão do produtor (\hat{P}_p) e a exactidão do utilizador (\hat{P}_u). A exactidão global (\hat{P}) avalia a proporção de observações (pontos) correctamente classificadas na amostra de validação. Segundo Jensen (2005) a exactidão global constitui uma medida do erro de omissão. A exactidão do produtor (\hat{P}_p) exprime a proporção entre o número de observações (pontos) correctamente classificados numa classe e o número total de observações da

amostra de validação que efectivamente pertencem a essa classe. Consequentemente constitui uma medida do erro de comissão. A exactidão do utilizador (\hat{P}_u) exprime a proporção de observações da amostra de validação que efectivamente pertence à classe a que foi atribuída e representa a confiança que o utilizador pode ter nos resultados da classificação.

Dado que a classificação do uso do solo por recurso a dados LANDSAT e QUICKBIRD foi aplicada a três áreas de estudo, nos trabalhos precedentes (Dinis *et al*, 2012c; 2013) apresentaram-se três matrizes de erro/confusão para cada algoritmo de classificação, de forma a viabilizar a avaliação do desempenho de cada algoritmo por área estudada. No presente estudo, para cada algoritmo testado produziu-se uma única matriz de erro/confusão por totalização dos valores de células correlativas das matrizes de confusão associadas a cada área de estudo. Consequentemente, as medidas de avaliação do desempenho dos algoritmos testados (\hat{P} , \hat{P}_p e \hat{P}_u) a partir de dados LANDSAT e QUICKBIRD, foram estimadas com base numa amostra que resultou da fusão de três amostras de validação parcelares.

Considerou-se que exactidão global (\hat{P}) seria a medida mais ajustada à comparação do desempenho dos classificadores a cada escala de análise e entre escalas de análise. Deste modo, na avaliação da significância estatística das diferenças entre as exactidões globais obtidas por diferentes algoritmos à mesma escala de análise, utilizou-se o teste McNemar com correcção de continuidade (Foody, 2004 - expressão (8)) tendo em conta a dependência das amostras empregues. Na avaliação da significância estatística das diferenças entre as exactidões globais obtidas pelos algoritmos a diferentes escalas de análise, utilizou-se o teste para diferenças entre duas proporções resultantes de amostras independentes (Foody, 2004 - expressão (4)). No desenvolvimento dos testes de hipóteses referidos adoptou-se um nível de significância de 0.05.

3 Resultados

No presente capítulo descrevem-se os principais resultados da classificação da ocupação do solo desenvolvida a três escalas de análise por sete algoritmos de classificação. Os Quadros 4, 5 e 6 sintetizam as medidas de exactidão temática obtidas pelos algoritmos na classificação de dados a diferentes resoluções espaciais (MERIS, LANDSAT e QUICKBIRD, respectivamente).

Quadro 4 – Medidas de exactidão temática dos algoritmos de classificação testados a partir de dados MERIS

(área de estudo: Portugal Continental)

	ML		LDC		DQDC		KNN		PARZEN		CART		BMP	
	\hat{P}_p	\hat{P}_u	\hat{P}_p	\hat{P}_u	\hat{P}_p	\hat{P}_u	\hat{P}_p	\hat{P}_u	\hat{P}_p	\hat{P}_u	\hat{P}_p	\hat{P}_u	\hat{P}_p	\hat{P}_u
\hat{P}_p = Exactidão do Produtor														
\hat{P}_u = Exactidão do Utilizador														
1.1 Áreas Artificiais Contínuas	59%	74%	56%	61%	40%	47%	61%	35%	35%	55%	46%	64%	42%	60%
1.2 Áreas Artificiais Descontínuas	78%	61%	58%	55%	42%	34%	52%	80%	73%	44%	70%	44%	62%	50%
2.1 Agricultura de Regadio	88%	78%	88%	98%	78%	89%	89%	76%	71%	88%	92%	87%	84%	81%
2.2 Agricultura de Sequeiro	69%	90%	78%	90%	65%	87%	74%	60%	52%	81%	63%	79%	69%	81%
2.3 Arrozais	83%	85%	71%	85%	60%	69%	78%	51%	57%	67%	55%	82%	57%	88%
3.1 Floresta de Folhosas	49%	84%	82%	88%	54%	71%	72%	47%	47%	67%	59%	68%	74%	81%
3.2 Floresta de Resinosas	73%	92%	92%	71%	89%	64%	62%	75%	88%	63%	70%	69%	83%	80%
3.3 Floresta Mista	77%	52%	80%	69%	45%	38%	46%	63%	38%	33%	60%	48%	66%	63%
3.4 Vegetação Herbácea	73%	85%	92%	63%	67%	43%	52%	60%	75%	59%	60%	55%	77%	69%
3.5 Matos	83%	61%	81%	71%	43%	68%	38%	89%	77%	58%	83%	42%	94%	37%
3.6 Vegetação Esparsa	82%	93%	90%	96%	66%	56%	55%	46%	66%	49%	44%	65%	54%	82%
4 Solo Nu	90%	82%	64%	91%	64%	74%	77%	46%	48%	71%	54%	90%	26%	87%
5 Áreas Áridas	75%	100%	88%	85%	78%	74%	83%	65%	65%	79%	82%	95%	75%	100%
6 Zonas Húmidas	94%	67%	92%	90%	67%	60%	59%	65%	65%	55%	73%	75%	86%	68%
7 Corpos de Água	76%	95%	72%	97%	72%	95%	90%	52%	50%	89%	72%	90%	64%	82%
\hat{P} = Exactidão Global	77%		79%		62%		61%		61%		66%		68%	

Quadro 5 – Medidas de exactidão temática dos algoritmos de classificação testados a partir de dados LANDSAT

(áreas de estudo: E, J, A)

