



Universidade de Coimbra
Faculdade de Ciências e Tecnologia
Departamento de Matemática

Dissertação de Mestrado em Engenharia Geográfica
2011/2012

**Espacialização da exatidão da classificação automática de
imagens multiespectrais usando medidas de incerteza e
classificadores não rígidos**

Spatializing the accuracy of automatic classification of multispectral
images using uncertainty measures and soft classifiers

João Pedro Apolinário Palma

Orientação

Cidália Costa Fonte (FCTUC)
Luísa Gonçalves (IPL)

Coimbra, 2012

Agradecimentos

Gostaria de deixar uma palavra de reconhecimento às minhas orientadoras científicas, Doutora Cidália Costa Fonte e Doutora Luísa Maria da Silva Gonçalves, pelo seu apoio, conselhos e sugestões que, bastante contribuíram para o cumprimento dos objetivos que me foram propostos no início desta dissertação.

À minha família que nunca deixou de me apoiar ao longo do meu percurso, em especial à minha mãe, por sempre acreditar em mim, nas minhas capacidades e no meu crescimento enquanto pessoa, mesmo que isso tenha demorado um pouco mais que o esperado.

À Inês, por ser a minha companheira, por partilhar todos os momentos importantes da minha vida e, particularmente, pelo estímulo dado no decorrer da execução deste trabalho.

|

Nº do aluno: 2000845236

Nome: João Pedro Apolinário Palma

Título da dissertação:

Espacialização da exatidão da classificação automática de imagens multiespetrais usando medidas de incerteza e classificadores não rígidos

Palavras-Chave:

- ✓ Classificação automática de imagens multiespetrais
- ✓ Classificadores não rígidos
- ✓ Exatidão
- ✓ Incerteza
- ✓ Segmentação

Resumo

A classificação automática de imagens multiespectrais é uma importante ferramenta na construção de mapas temáticos de ocupação de solo, permitindo uma monitorização eficaz das alterações paisagísticas e de cobertura de solo, contribuindo para uma melhor gestão dos recursos presentes na superfície terrestre.

Existem diversos tipos de classificadores, sendo de destacar os classificadores rígidos que atribuem, inequivocamente, uma ocupação de solo a um *pixel*, e os classificadores não rígidos que, não atribuem uma classe a um *pixel*, mas definem valores de confiança de atribuição de cada classe a esse *pixel*. Os classificadores não rígidos permitem calcular índices de incerteza representantes da dificuldade que o classificador teve para classificar o *pixel* em questão.

Um tema importante na produção de mapas de cobertura de solo é a avaliação da sua exatidão. Regra geral, esta avaliação da exatidão da classificação é feita recorrendo a matrizes de confusão para toda a imagem classificada mas, uma vez que a exatidão poderá não ser homogénea em toda a classificação, este método não permite obter uma avaliação da variação da exatidão em diferentes zonas da imagem.

O principal objetivo desta dissertação consiste na avaliação da incerteza resultante da classificação de imagens multiespectrais utilizando diferentes classificadores e, conseqüentemente, estudar de que forma esta informação da incerteza poderá ser um indicador para espacializar a exatidão da classificação, em diferentes áreas da imagem classificada.

A abordagem utilizada baseia-se na metodologia proposta por Fonte e Gonçalves (2011), ou seja, são realizadas classificações de duas imagens de diferentes resoluções, utilizando diferentes classificadores não rígidos, sendo as imagens das incertezas resultantes das classificações segmentadas, permitindo diferenciar zonas da classificação com diferentes valores de incerteza. São então, calculadas as médias de incerteza, em cada zona segmentada, e é calculada a exatidão global da classificação para diferentes níveis de

incerteza, assim como a exatidão do utilizador e do produtor, para diferentes níveis de incerteza.

Os estudos realizados e os resultados obtidos mostram que a exatidão resultante da classificação de imagens multiespectrais utilizando classificadores não rígidos varia consistentemente em função do nível de incerteza obtido, o que sugere que a incerteza pode ser um indicador da exatidão da classificação, bem como da espacialização dessa exatidão na classificação em questão.

Abstract

The automatic classification of multispectral images is an important tool in the construction of thematic and land cover maps and, enables an efficient monitoring of landscape and ground cover changes contributing to a better management of resources on the land surface.

Several types of classifiers can be used to produce these maps. Hard classifiers that clearly assign a land occupation type to a pixel, and soft classifiers that do not assign a class to a pixel, but provides information about the degree of membership of that pixel to each of the possible classes. Soft classifiers allow calculating indexes of uncertainty, representing the difficulty that the classifier had to classify the pixel in question.

An important issue in the production of land cover maps is their accuracy evaluation. Generally, this classification accuracy assessment is done by obtaining confusion matrices for the entire classified image but, since the accuracy may not be uniform throughout the classification, this method does not allow an evaluation of the accuracy variation in different areas of the image.

The main objective of the thesis is to assess the uncertainty resulting from the classification of multispectral images using different classifiers, and to investigate how this uncertainty information may be used as an indicator to spatialize the classification accuracy in different areas of the classified image.

It is presented an approach based on the methodology proposed by Fonte and Gonçalves (2011). Two images of different resolutions are classified using different soft classifiers, and the resulting uncertainty images are segmented, allowing to identify different classification areas with different values of uncertainty. Then it is calculated the uncertainty average in each segmented area, and it is calculated the classification overall accuracy and the users and producers accuracy for different levels of uncertainty.

The obtained results show that the accuracy of the classification of multispectral images using soft classifiers varies consistently with the level of uncertainty obtained,

suggesting that the uncertainty information may be an indicator of the accuracy of a classification and an indicator to spatialize the accuracy of the classification in question.

Índice

Agradecimentos.....	i
Resumo.....	v
Abstract.....	vii
Índice.....	ix
Índice de Figuras.....	xii
Índice de Tabelas.....	xvi
1. Introdução.....	1
1.1. Motivação.....	1
1.2. Objetivos.....	2
1.3. Principais contribuições previstas.....	3
2. Enquadramento.....	5
2.1. Classificação automática de imagens multiespectrais.....	5
2.1.1. Classificadores não rígidos.....	6
2.1.2. Incerteza.....	9
2.2.2. Avaliação da exatidão.....	11
2.3. Segmentação de imagens.....	13
3. Espacialização da exatidão.....	15
3.1. Revisão bibliográfica.....	15
3.2. Metodologia.....	16

4. Caso de estudo	20
4.1. Área de estudo	20
4.2. Dados Imagem	20
4.3. Nomenclatura usada	23
4.4. Classificação.....	24
4.5. Cálculo da incerteza	29
4.6. Segmentação da incerteza.....	33
4.7. Avaliação da exatidão	42
4.8. Análise de resultados	47
4.8.1. Comparação dos índices de exatidão global resultantes da classificação da imagem Ikonos..	47
4.8.2. Comparação dos índices de exatidão global resultantes da classificação da imagem Spot	49
4.8.3. Exatidões do utilizador e do produtor, resultantes das classificações da imagem Ikonos, utilizando o classificador da máxima verosimilhança.....	51
4.8.4. Exatidões do utilizador e do produtor, resultantes das classificações da imagem Ikonos, utilizando o classificador BelClass.....	54
4.8.5. Exatidões do utilizador e do produtor, resultantes das classificações da imagem Spot, utilizando o classificador da máxima verosimilhança.....	57
4.8.6. Exatidões do utilizador e do produtor, resultantes das classificações da imagem Spot, utilizando o classificador BelClass.....	60
4.8.7. Espacialização da exatidão obtida em cada intervalo de incerteza resultante da classificação da imagem Ikonos, utilizando o classificador da máxima verosimilhança	62
4.8.8. Espacialização da exatidão obtida em cada intervalo de incerteza resultante da classificação da imagem Ikonos utilizando o classificador BelClass.....	70
4.8.9. Espacialização da exatidão obtida em cada intervalo de incerteza resultante da classificação da imagem Spot utilizando o classificador da máxima verosimilhança	73
4.8.10. Espacialização da exatidão obtida em cada intervalo de incerteza resultante da classificação da imagem Spot utilizando o classificador BelClass.....	77
5. Conclusões.....	84
Bibliografia.....	87