	ML		LDC		DQDC		KNN		PARZEN		CART		BMP	
	\hat{P}_p	\hat{P}_u	\hat{P}_p	\hat{P}_u	\hat{P}_p	\hat{P}_u	\hat{P}_p	\hat{P}_u	\hat{P}_p	\hat{P}_u	\hat{P}_p	\hat{P}_u	\hat{P}_p	\hat{P}_u
\hat{P}_p = Exactidão do Produtor														
\hat{P}_u = Exactidão do Utilizador														
1.1 Áreas Artificiais Contínuas	-	-	-	-	-	-	-	-	-	-	-	-	-	-
1.2 Áreas Artificiais Descontínuas	71%	83%	68%	68%	52%	78%	73%	64%	73%	65%	70%	63%	70%	64%
2.1 Agricultura de Regadio	89%	75%	99%	69%	94%	66%	94%	75%	94%	76%	96%	72%	95%	63%
2.2 Agricultura de Sequeiro	81%	75%	68%	74%	74%	62%	68%	74%	67%	74%	67%	67%	78%	71%
2.3 Arrozais	81%	92%	62%	90%	83%	70%	81%	79%	81%	79%	79%	83%	76%	69%
3.1 Floresta de Folhosas	81%	77%	64%	80%	67%	69%	75%	66%	74%	68%	79%	59%	50%	74%
3.2 Floresta de Resinosas	77%	88%	83%	77%	63%	77%	73%	80%	73%	78%	67%	79%	59%	80%
3.3 Floresta Mista	56%	49%	64%	40%	72%	44%	42%	45%	47%	48%	31%	30%	0%	0%
3.4 Vegetação Herbácea	77%	84%	86%	77%	71%	69%	74%	77%	75%	77%	65%	76%	79%	83%
3.5 Matos	73%	78%	72%	74%	67%	72%	67%	70%	67%	69%	65%	69%	77%	58%
3.6 Vegetação Esparsa	65%	70%	45%	58%	41%	42%	57%	67%	59%	67%	49%	65%	36%	66%
4 Solo Nu	96%	74%	91%	88%	90%	82%	92%	81%	93%	82%	90%	81%	90%	79%
5 Áreas Áridas	88%	70%	73%	76%	68%	75%	80%	67%	80%	65%	80%	70%	88%	72%
6 Zonas Húmidas	86%	72%	71%	79%	53%	78%	67%	82%	67%	82%	79%	87%	0%	0%
7 Corpos de Água	83%	97%	88%	96%	84%	97%	87%	97%	87%	97%	86%	97%	89%	86%
\hat{P} = Exactidão Global	79%		75%		69%		74%		74%		71%		71%	

- classe de espaço não representada na área de estudo, à resolução espacial adoptada

Quadro 6 – Medidas de exactidão temática dos algoritmos de classificação testados a partir de dados QUICKBIRD

(áreas de estudo: E, J, A)

	ML		LDC		DQDC		KNN		PARZEN		CART		BMP	
	\hat{P}_p	\hat{P}_u	\hat{P}_p	\hat{P}_u	\hat{P}_p	\hat{P}_u	\hat{P}_p	\hat{P}_u	\hat{P}_p	\hat{P}_u	\hat{P}_p	\hat{P}_u	\hat{P}_p	\hat{P}_u
\hat{P}_p = Exactidão do Produtor														
\hat{P}_u = Exactidão do Utilizador														
1.1 Áreas Artificiais Contínuas	-	-	-	-	-	-	-	-	-	-	-	-	-	-
1.2 Áreas Artificiais Descontínuas	75%	79%	50%	61%	31%	44%	76%	50%	68%	51%	79%	55%	56%	39%
2.1 Agricultura de Regadio	100%	93%	97%	92%	99%	90%	97%	90%	97%	90%	99%	93%	98%	94%
2.2 Agricultura de Sequeiro	83%	70%	73%	67%	78%	62%	82%	63%	81%	66%	79%	66%	76%	44%
2.3 Arrozais	92%	98%	92%	88%	92%	94%	68%	89%	68%	89%	74%	95%	52%	81%
3.1 Floresta de Folhosas	93%	95%	89%	79%	85%	81%	86%	85%	86%	85%	88%	85%	93%	90%
3.2 Floresta de Resinosas	91%	84%	69%	74%	62%	69%	75%	73%	76%	74%	74%	75%	66%	74%
3.3 Floresta Mista	-	-	-	-	-	-	-	-	-	-	-	-	-	-
3.4 Vegetação Herbácea	80%	72%	78%	60%	77%	59%	72%	73%	76%	73%	70%	73%	47%	54%
3.5 Matos	74%	86%	56%	71%	61%	71%	59%	76%	62%	78%	64%	76%	62%	71%
3.6 Vegetação Esparsa	88%	84%	83%	79%	62%	69%	62%	87%	66%	85%	81%	85%	0%	0%
4 Solo Nu	74%	94%	72%	92%	68%	91%	59%	92%	64%	82%	63%	91%	59%	95%
5 Áreas Ardidas	100%	86%	89%	77%	79%	79%	74%	70%	79%	71%	84%	84%	89%	74%
6 Zonas Húmidas	71%	100%	73%	83%	59%	67%	57%	100%	57%	100%	48%	95%	2%	100%
7 Corpos de Água	93%	100%	96%	93%	94%	97%	93%	98%	93%	98%	95%	98%	94%	92%
\hat{P} = Exactidão Global	85%		76%		72%		75%		76%		77%		66%	

- classe de espaço não representada na área de estudo, à resolução espacial adoptada

3.1 Desempenho global dos algoritmos de classificação a diferentes escalas de análise

A comparação da exactidão global (\hat{P}) obtida pelos algoritmos testados às diferentes escalas de análise permitiu compreender que para a maioria dos algoritmos este parâmetro cresceu com o nível de detalhe dos dados de satélite a classificar. Na análise da Figura 2, destaca-se o algoritmo ML pelo melhor desempenho global na classificação do uso do solo, ainda que à escala da MERIS a exactidão global disponibilizada pelo ML tenha sido superada pela obtida pelo algoritmo LDC.