Espacialização da exatidão da classificação automática de imagens multiespectrais usando medidas de incerteza e classificadores não rígidos

Anexos	91
Anexo A – Matrizes de confusão obtidas a partir da classificação da imagem Ikonos, utilizando o classificador da máxima verossimilhança.	91
Anexo B - Matrizes de confusão obtidas a partir da classificação da imagem Ikonos, utilizando o classificador BelClass	94
Anexo C - Matrizes de confusão obtidas a partir da classificação da imagem Spot, utilizando o classificador da máxima verossimilhança	97
Anexo D - Matrizes de confusão obtidas a partir da classificação da imagem Spot, utilizando o classificador BelClass	100

Índice de Figuras

Figura 1 – Fluxograma da metodologia utilizada no decorrer da dissertação	19
Figura 2 - Composição em falsa cor (RGB 432) da imagem Ikonos da região da Marinha Grande	21
Figura 3- Composição em Falsa cor (RGB 432) da imagem Spot.....	22
Figura 4 - Exemplo de áreas de treino definidas para a imagem Ikonos	24
Figura 5 – Diagrama de dispersão da separabilidade das classes da imagem Ikonos (Bandas vermelho e infravermelho próximo)	25
Figura 6- Diagrama de dispersão da separabilidade espectral entre bandas da imagem Spot	26
Figura 7 - Imagem obtida da classificação da imagem Ikonos utilizando o classificador da Máxima Verosimilhança.....	27
Figura 8- Classificação da imagem Ikonos utilizando o classificador BelClass	27
Figura 9- Imagem obtida da classificação da imagem Spot utilizando o classificador da Máxima Verosimilhança.....	28
Figura 10- Classificação da imagem Spot utilizando o classificador BelClass	29
Figura 11- Incerteza resultante da classificação da imagem Ikonos utilizando o classificador da Máxima Verosimilhança	30
Figura 12- Incerteza resultante da classificação da imagem Ikonos utilizando o classificador BelClass	31
Figura 13- Incerteza resultante da classificação da imagem Spot utilizando o classificador da Máxima Verosimilhança	32
Figura 14- Incerteza resultante da classificação da imagem Spot utilizando o classificador BelClass	32
Figura 15- Segmentação da incerteza resultante da classificação da imagem Ikonos, obtida com o classificador da Máxima Verosimilhança.....	34
Figura 16 -Segmentação da incerteza da resultante da classificação da imagem Ikonos, obtida com o classificador BelClass.....	35
Figura 17- Segmentação da incerteza da resultante da classificação da imagem Spot, obtida com o classificador da máxima verosimilhança	36
Figura 18- Segmentação da incerteza da resultante da classificação da imagem Spot, obtida com o classificador BelClass.....	36

Figura 19- Histograma da distribuição da incerteza obtida na classificação da imagem Ikonos, utilizando o classificador da máxima verosimilhança.....	37
Figura 20 - Histograma da distribuição da incerteza obtida na classificação da imagem Ikonos, utilizando o classificador BelClass.....	37
Figura 21- Representação dos intervalos de incerteza resultantes da classificação da imagem Ikonos, utilizando o classificador da máxima verosimilhança.....	38
Figura 22- Representação dos intervalos de incerteza resultantes da classificação da imagem Ikonos utilizando o classificador BelClass.....	39
Figura 23- Histograma da distribuição da incerteza obtida na classificação da imagem Spot, utilizando o classificador da máxima verosimilhança.....	39
Figura 24- Representação dos intervalos de incerteza resultantes da classificação da imagem Spot, utilizando o classificador da máxima verosimilhança.....	40
Figura 25- Histograma da distribuição da incerteza obtida na classificação da imagem Spot, utilizando o classificador BelClass.....	40
Figura 26- Representação dos intervalos de incerteza resultantes da classificação da imagem Spot, utilizando o classificador da máxima verosimilhança.....	41
Figura 27- Exatidões do utilizador obtidas na totalidade da classificação e em cada intervalo de incerteza resultante da classificação da imagem Ikonos, utilizando o classificador da máxima verosimilhança.....	52
Figura 28- Exatidões do produtor obtidas na totalidade da classificação e em cada intervalo de incerteza resultante da classificação da imagem Ikonos, utilizando o classificador da máxima verosimilhança.....	53
Figura 29- Classificação dos níveis de incerteza de 0 a 0.05 e de 0.05 a 0.09 e maior que 0.09 da imagem Ikonos, utilizando o classificador da máxima verosimilhança.....	53
Figura 30- Exatidões do utilizador obtidas na totalidade da classificação e em cada intervalo de incerteza resultante da classificação da imagem Ikonos, utilizando o classificador Belclass.....	55
Figura 31- Classificação dos níveis de incerteza de 0 a 0.75 e de 0.75 a 0.88 e maior que 0.88 da imagem Ikonos, utilizando o classificador BelClass.....	55
Figura 32- Exatidões do produtor obtidas na totalidade da classificação e em cada intervalo de incerteza resultante da classificação da imagem Ikonos, utilizando o classificador Belclass.....	56
Figura 33- Exatidões do utilizador obtidas na totalidade da classificação e em cada intervalo de incerteza resultante da classificação da imagem Spot, utilizando o classificador da máxima verosimilhança.....	58
Figura 34- Classificação dos níveis de incerteza de 0 a 0.12, de 0.12 a 0.19 e maior que 0.19 da imagem Spot, utilizando o classificador da máxima verosimilhança.....	58

Figura 35- Exatidões do produtor obtidas na totalidade da classificação e em cada intervalo de incerteza resultante da classificação da imagem Spot, utilizando o classificador da máxima verosimilhança.....	59
Figura 36- Exatidões do utilizador obtidas na totalidade da classificação e em cada intervalo de incerteza resultante da classificação da imagem Spot, utilizando o classificador BelClass.....	60
Figura 37- Classificação dos níveis de incerteza de 0 a 0,82, de 0,82 a 0,87 e maior que 0,87 da imagem Spot, utilizando o classificador BelClass	61
Figura 38- Exatidões do produtor obtidas na totalidade da classificação e em cada intervalo de incerteza resultante da classificação da imagem Spot, utilizando o classificador BelClass.....	62
Figura 39 – Ocupação de solo das zonas de incerteza menor que 0,05, resultante da classificação da imagem Ikonos, utilizando o classificador da máxima Verosimilhança	63
Figura 40- Ocupação de solo das zonas de incerteza entre 0,05 e 0,09, resultante da classificação da imagem Ikonos, utilizando o classificador da máxima Verosimilhança	66
Figura 41- Imagem da ocupação de solo relativa à zona 1, demarcada na Figura 40	66
Figura 42 – Imagem da ocupação de solo relativa à zona 2, demarcada na Figura 40.....	67
Figura 43- Ocupação de solo das zonas de incerteza entre maior que 0,09, resultante da classificação da imagem Ikonos, utilizando o classificador da máxima Verosimilhança	68
Figura 44- Imagem da ocupação de solo relativa à zona 1, demarcada na Figura 43	69
Figura 45- Imagem da ocupação de solo relativa à zona 2, demarcada na Figura 43	69
Figura 46- Imagem da ocupação de solo relativa à zona 3, demarcada na Figura 43	69
Figura 47- Ocupação de solo das zonas de incerteza menor que 0,75, resultante da classificação da imagem Ikonos, utilizando o classificador BelClass.....	70
Figura 48 – Exemplo de <i>pixels</i> que na realidade são floresta, apesar de serem classificados pelo classificador BelClass, como vegetação arbustiva (zona demarcada na imagem 47)	71
Figura 49- Ocupação de solo das zonas de incerteza entre 0,75 e 0,88, resultante da classificação da imagem Ikonos, utilizando o classificador BelClass.....	72
Figura 50- Ocupação de solo das zonas de incerteza maior que 0,88, resultante da classificação da imagem Ikonos, utilizando o classificador BelClass.....	73
Figura 51- Ocupação de solo das zonas de incerteza menor que 0,12, resultante da classificação da imagem Spot, utilizando o classificador da máxima Verosimilhança.....	74
Figura 52- Ocupação de solo das zonas de incerteza entre 0,12 e 0,19, resultante da classificação da imagem Spot, utilizando o classificador da máxima Verosimilhança.....	75
Figura 53- Ocupação de solo das zonas de incerteza entre maior que 0,19, resultante da classificação da imagem Spot, utilizando o classificador da máxima Verosimilhança	76
Figura 54 – Ocupação de solo presente na zona demarcada na Figura 63.....	76

Figura 55- Ocupação de solo das zonas de incerteza menor que 0.82, resultante da classificação da imagem Spot, utilizando o classificador BelClass	78
Figura 56- Zona de menor incerteza comum à classificação da imagem Spot com os dois classificadores.....	78
Figura 57- Imagem da ocupação de solo da região demarcada na Figura 56	79
Figura 58- Ocupação de solo das zonas de incerteza entre 0.82 e 0.87, resultante da classificação da imagem Spot, utilizando o classificador BelClass	80
Figura 59 - Ocupação de solo das zonas de incerteza maior que 0.87, resultante da classificação da imagem Spot, utilizando o classificador BelClass	81
Figura 60 - Imagem da ocupação de solo relativa à zona 1, demarcada na Figura 59	81
Figura 61 - Imagem da ocupação de solo relativa à zona 2, demarcada na Figura 59	81
Figura 62 - Imagem da ocupação de solo relativa à zona 3, demarcada na Figura 59	82
Figura 63 - Imagem da ocupação de solo relativa à zona 4, demarcada na Figura 59	82
Figura 64 - Zona de maior incerteza comum à classificação da imagem Spot com os dois classificadores.....	83

Índice de Tabelas

Tabela 1 – Exemplo de uma matriz de confusão.....	11
Tabela 2- Características da imagem Ikonos utilizada no estudo	21
Tabela 3 - Característica da imagem Spot utilizada no estudo	22
Tabela 4- Variação da incerteza em função da imagem e do classificador utilizado	30
Tabela 5-Exatidão global (%) dos diferentes intervalos de incerteza resultantes da classificação da imagem Ikonos, utilizando o classificador da máxima verosimilhança	43
Tabela 6- Exatidão do utilizador (%) para os diferentes intervalos de incerteza resultantes da classificação da imagem Ikonos, utilizando o classificador da máxima verosimilhança	44
Tabela 7- Exatidão do produtor (%) para os diferentes intervalos de incerteza resultantes da classificação da imagem Ikonos, utilizando o classificador da máxima verosimilhança	44
Tabela 8- Exatidão global (%) dos diferentes intervalos de incerteza resultantes da classificação da imagem Ikonos, utilizando o classificador BelClass	44
Tabela 9- Exatidão do utilizador (%) para os diferentes intervalos de incerteza resultantes da classificação da imagem Ikonos, utilizando o classificador BelClass	44
Tabela 10- Exatidão do produtor (%) para os diferentes intervalos de incerteza resultantes da classificação da imagem Ikonos, utilizando o classificador BelClass	45
Tabela 11- Exatidão global (%) dos diferentes intervalos de incerteza resultantes da classificação da imagem Spot utilizando o classificador da máxima verosimilhança.....	45
Tabela 12- Exatidão do utilizador (%) para os diferentes intervalos de incerteza resultantes da classificação da imagem Spot utilizando o classificador da máxima verosimilhança.....	45
Tabela 13- Exatidão do produtor (%) para os diferentes intervalos de incerteza resultantes da classificação da imagem Spot utilizando o classificador da máxima verosimilhança.....	46
Tabela 14- Exatidão global (%) dos diferentes intervalos de incerteza resultantes da classificação da imagem Spot utilizando o classificador BelClass.....	46
Tabela 15- Exatidão do utilizador (%) para os diferentes intervalos de incerteza resultantes da classificação da imagem Spot utilizando o classificador BelClass.....	46
Tabela 16- Exatidão do produtor (%) para os diferentes intervalos de incerteza resultantes da classificação da imagem Spot utilizando o classificador BelClass.....	47
Tabela 17- Exatidão Global dos vários níveis de incerteza das classificações da imagem Ikonos, utilizando o classificador da Máxima Verosimilhança e o classificador BelClass	49

Tabela 18- Exatidão Global dos vários níveis de incerteza das classificações da imagem Spot, utilizando o classificador da Máxima Verosimilhança e o classificador BelClass	51
Tabela 19 – Área urbana total e percentagem por cada nível de incerteza resultante da classificação da imagem Ikonos, com o classificador da máxima verosimilhança.....	64
Tabela 20 - Valor das áreas de cada classe na incerteza entre 0.05 e 0.09, resultante da classificação da imagem Ikonos, utilizando o classificador da máxima verosimilhança	65
Tabela 21 - Valor das áreas de cada classe no intervalo de incerteza maior que 0.09, resultante da classificação da imagem Ikonos, utilizando o classificador da máxima verosimilhança	67
Tabela 22- Matriz de confusão da classificação da imagem Ikonos, utilizando o classificador da Máxima verosimilhança (amostra 500).....	91
Tabela 23- Matriz de confusão obtida a partir da amostra de 750 pontos, resultante da classificação da imagem Ikonos, utilizando o classificador da Máxima Verosimilhança.....	91
Tabela 24- Matriz de confusão da incerteza menor ou igual que 0.05, resultante da classificação da imagem Ikonos, com o classificador da Máxima Verosimilhança	92
Tabela 25- Matriz de confusão da incerteza entre 0.05 e 0.09 resultante da classificação da imagem Ikonos, utilizando o classificador da Máxima Verosimilhança	92
Tabela 26- Matriz de confusão da incerteza maior que 0.09 resultante da classificação, da imagem Ikonos, utilizando o classificador da Máxima Verosimilhança	92
Tabela 27- Matriz de confusão da incerteza menor que 0.10 resultante da classificação, da imagem Ikonos, utilizando o classificador da Máxima Verosimilhança	93
Tabela 28- Matriz de confusão da incerteza menor entre 0.10 e 0.15 resultante da classificação, da imagem Ikonos, utilizando o classificador da Máxima Verosimilhança	93
Tabela 29- Matriz de confusão da incerteza maior que 0.15 resultante da classificação, da imagem Ikonos, obtida com o classificador da Máxima Verosimilhança.....	93
Tabela 30- Matriz de confusão da classificação da imagem Ikonos utilizando o classificador BelClass (amostra 500).....	94
Tabela 31- Matriz de confusão obtida a partir da amostra de 750 pontos resultante da classificação, da imagem Ikonos, utilizando o classificador BelClass	94
Tabela 32- Matriz de confusão da incerteza menor ou igual que 0.75 resultante da classificação da imagem Ikonos, utilizando o classificador BelClass	95
Tabela 33- Matriz de confusão da incerteza entre 0.75 e 0.88 resultante da classificação da imagem Ikonos, utilizando o classificador BelClass.....	95
Tabela 34- Matriz de confusão da incerteza maior que 0.88 resultante da classificação da imagem Ikonos, utilizando o classificador BelClass.....	95
Tabela 35- Matriz de confusão da incerteza menor que 0.60 resultante da classificação da imagem Ikonos, utilizando o classificador BelClass.....	96