Figura 2 – Exactidão Global obtida pelos algoritmos testados na classificação do Uso do Solo a diferentes resoluções espaciais

Os resultados apresentados, complementados pela análise da Figura 3, possibilitam levantar algumas questões relativas ao desempenho global dos algoritmos na classificação do uso do solo a diferentes escalas de análise.

- Qual o algoritmo que revela melhor desempenho global na classificação desenvolvida a partir dos dados menos detalhados (MERIS)? Serão as exactidões globais produzidas pelo ML e pelo LDC significativamente diferentes à escala da MERIS?

À escala da MERIS, as exactidões globais disponibilizadas pelo ML e pelo LDC são superiores às disponibilizadas pelo restantes classificadores (vide Figura 3). Contudo

não existe evidência estatística de que as exactidões globais proporcionadas pelo ML e pelo LDC sejam significativamente diferentes entre si.

- Qual o algoritmo que revela melhor desempenho global na classificação desenvolvida a partir dos dados LANDSAT? Serão as exactidões globais produzidas pelo ML e pelo LDC significativamente diferentes à escala da LANDSAT?

À escala da LANDSAT, comprova-se que a exactidão global disponibilizada pelo ML é significativamente diferente das exactidões globais disponibilizadas pelos restantes classificadores, incluindo o LDC. A Figura 3 atesta o melhor desempenho global do algoritmo ML.

- Qual o algoritmo que revela melhor desempenho global na classificação desenvolvida a partir dos dados QUICKBIRD?

À escala da QUICKBIRD, existe igualmente evidência que a exactidão global proporcionada pelo ML é significativamente diferente das exactidões globais disponibilizadas pelos restantes classificadores. A Figura 3 testemunha a superioridade do algoritmo ML face ao restantes.

No que diz respeito à exactidão global da classificação do uso do solo produzida pelo ML a diferentes escalas de análise, comprovou-se que à escala da QUICKBIRD aquela exactidão é significativamente diferente da obtida à escala da LANDSAT e da obtida à escala da MERIS. A Figura 4 corrobora que o algoritmo ML teve melhor desempenho global na classificação do uso do solo por recurso a dados QUICKBIRD.

Por fim, comprovou-se que a exactidão global disponibilizada pelo ML à escala da QUICKBIRD é significativamente diferente da exactidão global proporcionada pelo LDC à escala da MERIS. A Figura 4 demonstra que a classificação do uso do solo produzida pelo ML a partir de dados QUICKBIRD foi globalmente mais exacta do que a classificação produzida pelo LDC a partir de dados MERIS.




Figura 3 – Exactidão Global produzida pelos algoritmos testados na classificação do Uso do Solo a diferentes resoluções espaciais: Estimativas e respectivos intervalos de confiança a 95%

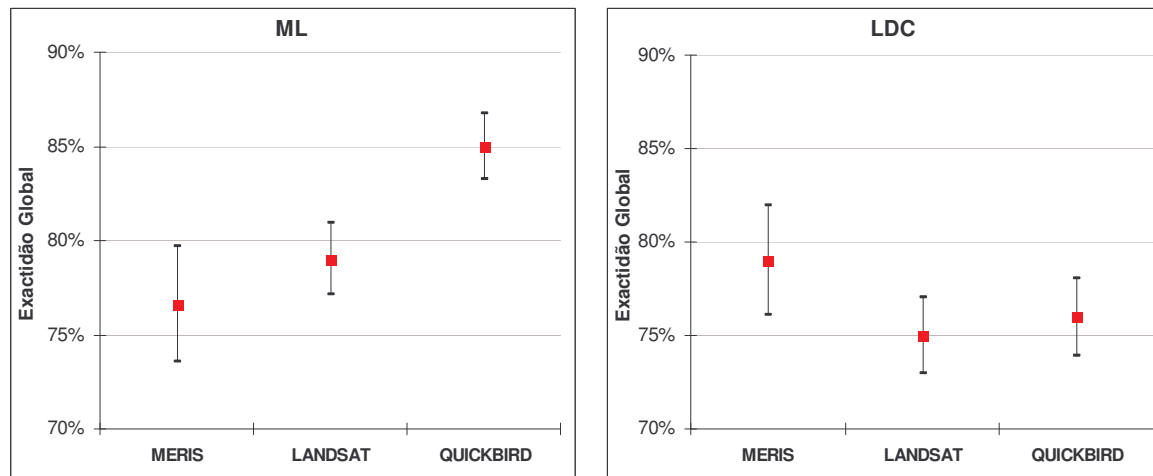


Figura 4 – Exactidão Global produzida pelos algoritmos ML e LDC na classificação do Uso do Solo a diferentes resoluções espaciais: Estimativas e respectivos intervalos de confiança a 95%

3.2 Desempenho dos algoritmos na identificação de classes da nomenclatura LANDAU a diferentes escalas de análise

Uma análise das medidas de exactidão temática produzidas pelos algoritmos de classificação testados para as classes da nomenclatura LANDAU de maior interesse para o projecto, permitiu realçar alguns aspectos que seguidamente se detalham dando ênfase à relação entre a escala de análise e a exactidão da classificação, bem como ao desempenho do algoritmo ML neste contexto.

- Para a grande maioria dos algoritmos ensaiados, as mais elevadas exactidões na classificação da Agricultura de Regadio (2.1) foram obtidas por utilização de imagens QUICKBIRD (vide Figura 5). Com base nestes dados de satélite o algoritmo ML disponibilizou máxima exactidão do produtor ($\hat{P}_p=100\%$) e uma exactidão do utilizador (\hat{P}_u) de 93%.




Figura 5 – Exactidões do Produtor e do Utilizador obtidas pelos algoritmos testados na classificação da Agricultura de Regadio (2.1) a diferentes resoluções espaciais

- Na classificação da Agricultura de Sequeiro (2.2), as maiores exactidões do produtor foram alcançadas por utilização da escala de maior detalhe (imagens QUICKBIRD), mas as mais elevadas exactidões do utilizador foram maioritariamente obtidas através da utilização da escala de menor detalhe (imagem MERIS). Na classificação desta agricultura, o algoritmo ML disponibilizou uma exactidão do produtor (\hat{P}_p) de 83% à escala da QUICKBIRD e uma exactidão do utilizador (\hat{P}_u) de 90% à escala da MERIS (vide Figura 6).

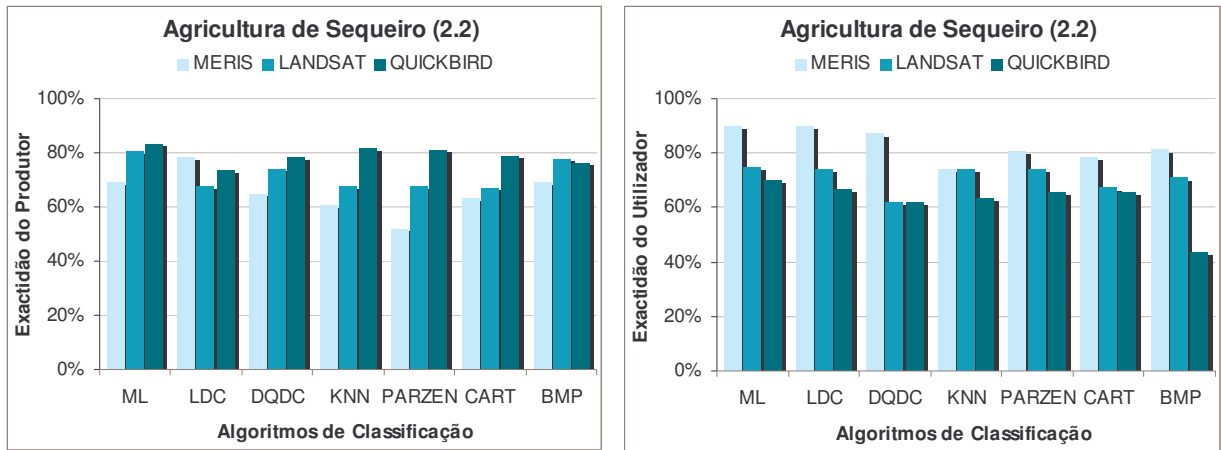


Figura 6 – Exactidões do Produtor e do Utilizador obtidas pelos algoritmos testados na classificação da Agricultura de Sequeiro (2.2) a diferentes resoluções espaciais

- Na classificação dos Arrozais (2.3), as mais elevadas exactidões do utilizador foram maioritariamente obtidas por utilização de imagens QUICKBIRD (vide Figura 7). No entanto, somente três algoritmos (ML, LDC e DQDC) evidenciaram maiores exactidões do produtor a partir da classificação destas imagens. As mais elevadas exactidões do produtor obtidas pelos algoritmos remanescentes resultaram da classificação de imagens LANDSAT. Na classificação dos Arrozais através de imagens QUICKBIRD, o algoritmo ML disponibilizou uma exactidão do produtor (\hat{P}_p) de 92% e uma exactidão do utilizador (\hat{P}_u) de 98%.




Figura 7 – Exactidões do Produtor e do Utilizador obtidas pelos algoritmos testados na classificação de Arrozais (2.3) a diferentes resoluções espaciais

- A classificação da Floresta de Folhosas (3.1) através de imagens QUICKBIRD assegurou a obtenção das mais elevadas exactidões do produtor e do utilizador para quase todos os algoritmos ensaiados (vide Figura 8). Na classificação realizada com base nestas imagens, o ML foi o algoritmo que revelou melhor

desempenho, apresentando uma exactidão do produtor (\hat{P}_p) de 93% e uma exactidão do utilizador (\hat{P}_u) de 95%.




Figura 8 – Exactidões do Produtor e do Utilizador obtidas pelos algoritmos testados na classificação das **Florestas de Folhosas (3.1)** a diferentes resoluções espaciais

- A classificação de Floresta de Resinosas (3.2) realizada a partir da escala mais detalhada (QUICKBIRD) nem sempre assegurou a obtenção das maiores exactidões (vide Figura 9). Na aplicação do algoritmo ML à classificação deste tipo de floresta, a maior exactidão do produtor ($\hat{P}_p=91\%$) foi obtida por classificação de imagens QUICKBIRD, mas a maior exactidão do utilizador ($\hat{P}_u=92\%$) foi obtida por classificação da imagem de menor detalhe (MERIS).

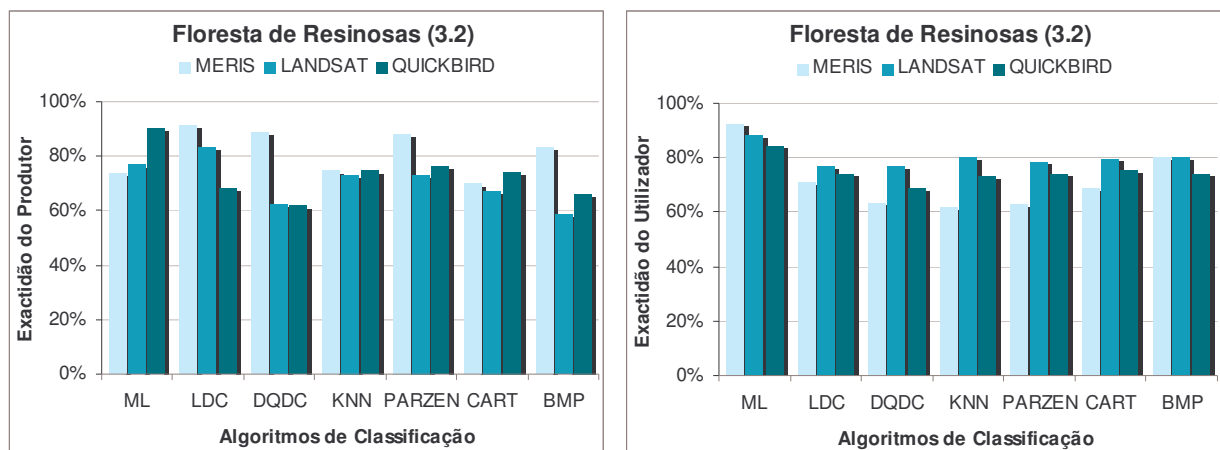


Figura 9 – Exactidões do Produtor e do Utilizador obtidas pelos algoritmos testados na classificação das **Florestas de Resinosas (3.2)** a diferentes resoluções espaciais