Tabela 36- Matriz de confusão da incerteza entre 0.60 e 0.80 resultante da classificação da imagem Ikonos, utilizando o classificador BelClass.....	96
Tabela 37- Matriz de confusão da incerteza maior que 0.80 resultante da classificação da imagem Ikonos, utilizando o classificador BelClass.....	96
Tabela 38 -Matriz de confusão da classificação da imagem Spot, utilizando o classificador da Máxima verosimilhança (amostra 500).....	97
Tabela 39- Matriz de confusão com a amostra de 750 pontos resultante da classificação da imagem Spot, utilizando o classificador da Máxima Verosimilhança.....	97
Tabela 40- Matriz de confusão da incerteza menor ou igual que 0.12 resultante da classificação da imagem Spot, utilizando o classificador da Máxima Verosimilhança	98
Tabela 41- Matriz de confusão da incerteza entre 0.12 e 0.19 resultante da classificação da imagem Spot, utilizando o classificador da Máxima Verosimilhança.....	98
Tabela 42- Matriz de confusão da incerteza maior que 0.19 resultante da classificação da imagem Spot, utilizando o classificador da Máxima Verosimilhança.....	98
Tabela 43- Matriz de confusão da incerteza menor que 0.10 resultante da classificação da imagem Spot, utilizando o classificador da Máxima verosimilhança.....	99
Tabela 44- Matriz de confusão da incerteza entre 0.10 e 0.20 resultante da classificação, da imagem Spot, utilizando o classificador da Máxima verosimilhança.....	99
Tabela 45- Matriz de confusão da incerteza maior que 0.20 resultante da classificação da imagem Spot, utilizando o classificador da Máxima verosimilhança.....	99
Tabela 46- Matriz de confusão da classificação da imagem Spot, utilizando o classificador BelClass (amostra 500).....	100
Tabela 47- Matriz de confusão com a amostra de 750 pontos resultante da classificação da imagem Spot, utilizando o classificador BelClass.....	100
Tabela 48- Matriz de confusão da incerteza menor ou igual que 0.82 resultante da classificação da imagem Spot, utilizando o classificador BelClass.....	101
Tabela 49- Matriz de confusão da incerteza entre 0.82 e 0.87 resultante da classificação da imagem Spot, utilizando o classificador da BelSpot	101
Tabela 50- Matriz de confusão da incerteza maior que 0.87 resultante da classificação da imagem Spot, utilizando o classificador da BelSpot	101
Tabela 51- Matriz de confusão da incerteza menor que 0.65 resultante da classificação da imagem Spot, utilizando o classificador BelClass.....	102
Tabela 52- Matriz de confusão da incerteza entre 0.65 e 0.85 resultante da classificação da imagem Spot, utilizando o classificador BelClass.....	102
Tabela 53- Matriz de confusão da incerteza maior que 0.85 resultante da classificação da imagem Spot, utilizando o classificador BelClass.....	102

1. Introdução

1.1. Motivação

Hoje em dia, é necessário fazer uma gestão de recursos naturais e de uso de solo, por forma a responder aos novos desafios ambientais, de ordenamento do território e económicos, que o desenvolvimento da ciência e da tecnologia colocaram. Neste sentido, é fundamental haver um maior conhecimento e representação fiel dos fenómenos e recursos presentes à superfície da terra, pelo que a deteção remota assumiu uma posição de relevo no controlo e monitorização desses recursos, elaborando mapas de ocupação e uso de solo. A análise e interpretação de imagens de satélite de alta resolução permitem identificar e mapear alterações da ocupação e uso do solo, estudando detalhadamente evoluções ambientais, tanto ao nível de gestão florestal como do planeamento urbano.

Uma das principais ferramentas na produção de cartografia de ocupação de solo, é a classificação automática de imagens de satélite que consiste na atribuição de um tipo de ocupação de solo a cada *pixel* da imagem, de acordo com a resposta espectral desse mesmo *pixel*. Uma abordagem, característica de classificadores designados por classificadores rígidos, é baseada na atribuição inequívoca de uma determinada classe a cada unidade espacial da imagem (um *pixel* ou um objeto). No entanto, esta dissertação será centrada na análise de resultados obtidos a partir de classificadores não-rígidos, que não atribuem definitivamente uma classe a um *pixel*, mas definem valores de **confiança e valores de incerteza**, para a atribuição de cada classe ao *pixel* em questão. A partir deste tipo de classificação podem obter-se classificações rígidas, atribuindo a cada *pixel* a classe a que está associado um maior grau de confiança.

Naturalmente, estes processos não são isentos de erros e, como tal, é necessário aferir a qualidade e consequente exatidão da classificação. Esta avaliação é, normalmente, feita a partir da geração de matrizes de confusão para toda a imagem classificada, onde é calculado um **índice de exatidão global da classificação, bem como, valores da exatidão do produtor e do utilizador, por classe**. No entanto, esta exatidão poderá não ser uniforme em toda a imagem classificada, havendo regiões com um maior nível de

exatidão e outras com uma exatidão mais baixa. Esta variação não pode ser estudada usando as tradicionais matrizes de confusão globais, sendo por isso necessário desenvolver formas alternativas de realizar a avaliação da qualidade da classificação. Neste contexto, Fonte e Gonçalves (2011), a partir segmentação da imagem da incerteza resultante de uma classificação não rígida, mostrou que zonas escolhidas em regiões de interesse e com diferentes valores de incerteza, apresentam exatidões diferentes.

Este trabalho, com base na abordagem proposta em Fonte e Gonçalves (2011), através da segmentação da imagem em função da variação da incerteza de toda a classificação, pretende estudar a variação da exatidão em toda a imagem, bem como espacializar essa exatidão em função da incerteza e da ocupação de solo correspondente. Deste ponto de vista, é necessário identificar em que medida a informação da incerteza poderá ser representativa dos diferentes níveis de exatidão em várias zonas da imagem, para a nomenclatura escolhida e para vários níveis de segmentação de incerteza.

1.2. Objetivos

Esta dissertação tem como objetivo principal averiguar se a informação sobre a incerteza resultante da utilização de vários classificadores não rígidos, para classificar imagens multiespectrais, pode ser utilizado como indicador para espacializar a exatidão da classificação. Neste sentido, torna-se importante compreender de que forma a informação da incerteza poderá ter influência, ou ser representativa, na obtenção de diferentes níveis de exatidão em diversas zonas da imagem classificada, de acordo com as classes de ocupação de solo definidas.

Para estes objetivos serem devidamente atingidos é necessário compreender de que forma variam a incerteza e a exatidão em função do classificador utilizado, e se maiores valores de incerteza produzem coeficientes de exatidão mais baixos. É também, importante estudar a exatidão global, do produtor e do utilizador, para todas as classes e para toda a imagem.