- O elevado detalhe proporcionado pelas imagens QUICKBIRD impossibilitou o reconhecimento da Floresta Mista (3.3) nas áreas estudadas. Esta classe de espaço é extremamente difícil de identificar devido à sua heterogeneidade, o que

justifica a reduzida fidelidade na sua classificação, comparativamente a outros tipos de floresta. Na classificação da Floresta Mista através da imagem MERIS, a maioria dos algoritmos produziu exactidões do produtor superiores às obtidas por classificação de imagens LANDSAT (vide Figura 10). Os valores de exactidão do utilizador alcançados na classificação deste tipo de floresta apontam para a inexistência de uma relação entre o nível detalhe dos dados e a magnitude daquela exactidão. Na aplicação do algoritmo ML, quer a maior exactidão do produtor ($\hat{P}_p=77\%$), quer a maior exactidão do utilizador ($\hat{P}_u=52\%$) foram obtidas por classificação da imagem MERIS.




Figura 10 – Exactidões do Produtor e do Utilizador obtidas pelos algoritmos testados na classificação da Floresta Mista (3.3) a diferentes resoluções espaciais

- Na classificação da Vegetação Herbácea (3.4) constata-se igualmente a inexistência de uma relação explícita entre a escala de análise e a exactidão alcançada (vide Figura 11). Na aplicação do algoritmo ML à classificação deste tipo de vegetação, as imagens de maior detalhe (QUICKBIRD) possibilitaram a obtenção da maior exactidão do produtor ($\hat{P}_p=80\%$), no entanto a maior exactidão do utilizador foi alcançada através da classificação da imagem MERIS ($\hat{P}_u=85\%$).

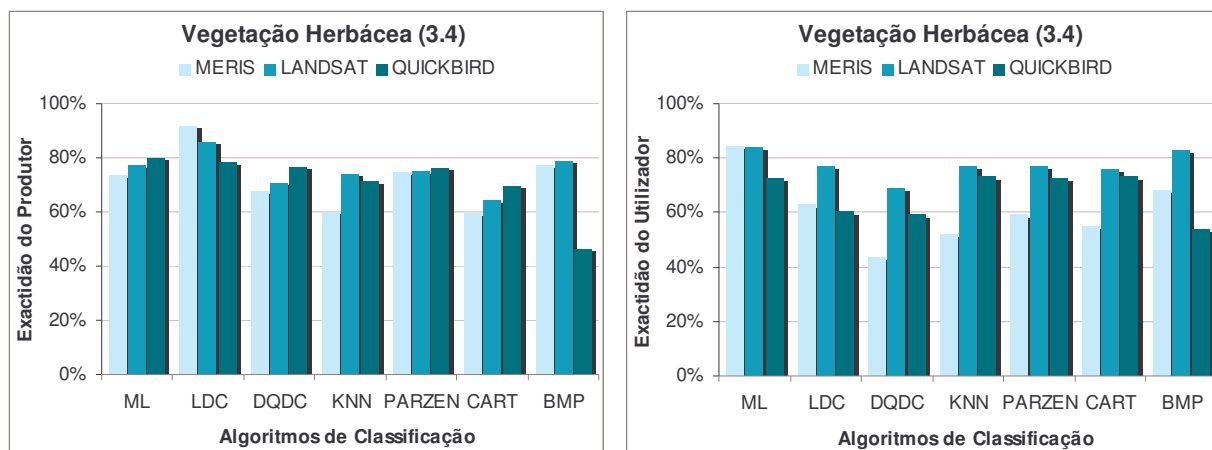


Figura 11 – Exactidões do Produtor e do Utilizador obtidas pelos algoritmos testados na classificação da **Vegetação Herbácea (3.4)** a diferentes resoluções espaciais

- No reconhecimento dos Matos (3.5) a maioria dos algoritmos testados obteve maiores exactidões do produtor através da classificação de dados à escala menos detalhada (imagem MERIS). No que diz respeito à magnitude da exactidão do utilizador (vide Figura 12), verificou-se o fenómeno inverso: as exactidões mais elevadas resultaram da classificação das imagens de maior detalhe (QUICKBIRD). Na classificação desta classe o algoritmo ML obteve uma exactidão do produtor (\hat{P}_p) de 83% à escala da MERIS, e uma exactidão do utilizador (\hat{P}_u) de 86% à escala da QUICKBIRD.




Figura 12 – Exactidões do Produtor e do Utilizador obtidas pelos algoritmos testados na classificação dos **Matos (3.5)** a diferentes resoluções espaciais

- No que concerne à classificação da Vegetação Esparsa (3.6) também não é notória a existência de uma associação entre a escala de análise e a exactidão. Na aplicação do algoritmo ML à classificação deste tipo de vegetação (vide Figura 13), a maior exactidão do produtor ($\hat{P}_p=88\%$) foi proporcionada pela classificação de

imagens QUICKBIRD e a maior exactidão do utilizador ($\hat{P}_u = 93\%$) resultou da classificação da imagem MERIS.