De forma a obter-se a variação da exatidão em diferentes zonas resultantes da classificação da imagem utilizando classificadores não rígidos, a imagem da incerteza obtida é segmentada. Após as imagens da incerteza resultante da classificação com os diferentes

classificadores serem segmentadas, é necessário verificar de que forma variam os valores de exatidão para cada zona segmentada em função de diferentes níveis de incerteza. Finalmente é também observado que tipo de ocupação de solo está presente nas diferentes zonas com diferentes níveis de incerteza e de que forma estes tipos de ocupação de solo poderão ter influenciado os resultados da exatidão obtida em cada nível de incerteza da classificação.

1.3. Principais contribuições previstas

A avaliação da exatidão da classificação automática de imagens multiespetrais, permite obter importantes indicadores sobre a qualidade da classificação. Regra geral, esta avaliação é feita através da geração de matrizes de confusão para toda a imagem classificada, sem ser analisada a variação espacial dessa exatidão.

Já foram desenvolvidos alguns estudos com o objetivo de considerar esta variação da exatidão na imagem, mas com escassas referências à sua espacialização. Woodcock *et al* (2001), definiu matrizes de confusão associadas a *pixels* com diferentes níveis de confiança e também foram realizadas experiências desenvolvendo as matrizes de confusão da classificação nas imediações de pontos de interesse relevante (Foody,2005). No campo da análise da relevância dos valores de incerteza resultantes de uma classificação não rígida, Gonçalves *et al* (2010) e Gonçalves *et al* (2009) mostraram que estes valores de incerteza podem ser considerados como indicadores válidos da exatidão de uma classificação.

No entanto, é necessário averiguar até que ponto existe uma relação entre a incerteza resultante de uma classificação utilizando classificadores não rígidos e a forma como a exatidão é distribuída espacialmente em toda a imagem. Assim, esta dissertação pretende contribuir para um maior conhecimento ao nível da correlação entre a incerteza e a espacialização da exatidão resultante da classificação de imagens multiespetrais utilizando classificadores não rígidos e, através da segmentação dessa incerteza, compreender a sua relação com os diferentes níveis de exatidão presentes na imagem classificada. Para tal, foram classificadas diferentes imagens da mesma região, com diferentes resoluções e que, por isso, apresentam diferentes dificuldades à classificação, em função da maior presença de *pixels* mistos nas imagens de menor resolução ou o maior grau de detalhe nas imagens de

maior resolução. Foram também utilizados diversos classificadores, o que permitiu avaliar a diferença de resultados obtidos, de acordo com o classificador.

2. Enquadramento

2.1. Classificação automática de imagens multiespectrais

A classificação automática de imagens multiespectrais é, atualmente, uma das mais importantes ferramentas utilizadas na detecção remota e pretende delinear regiões ou categorias de ocupação da superfície terrestre, a partir de valores de radiação espectral dos *pixels* de imagens obtidas por satélites em órbita à volta da Terra.

Mais recentemente, o lançamento de satélites que obtêm imagens de muito alta resolução veio colocar novos desafios e problemas neste campo de estudo, o que conduziu ao seu desenvolvimento e conseqüente aparecimento de novas tecnologias. Este aumento da resolução espacial permitiu, por exemplo, a utilização destas imagens em contexto urbano; no entanto, uma maior variabilidade espectral e um maior grau de detalhe, facilita a presença de *pixels* de sombra e pode provocar erros na classificação (Goetz *et al*, 2003). Outro problema presente neste tipo de imagens, é a frequente presença de *pixels* mistos, ou seja a existência de mais do que um tipo de ocupação de solo no *pixel* em questão, o que, em conjunto com as limitações descritas anteriormente, torna a classificação um processo bastante complexo e nem sempre com resultados satisfatórios. Por isso, o estudo e desenvolvimento de novas tecnologias e de novas formas de realizar a classificação, continua a ser um campo de investigação bastante explorado, conduzindo ao aparecimento de diversos tipos de classificadores.

Os classificadores, atualmente, mais comuns são baseados em diversas teorias, como as teorias de probabilidade e de possibilidade aplicadas a noções de conjuntos clássicos, onde a pertença de um objeto a um conjunto é verdadeira ou falsa, não permitindo a transição gradual entre pertença ou não pertença. Outros exemplos de teorias que servem de suporte teórico para o desenvolvimento de classificadores, são as redes neuronais ou máquinas de suporte vetorial (*Support vector machines*). Por outro lado, uma importante generalização da teoria clássica de conjuntos, que apresenta a noção de conjuntos difusos (*fuzzy*) e assenta na possibilidade de transição de um objeto entre

conjuntos, em que o grau de pertença desse objeto é definido através de uma função, levou ao aparecimento de classificadores *fuzzy*.

O processo de classificação pode associar apenas uma classe de ocupação de solo a cada *pixel* da imagem e, neste caso, o classificador é dito rígido, ou então pode definir um conjunto de valores que avaliam o grau de pertença de cada *pixel* a cada classe considerada, sendo chamados classificadores não rígidos (Wang, 1990; Foody, 2000b; Ibrahim *et al*, 2005). É possível realizar classificações rígidas a partir de um classificador não rígido, bastando, para isso, atribuir a cada unidade espacial da imagem (*pixel*), a classe que apresenta o maior grau de pertença. Nesta dissertação irão ser utilizados classificadores não rígidos, pelo que estes serão descritos com maior detalhe no ponto seguinte.

Regra Geral o processo de classificação baseia-se na classificação assistida ou supervisionada e assenta em três importantes fases. Em primeiro lugar definir áreas de treino, que descrevem as respostas espectrais de cada classe de ocupação de solo; de seguida, a partir dos resultados obtidos na fase anterior, atribuir uma classe a cada *pixel* da imagem ou valores de pertença a cada classe, caso sejam utilizados classificadores rígidos ou classificadores não rígidos; finalmente, avaliar a classificação calculando índices de exatidão para os resultados obtidos.

2.1.1. Classificadores não rígidos

Classificadores não rígidos, ao contrário de classificadores rígidos, não associam definitivamente uma classe a um *pixel*. **Produzem, através dos valores das assinaturas espectrais contidas nas zonas de treino, um conjunto de valores que avaliam o grau de pertença desse *pixel* a cada classe definida e permitem avaliar a incerteza da classificação.**

Os resultados obtidos com uma classificação utilizando classificadores não rígidos, não é uma única imagem da ocupação do solo mas um conjunto de imagens (uma por classe) que representam valores de confiança de atribuição de uma determinada classe a um *pixel* e índices de incerteza que podem ser interpretados como a dificuldade do classificador para atribuir uma classe a esse *pixel*.

Como exemplos de classificadores não rígidos, é possível referir o classificador fuzzy baseado na mínima distância à média, o classificador probabilístico da máxima

verossimilhança que calcula probabilidades a posteriori, a partir do teorema de Bayes ou classificadores baseados na teoria de Dempster-Shafer, entre outros.

Neste trabalho, uma vez que estão presentes no *software* Idrisi Taiga e apresentam diferentes graus de atribuição de cada classe a cada pixel, o que permite calcular valores de incerteza da classificação, são utilizados o classificador probabilístico da máxima verossimilhança e um classificador baseado na teoria de Dempster-Shafer, pelo que seguidamente apenas estes serão desenvolvidos com maior detalhe.

O classificador probabilístico da máxima verossimilhança apresenta como resultados uma imagem por classe e calcula a probabilidade, a posteriori, de cada *pixel* pertencer a essa classe, a partir da função densidade apresentada de seguida: (Foody *et al*, 1992)

$$p(\mathbf{x}_k|i) = \frac{1}{(2\pi)^{n/2}|\mathbf{V}_i|^{1/2}} \exp(-1/2[(\mathbf{X}_k - \mathbf{u}_i)^T \mathbf{V}_i^{-1}(\mathbf{X}_k - \mathbf{u}_i)]) \quad (1)$$

Onde $\mathbf{p}(\mathbf{x}_k|i)$ é uma função densidade de pertença de um *pixel* \mathbf{x}_k à classe i , n é o número de bandas, \mathbf{X}_k é o vector das respostas espectrais do *pixel* em cada banda, \mathbf{V}_i é a matriz de variância-covariância para a classe i e \mathbf{u}_i é o vector média para a classe i utilizando todos os *pixels*.

O termo $[(\mathbf{X}_k - \mathbf{u}_i)^T \mathbf{V}_i^{-1}(\mathbf{X}_k - \mathbf{u}_i)]$ é a distância de Mahalanobis entre o *pixel* e o centróide da classe i .

As probabilidades, a posteriori, calculadas a partir do teorema de Bayes são obtidas pela formula apresentada em (2)

$$p_i(\mathbf{x}_k) = \frac{p(\mathbf{x}_k|i) * P(i)}{\sum_{i=1}^t p(\mathbf{x}_k|i) * P(i)} \quad (2)$$

Sendo $\mathbf{p}(\mathbf{x}_k|i)$ a função densidade de probabilidade, a posteriori, de pertença de um *pixel* à classe i (probabilidade de a hipótese ser verdadeira dada a evidencia, ou seja uma vez conhecidos os valores experimentais), $\mathbf{P}(i)$ é a probabilidade a priori da classe i (probabilidade da hipótese ser verdadeira independentemente da evidencia, ou seja antes de conhecidos os dados experimentais), e t é o numero total de classes. Para cada *pixel*, a soma das probabilidades a posteriori é 1 (Foody *et al*, 1992).

Assim, de acordo com este classificador, fica definido para cada *pixel* uma distribuição da probabilidade a cada classe; por exemplo a um *pixel* pode ficar associado uma probabilidade de 0.8 de pertença à classe urbano, 0.1 à classe solo nu e 0.1 à classe vegetação arbustiva.

O classificador baseado na teoria da evidência de Dempster-Shafer é uma variação da teoria de probabilidades de Bayes que assume a possibilidade da ignorância, ou seja não assume que tem acesso a toda a informação. Este classificador apresenta valores de confiança ou crença de pertença de um *pixel* a determinada classe (*belief*), ou a medida em que os valores observados não refutam a hipótese de pertença a uma classe, designada por plausibilidade (*plausability*).

A função que o classificador, baseado na teoria de Dempster-Shafer, utiliza para calcular os valores de *belief* e que devolve um valor do grau de associação a uma classe (*commonality*) é o seguinte (3) (Idrisi Taiga *Help*):

$$c_i(x_k) = \frac{p(x_k|i) * P(i)}{\max[p(x_k|i) * P(i)]} \quad (3)$$

O cálculo deste valor começa por ser semelhante ao utilizado no cálculo das probabilidades no classificador da máxima verosimilhança; no entanto, em vez de normalizar este valor pelo seu somatório, normaliza-o pelo valor máximo presente em toda a imagem.

Esta teoria assenta no pressuposto de existir pelo menos um *pixel* que é uma representação perfeita de cada classe (possivelmente um pixel pertencente a uma área de treino), pelo que os valores do grau de associação (*commonality*) variam entre 0 (nenhum grau de associação a uma classe) e 1 (grau máximo de associação).

O próximo passo para encontrar os valores de confiança de pertença de um *pixel* a uma classe (*beliefs*), consiste em ordenar os valores de *commonality*, para cada pixel e calcular probabilidades pela diferença entre valores consecutivos, para todas as classes. O valor de *belief* será o somatório de todos os valores das probabilidades.

2.1.2. Incerteza

A cartografia elaborada a partir de deteção remota deve ser bastante fiável, de forma a apresentar produtos de qualidade e poder responder às necessidades que o desenvolvimento de novas tecnologias suscita, como a integração em sistemas de informação geográfica. Assim, é importante abordar esta questão com a perspectiva de melhor compreender a fonte de possíveis erros e quantificar e caracterizar a incerteza resultante.

Esta incerteza é referente à dificuldade em estabelecer fronteiras e identificar diferenças, claras e concisas, entre zonas com distintos tipos de ocupação de solo e pode ser encarada como a dificuldade que o classificador teve em atribuir uma classe a um *pixel*. Pode ser provocada pela abundante existência de *pixels* mistos, pela possibilidade de existência de diferentes ocupações de solo com assinaturas espectrais próximas e pelo facto de diferentes métodos de classificação associarem classes diferentes a níveis de radiação semelhantes (Ibrahim *et al*, 2005).

Tal como no caso dos classificadores, existem duas teorias clássicas de incerteza - a primeira baseada na noção de possibilidade e a segunda baseada na noção de probabilidade - aplicadas a teorias de conjuntos clássicos. Posteriormente, foi introduzida a noção de incerteza a partir da generalização da teoria de conjuntos clássicos para conjuntos difusos ou *fuzzy*.

As medidas de incerteza foram então desenvolvidas de acordo com a teoria utilizada (probabilidades, possibilidades, *fuzzy*), em que é encontrada uma função de incerteza que atribui valores no intervalo [0,1]. Existem duas medidas clássicas de incerteza: a entropia de Shannon (1948), aplicada à teoria das probabilidades e a medida de Hartley (1928), fundamentada com base na teoria das possibilidades (Klir, 1999). As medidas de incerteza mais utilizadas têm sido as medidas de entropia, de forma a indicar o grau de confiança associada à atribuição das classes ao *pixel* e indicar a fiabilidade da classificação. Um valor elevado de entropia significa que um *pixel* apresenta várias possibilidades para atribuição de classes, sendo o seu valor máximo quando, ao *pixel* em questão, são atribuídas todas as classes com igual valor de probabilidade. Um valor de entropia 0 significa que apenas é atribuída uma classe ao *pixel*, com probabilidade de pertença igual a 1.

A partir da generalização das medidas clássicas de incerteza, com o objetivo de serem aplicadas em conjuntos fuzzy, foram desenvolvidas as medidas de não especificidade (Higashi e Klir, 1982), que quantificam a incerteza resultante da ambiguidade inerente à escolha de um elemento entre um conjunto finito de alternativas possíveis, ou seja quanto maior o numero de alternativas menos especifica é a escolha (Klir 1999; Klir, 2004).

Uma vez que no decorrer da dissertação foi utilizado o *software* Idrisi Taiga, que disponibiliza uma medida de incerteza designada por *Relative Maximum Probability Deviation* (Bo e Wang, 2008), de seguida apenas esta medida será apresentada em maior detalhe, sendo referida no decorrer do trabalho como Ratio de Incerteza (RI). Esta medida varia no intervalo [0,1], sendo que 1 é o maior valor de incerteza, e pode ser aplicada a distribuições de probabilidade e de possibilidade.

Quando é aplicada a distribuições de probabilidade, a medida é apresentada como

$$RI = 1 - \frac{\max_{i=1\dots n}(p_i) - \frac{\sum_{i=1}^n p_i}{n}}{1 - \frac{1}{n}} \quad (4)$$

Onde p_i ($i=1,\dots,n$) traduzem os graus de probabilidade das várias classes associadas a cada *pixel*, sendo neste caso $\sum_{i=1}^n p_i = 1$, e n é o número de classes.

O menor valor p_i é obtido quando $p=(1,0,\dots,0)$ e o valor máximo é alcançado quando $p=(1/n,1/n,\dots,1/n)$.