Figura 13 – Exactidões do Produtor e do Utilizador obtidas pelos algoritmos testados na classificação da **Vegetação Esparsa** (3.6) a diferentes resoluções espaciais

- Na identificação de Solo Nu (4) as mais elevadas exactidões do produtor foram produzidas através da classificação de imagens LANDSAT, mas as mais elevadas exactidões do utilizador foram obtidas por classificação de imagens QUICKBIRD (vide Figura 14). Na classificação desta classe o algoritmo ML obteve uma exactidão do produtor (\hat{P}_p) de 96% recorrendo a imagens LANDSAT, e uma exactidão do utilizador (\hat{P}_u) de 94% recorrendo a imagens QUICKBIRD.

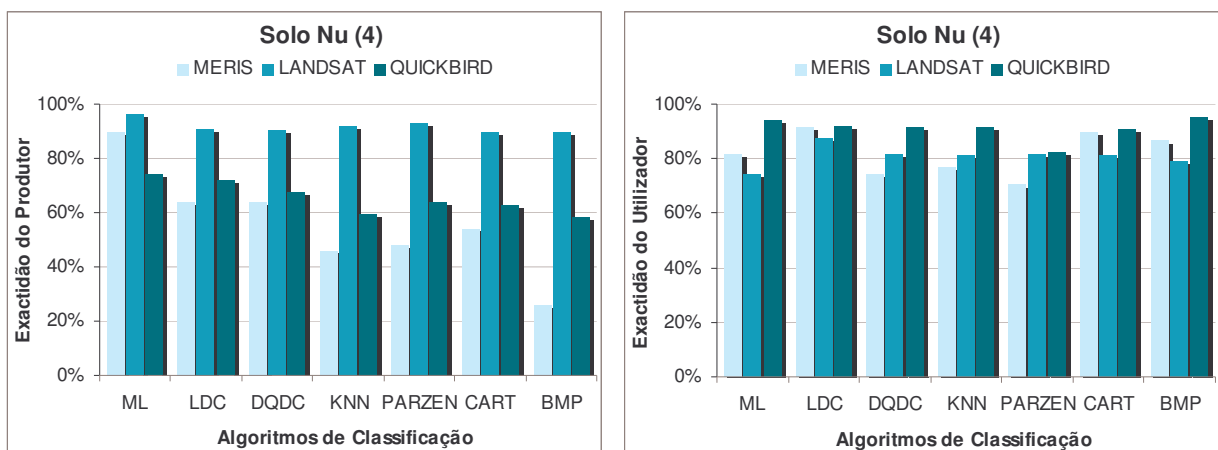


Figura 14 – Exactidões do Produtor e do Utilizador obtidas pelos algoritmos testados na classificação do **Solo Nu** (4) a diferentes resoluções espaciais

- No reconhecimento das Áreas Ardidas (5), a maioria dos algoritmos obteve maiores exactidões do utilizador por classificação de dados MERIS (vide Figura 15). Ao invés, as maiores exactidões do produtor foram geradas através da classificação de dados de muito elevada resolução espacial (QUICKBIRD). Na classificação destas

áreas o algoritmo ML obteve máxima exactidão do utilizador ($\hat{P}_u=100\%$) recorrendo à imagem MERIS e máxima exactidão do produtor ($\hat{P}_p=100\%$) recorrendo às imagens QUICKBIRD.




Figura 15 – Exactidões do Produtor e do Utilizador obtidas pelos algoritmos testados na classificação das **Áreas Áridas (5)** a diferentes resoluções espaciais

- Na classificação das Zonas Húmidas (6) a maioria dos algoritmos testados obteve maiores exactidões do utilizador por recurso a imagens QUICKBIRD e maiores exactidões do produtor por recurso à imagem MERIS (vide Figura 16). Com base nesta imagem, o algoritmo ML produziu a uma exactidão do produtor (\hat{P}_p) de 94%. A máxima exactidão do utilizador ($\hat{P}_u=100\%$) atingida pelo ML decorreu da classificação de imagens QUICKBIRD.




Figura 16 – Exactidões do Produtor e do Utilizador obtidas pelos algoritmos testados na classificação das **Zonas Húmidas (6)** a diferentes resoluções espaciais

- A maioria dos algoritmos testados denotou maior rigor na classificação de Corpos de Água (7) a partir de imagens de muito elevada resolução espacial – QUICKBIRD

(vide Figura 17). Por recurso a estas imagens o ML obteve uma exactidão do utilizador máxima ($\hat{P}_u = 100\%$), e uma exactidão do produtor (\hat{P}_p) de 93%.




Figura 17 – Exactidões do Produtor e do Utilizador obtidas pelos algoritmos testados na classificação de **Corpos de Água (7)** a diferentes resoluções espaciais

3.2.1 Desempenho do algoritmo ML

As Figuras 18 e 19 ilustram respectivamente, a exactidão do produtor e a exactidão do utilizador obtida pelo algoritmo ML na classificação do uso do solo, segundo classes da nomenclatura LANDAU, a partir de dados de diferentes resoluções espaciais.




Figura 18 – **Exactidão do produtor** obtida pelo algoritmo ML na classificação do uso do solo segundo classes da nomenclatura LANDAU, a diferentes resoluções espaciais

Da Figura 18 conclui-se que na classificação do uso do solo através da nomenclatura LANDAU, as exactidões do produtor obtidas pelo algoritmo ML foram na sua maioria mais elevadas quando se utilizaram imagens QUICKBIRD. A adopção da imagem

MERIS conduziu à obtenção de maiores exactidões do produtor na classificação de Áreas Urbanas (1.1 e 1.2), Floresta Mista (3.3), Matos (3.5) e Zonas Húmidas (6). As imagens LANDSAT apenas proporcionaram uma maior exactidão do produtor na classificação do Solo Nu (4).

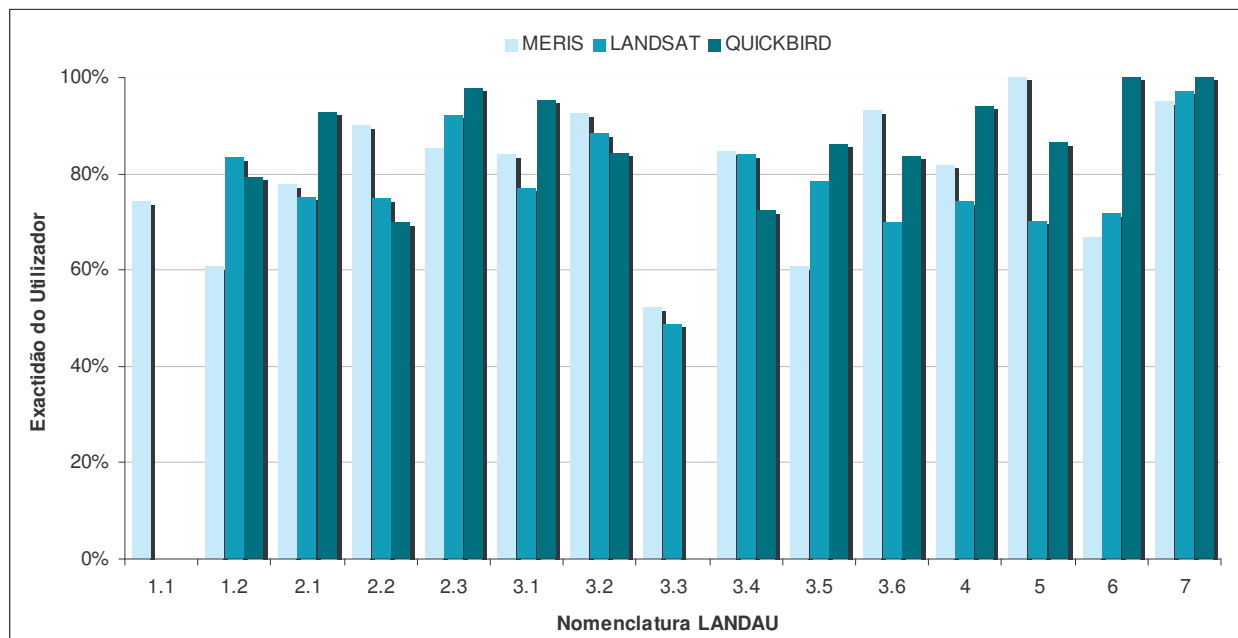


Figura 19 – Exactidão do utilizador obtida pelo algoritmo ML na classificação do uso do solo segundo classes da nomenclatura LANDAU, a diferentes resoluções espaciais

Da Figura 19 conclui-se que na classificação do uso do solo através da nomenclatura LANDAU, as exactidões do utilizador obtidas pelo algoritmo ML nem sempre foram mais elevadas quando se utilizaram imagens QUICKBIRD. Estas permitiram a obtenção de maiores exactidões do utilizador na classificação de Agricultura de Regadio (2.1), Arrozais (2.3), Florestas de Folhosas (3.1), Matos (3.5), Solo Nu (4), Zonas Húmidas (6) e Corpos de Água (7). A adopção da imagem MERIS conduziu à obtenção de maiores exactidões do utilizador na classificação de Agricultura de Sequeiro (2.2), Floresta de Resinosas (3.2), Floresta Mista (3.3), Vegetação Herbácea (3.4), Vegetação Esparsa (3.6) e Áreas Áridas (5). As imagens LANDSAT apenas proporcionaram uma maior exactidão do utilizador na classificação de Áreas Urbanas descontínuas (1.2).

4 Conclusões

O presente estudo visou a comparação do desempenho de sete algoritmos na classificação automática da ocupação de solo a três escalas de análise distintas.

Os resultados apresentados evidenciam o algoritmo ML pelo melhor desempenho

global na classificação do uso do solo e demonstram que à medida que a resolução espacial aumenta, o algoritmo ML revela ganhos na qualidade da classificação.

Embora o desempenho global na classificação do uso do solo por parte do algoritmo LDC não tenha sido significativamente diferente do do ML à escala de menor de detalhe (MERIS), constatou-se que o LDC denota um decréscimo de desempenho na classificação com o aumento da resolução espacial.

A perda de qualidade na classificação por parte do LDC à medida que a resolução espacial aumenta, poderá eventualmente ser justificada pelos pressupostos do próprio algoritmo. Embora o LDC e o ML partilhem o mesmo contexto teórico, porque ambos são classificadores paramétricos que recorrem à teoria de decisão bayesiana (ambos consideram que as classes apresentam uma distribuição Normal e que a classificação a ser atribuída ao pixel é a da classe que maximiza a probabilidade *à posteriori*), os algoritmos diferenciam-se na hipótese da homocedasticidade das classes. Ao invés do algoritmo ML, o algoritmo LDC admite que as classes apresentam igual variabilidade interna (homocedasticidade). Esta diferença introduz duas importantes implicações:

- Enquanto que para o LDC o verdadeiro elemento distintivo de uma classe é o vector médio representativo do centróide da classe, para o ML o padrão de espalhamento, representado pela elipse definida pela matriz de variância-covariância, constitui também um elemento de distinção entre as classes.
- As fronteiras de decisão definidas pelo LDC são hiperplanos de separabilidade, ou seja fronteiras lineares. As fronteiras de decisão definidas pelo ML apresentam um comportamento quadrático, que tanto pode estar associado a uma superfície parabolóide como a uma superfície elíptica.