Quando é aplicada a distribuições de possibilidade, a medida RI é dada por:

$$RI = 1 - \frac{\max_{i=1\dots n}(\pi_i) - \frac{\sum_{i=1}^n \pi_i}{n}}{1 - \frac{1}{n}} \quad (5)$$

Onde π_i ($i=1,\dots,n$) são os graus de possibilidade das várias classes associadas a cada *pixel*, sendo neste caso $\sum_{i=1}^n \pi_i \geq 0$ e n é o número de classes.

O menor valor π_i é obtido quando $\pi=(1,0,\dots,0)$ e o valor máximo é alcançado quando $p=(\alpha, \alpha, \dots, \alpha), \forall \alpha \in [0,1]$.

O segundo termo dos índices apresentados anteriormente, representa a diferença entre o grau máximo de probabilidade/possibilidade de atribuição de uma classe a um *pixel* e o mínimo que o melhor grau de probabilidade/possibilidade pode assumir quando todas as classes têm igual probabilidade/possibilidade de serem atribuídas a um *pixel*.

2.2.2. Avaliação da exatidão

A avaliação da exatidão é um importante componente no processo de construção de classificações automáticas de imagens multiespectrais. Esta avaliação da qualidade da classificação é feita, regra geral, a partir da definição de amostras por classe que, após serem cruzadas com a informação de referência relativa às amostras (verdade do terreno para cada elemento da amostra), permitem calcular matrizes de erro ou confusão. A partir destas matrizes de confusão podem ser deduzidos os Índices de Exatidão Específicos, o Índice de Exatidão do Utilizador (EU), o Índice de Exatidão do Produtor (EP) e os Índices de Exatidão Global (IEG) (Exatidão Global e coeficiente de KHAT) (Congalton and Green, 1999). A tabela 1 é representativa deste tipo de matriz de confusão.

Tabela 1 – Exemplo de uma matriz de confusão

		j = colunas (referencia)				Total n_{i+}
		H_1	H_2	..	H_k	
i=linhas (Classificação)	H_1	n_{11}	n_{12}	..	n_{1k}	n_{1+}
	H_2	n_{21}	n_{22}		n_{2k}	n_{2+}
	:	:	:	:	:	:
	H_k	n_{k1}	n_{k2}	..	n_{kk}	n_{k+}
Total n_{+j}		n_{+1}	n_{+2}	..	n_{+k}	n

Cada elemento n_{ij} da matriz de confusão é o numero de elementos da amostra cuja classe no mapa é i ($i=1,2,...,k$) e cuja classe na realidade (referência) é j ($j=1,2,...,k$). Os elementos da diagonal representam o número de elementos da amostra corretamente classificados, pelo que, os elementos fora da diagonal, são elementos da amostra que foram classificados incorretamente. Estes elementos mal classificados podem ser separados em

erros de omissão, ou seja os elementos de uma determinada classe que não foram classificados como tal, e erros de comissão, isto é, elementos que foram incluídos numa classe quando na realidade pertencem a outra.

A fórmula apresentada em (6), representa o total de elementos da amostra por cada classe i , pelo que através da formula apresentada em (7) são contabilizados a totalidade de pontos da amostra que na realidade (referência) pertencem à classe j .

$$n_{i+} = \sum_{j=1}^k n_{ij} \quad (6)$$

$$n_{+j} = \sum_{i=1}^k n_{ij} \quad (7)$$

A exatidão global de uma classificação (8), é obtida pelo quociente entre a totalidade dos *pixels* corretamente classificados em todas as classes (diagonal da matriz de confusão) e o total de elementos da amostra.

$$\text{Exatidão global} = \frac{\sum_{i=1}^k n_{ii}}{n} \quad (8)$$

A exatidão do utilizador de cada classe, tal como é apresentado em (9), é calculada através do quociente entre o número de *pixels* da classe i , corretamente classificados, e o total de elementos da amostra por cada classe i . Relativamente à exatidão do produtor (10), esta é obtida através do quociente entre o número de *pixels* da classe j que foram corretamente classificados e a totalidade de pontos da amostra que na realidade pertencem à classe de referência j .

$$\text{Exatidão do utilizador (E.U.)} = \frac{n_{ii}}{n_{i+}} \quad (9)$$

$$\text{Exatidão do Produtor (E.P.)} = \frac{n_{jj}}{n_{+j}} \quad (10)$$

Outro índice que também pode ser utilizado como indicador da exatidão da classificação é o Overall Kappa que é calculado através da formula apresentada em (11)

$$\text{Overall Kappa} = \frac{n \sum_{i=1}^k n_{ii} - \sum_{i=1}^k n_{i+} n_{+i}}{n^2 - \sum_{i=1}^k n_{i+} n_{+i}} \quad (11)$$

2.3. Segmentação de imagens

Ao analisar imagens é, muitas vezes, importante destacar ou focar determinada região, o que possibilita uma visualização mais precisa e correta dos elementos que são necessários analisar. Um processo que possibilita a concretização deste objetivo é a segmentação de imagens, consistindo na sua divisão em diferentes regiões, em que os *pixels* da cada uma delas possuem características semelhantes (Soille, 1999).

Existem várias técnicas para segmentar imagens, no entanto a maioria é baseada nas seguintes abordagens:

- ✓ Técnica de limiarização (*Threshold*), onde é definido um limiar ou fronteira e a partir dele, a imagem é transformada numa imagem binária. Por exemplo, numa imagem com níveis de cinzento variando entre 0 e 255, se for definido o limiar 100, todos os *pixels* abaixo de 100 ficarão com o valor 0 e os pixels maiores que 100 receberão o valor 1;
- ✓ Métodos baseados em deteção de bordos, onde são procuradas discontinuidades na imagem a partir da intensidade dos *pixels*. Estas discontinuidades são procuradas a partir de filtros que transformam a imagem *pixel a pixel* e que dependem, não só dos valores de intensidade do *pixel* em questão, mas também dos níveis de intensidade dos seus *pixels* vizinhos;
- ✓ Técnicas de crescimento de regiões, que dividem a imagem em regiões pelo agrupamento de *pixels* vizinhos com níveis de intensidade semelhantes. Um dos principais métodos deste tipo de segmentação é o *WaterShed* (Bacias hidrográfica);
- ✓ Métodos dos contornos ativos que utilizam informações locais sobre o contorno de um objeto. Um objeto é contornado através de uma curva *spline*, que vai sendo alterada iterativamente, expandindo ou encolhendo de acordo com uma função de energia, até se obter a forma do objeto a segmentar;
- ✓

No contexto da segmentação de imagens de incerteza, este é um processo de junção de *pixels* vizinhos de acordo com a semelhança dos seus valores de incerteza. Uma vez que o *software* Idrisi Taiga disponibiliza um método de segmentação por *WaterSheds* (bacias hidrográficas), que é um dos principais métodos de segmentação por crescimento

de regiões, baseando-se no princípio de inundação de relevos topográficos (Russ, 1998), de seguida, apenas este método será analisado mais detalhadamente.