Face ao exposto, perante dados com pouca resolução, como os da imagem MERIS, não existe detalhe suficiente, de modo que as fronteiras de decisão entre classes podem ser definidas de forma simples, como por exemplo um plano (LDC). Contudo, à medida que a resolução aumenta, as fronteiras entre classes começam a ganhar detalhe, sendo necessário aumentar a complexidade geométrica dessas superfícies de separabilidade. Neste caso, uma superfície simples como um plano tenderá a ser insuficiente. Deste modo, uma superfície mais complexa, como a definida pelo ML, apresentará melhores resultados. De facto, comparando os resultados obtidos à escala da QUICKBIRD com aqueles obtidos à escala da MERIS, podemos observar um ganho de qualidade dos classificadores que definem fronteiras mais complexas (ML, CART,

KNN, PARZEN) e uma perda de qualidade daquelas que definem fronteiras menos complexas (LDC, BMP). Este facto, igualmente realçado pelos resultados do projecto STATLOG (Mitchie *et al.*, 1994; citado por: Hastie *et al.*, 2009), foi também descrito por outros autores, designadamente por Kuncheva (2004) e Hastie e colaboradores (2009).

O presente estudo demonstrou igualmente uma vantagem dos classificadores mais simples (ML e LDC) sobre classificadores mais sofisticados (CART, KNN, BMP). Este resultado é consistente com o que tem sido observado por diferentes investigadores, nomeadamente Wilkinson (2005) e Hand (2006), em que o aparente sucesso no desenvolvimento de algoritmos de classificação cada vez mais sofisticados não se traduz em sucesso na qualidade dos resultados obtidos, quando tais classificadores são utilizados no processamento de dados reais. Os investigadores referidos argumentam que, na prática, os classificadores simples funcionam tão bem quanto os classificadores mais sofisticados, ultrapassando-os mesmo em determinados cenários de aplicabilidade, nomeadamente na simplicidade de utilização em condições reais. Segundo Wilkinson (2005) e Hand (2006), a explicação mais provável para estas observações encontra-se aparentemente na artificialidade dos testes realizados. Ou seja, os classificadores são muitas vezes comparados recorrendo a dados e a condições de “laboratório”, condições estas pouco similares às encontradas em processamento real (Hand, 2006). Deste modo, os resultados do presente estudo sugerem o uso de algoritmos de classificação mais simples, tanto do ponto de vista do utilizador como do ponto de vista computacional (tais como o ML e o LDC), não obstante o recurso a classificadores mais sofisticados quando empiricamente observado que os algoritmos mais simples não conseguem sistematicamente satisfazer as condições impostas pelo problema em análise.

No que diz respeito à escala de análise mais ajustada à classificação do uso do solo com base na nomenclatura LANDAU, as exactidões do utilizador e do produtor obtidas no presente estudo apontam para que se deverão utilizar imagens de menor detalhe (MERIS) na classificação de classes com assinaturas espectrais complexas tais como as Áreas Artificiais Contínuas (1.1) e a Floresta Mista (3.3). Por outro lado, a classificação de Áreas Artificiais Descontínuas (1.2) parece ser favorecida pela utilização de imagens LANDSAT (elevada resolução espacial). As imagens de muito elevada resolução espacial (QUICKBIRD) evidenciaram ser mais ajustadas à classificação da Agricultura de Regadio (2.1), da Floresta de Folhosas (3.1), da Vegetação Esparsa (3.6) e dos Corpos de Água (7). Na classificação das restantes

classes de espaço, não se observou concordância para a maioria dos algoritmos testados entre as escalas de análise que proporcionam a obtenção da maior exactidão do utilizador e do produtor. Ou seja, para a maioria dos classificadores a resolução espacial que assegura a obtenção da maior exactidão do utilizador nem sempre é similar à resolução espacial que assegura a obtenção da maior exactidão do produtor.

5 Referências Bibliográficas

Dinis J, Gonçalves M, Nicolau R, Reis R. Proposta de uma Nomenclatura de Ocupação do Solo. Relatório de execução do projecto LANDAU, Action 3.1 - Task 3. Lisboa, Instituto Geográfico Português, Janeiro 2012a.

Dinis J, Rodrigues P, Gonçalves M, Nicolau R, Reis R. Classificação uni-temporal da ocupação do solo através de dados de média resolução espacial – MERIS. Relatório de execução do projecto LANDAU, Action 3.2 - Task 3. Lisboa, Instituto Geográfico Português, Abril 2012b.

Dinis J, Rodrigues P, Nicolau R. Classificação uni-temporal da ocupação do solo através de dados de muito elevada resolução espacial – QUICKBIRD. Relatório de execução do projecto LANDAU, Action 3.2 - Task 3. Lisboa, Instituto Geográfico Português, Setembro 2012c.

Dinis J, Rodrigues P, Nicolau R. Classificação uni-temporal da ocupação do solo através de dados de elevada resolução espacial – LANDSAT. Relatório de execução do projecto LANDAU, Action 3.2 - Task 3. Lisboa, Direcção-Geral do Território, Dezembro 2012d.

Foody GM. Thematic Map Comparison: Evaluating the Statistical Significance of Differences in Classification Accuracy. *Photogrammetric Engineering & Remote Sensing*, May 2004, Vol. 70, No. 5, pp. 627–633.

Hand D J. Classifier technology and the illusion of progress. *Statistical Science, Institute of Mathematical Statistics*, 2006, Vol. 21, No. 1, 1–15.

Hastie T, Tibshirani R, Friedman J. *The elements of statistical learning: Data mining, inference and prediction*. Springer, 2nd edition, 2009.

Mitchie M, Spiegelhater DJ, Taylor CC. *Machine learning, neural and statistical classification*. Ellis Horwood series in artificial intelligence, 1994.

Nicolau R, Dinis J, Reis R. Definição das áreas de estudo e selecção dos dados de

base. Relatório de execução do projecto LANDAU, Tarefa 1. Lisboa, Instituto Geográfico Português, Junho 2011.

Jensen J R. Introductory digital image processing: a remote sensing perspective. 3rd Ed. Prentice Hall series in geographic information science, 2005.

Wilkinson G G. Results and implications of a study of fifteen years of satellite image classification experiments. IEEE Transactions on Geoscience and Remote Sensing, Vol. 43, No. 3, March 2005.