Neste caso, uma imagem derivada da variância é tratada como uma superfície, onde são atribuídos pixels a determinados segmentos de acordo com a semelhança dos seus valores de incerteza, sendo este processo desenvolvido em três etapas:

1. Uma janela, de tamanho variável e definida pelo utilizador, é centrada em cada *pixel*, sendo calculado o valor da variância dentro dessa janela e atribuído esse valor ao *pixel* em questão da imagem derivada;
2. Identifica o equivalente a bacias hidrográficas, usando a imagem da variância. Os *pixels* situados em zonas homogêneas têm valores de variância próximos de 0, pelo que *pixels* em zonas de fronteira apresentam valores de variância mais elevados. Os *pixels* são agrupados em bacias de acordo com estes graus de semelhança;
3. Agrupar as bacias. Segmentos de imagem adjacentes serão agrupados para formar novos segmentos da imagem de acordo com a sua semelhança. Este processo é iterativo, pelo que a cada iteração todos os segmentos da imagem são analisados para identificar o seu vizinho mais semelhante. Um segmento de imagem com o seu vizinho formam uma par de segmentos de imagem candidatos a serem agrupados se por exemplo, para um dado segmento A o seu vizinho mais próximo (semelhante) for B, e se A também for o vizinho mais próximo de B. No entanto, pares candidatos apenas serão agrupados se a diferença entre os dois segmentos for menor que um determinado limite, definido pelo utilizador. Esta diferença é avaliada com base nos seus valores da média e desvio padrão, sendo definidos pelo utilizador os respetivos pesos no processo, de acordo com o critério mais conveniente.

3. Espacialização da exatidão

3.1. Revisão bibliográfica

A classificação automática de imagens multiespectrais é uma importante ferramenta utilizada na detecção remota para obter mapas temáticos de ocupação de solo. Neste sentido, o processo de avaliação da sua qualidade e exatidão assume um papel extremamente importante, sendo, regra geral, feita através da geração de matrizes de confusão que definem valores de exatidão global e índices de exatidão do produtor e do utilizador para a totalidade da imagem classificada. No entanto, esta exatidão da classificação poderá não ser homogênea e variar em diversas zonas da imagem, o que não poderá ser devidamente avaliado com uma abordagem mais clássica.

Neste sentido, e no contexto das classificações não rígidas, Woodcock *et al* (2001) propôs a definição de matrizes de confusão associadas a *pixels* com diferentes níveis de confiança. Gerou matrizes para dois estratos diferentes, um onde o erro é menos provável de ocorrer e outro com maior probabilidade de ocorrência de erros. No entanto não foi feita qualquer referência à espacialização deste nível de confiança.

Foody (2005) abordou o problema de um ângulo diferente, em vez de avaliar a exatidão globalmente para toda a imagem, realizou a avaliação da exatidão localmente. Para tal, através de amostras de pontos nas vizinhanças de pontos de interesse, definiu matrizes de confusão restritas a determinadas regiões, contrariamente à habitual matriz calculada para toda a imagem. Os resultados obtidos demonstraram que, no estudo em questão, a exatidão varia de região para região.

Em Gonçalves *et al* (2009) e Gonçalves *et al* (2010), é abordada a questão da relação entre as medidas de incerteza resultantes de um classificador não rígido, com a exatidão da classificação. Particularmente, é analisado se estas medidas de incerteza podem ser utilizadas como indicadores da dificuldade que o classificador teve em atribuir uma determinada classe a cada *pixel*. Para este estudo, foram definidas matrizes de confusão para toda a imagem e analisados índices de incerteza por classe, que apresentaram claramente

uma correlação positiva com os coeficientes de exatidão. Este facto mostrou que as medidas de incerteza resultantes de uma classificação feita a partir de um classificador não rígido podem ser utilizadas para avaliar o comportamento de um classificador.

Fonte e Gonçalves (2011), apresentou uma segmentação da imagem da incerteza resultante de uma classificação e calculou a média da incerteza em cada região. Este processo mostrou que a segmentação de zonas de diferentes níveis de incerteza permite identificar áreas com diferentes índices de exatidão.

Mais recentemente, em Comber *et al* (2012), com o objetivo de estudar a espacialização da exatidão, foi utilizada uma abordagem baseada num método de regressão geograficamente ponderado, que admite a possibilidade de relações variarem geograficamente e que, estas variações, podem ser estimadas através de coeficientes de regressão. Este processo é materializado através de uma janela que percorre a imagem e estima coeficientes de regressão em cada local, sendo calculados o 1º quartil, a mediana e o 3º quartil dos coeficientes, bem como um coeficiente global e o valor da amplitude interquartil. Estes valores mostram se a realidade do terreno foi bem caracterizada (classificada) pelo classificador e a variação global dos coeficientes de regressão na imagem. Valores elevados indicam maior variação e uma maior aproximação dos resultados a um modelo de regressão linear. No estudo em questão, foi utilizado um modelo de regressão logística geograficamente ponderado para explorar a variação espacial da classificação, ou seja a variação entre a realidade do terreno e a classe que nesse local foi atribuída pelo classificador, verificando-se esta variação de coeficientes em algumas das classes definidas.

3.2. Metodologia

Pretende-se com este trabalho, a partir da abordagem proposta em Fonte e Gonçalves (2001), estudar a espacialização da exatidão da classificação de imagens multiespetrais, com base na incerteza resultante da utilização de classificadores não rígidos. Assim é necessário perceber se esta informação de incerteza pode ser utilizada como um indicador da variação da exatidão da classificação em diferentes zonas da imagem e para cada classe de ocupação de solo definida. Para a definição destas zonas é utilizado um processo de segmentação de imagens que permite obter regiões com características semelhantes. Neste caso, a partir dos resultados obtidos da classificação da imagem utilizando classificadores não rígidos, são obtidas regiões com valores de incerteza

próximos e, a partir destas zonas segmentadas, são definidos diferentes níveis ou intervalos de incerteza onde serão estudadas as diferentes exatidões resultantes.

A exatidão da classificação rígida, obtida a partir da classificação não rígida através da atribuição a cada *pixel* da classe com maior grau de pertença, será feita pela geração de matrizes de confusão e respetivos índices de exatidão global, exatidão do produtor e exatidão do utilizador, para cada classe considerada.

A execução da dissertação foi feita com base na seguinte metodologia, resumida no Fluxograma apresentado na Figura 1:

1. Definir classes de ocupação de solo a usar. Este ponto é fulcral no desenvolvimento do trabalho pois é necessário encontrar uma forma de representação do terreno através de classes de ocupação de solo, que sejam representativas da realidade da superfície em estudo;
2. Criar áreas de treino para cada uma das classes de ocupação de solo definidas anteriormente. Estas zonas de treino devem ser representativas e completas, ou seja, devem conter todos os valores espectrais das classes de ocupação definidas (Lillesand *et al*,2000).
3. Aferir a qualidade das áreas de treino definidas a partir dos gráficos de separabilidade (*Scatter Plots*) das respostas espectrais obtidas entre diferentes bandas. Caso a separabilidade obtida não seja a desejada, ou seja, se diferentes classes tiverem valores de resposta espectral demasiado próximos (esta situação poderá ser observada num *scatter plot* se as elipses de duas classe estiverem sobrepostas) será necessário reformular as áreas de treino e repetir os restantes procedimentos até os resultados serem mais satisfatórios. Se as áreas de treino apresentarem respostas espectrais por classe demasiado próximas, poderá haver dificuldade para o classificador diferenciar as classes e, desse facto, resultarem classificações de pior qualidade;
4. Realizar a classificação não rígida, e obter a respetiva classificação rígida;
5. Definir um conjunto de dados referência que permitam aferir a qualidade da classificação rígida obtida. Estes dados de referência, de forma a serem o mais representativos possível da classificação, devem ser obtidos pela geração de uma amostra estratificada de pelo menos 50 pontos por classe (Congalton and Green, 1999);
6. Calcular a matriz de confusão, e calcular os índices de exatidão global, e exatidão do utilizador e do produtor para cada classe;

7. Realizar a segmentação da imagem da incerteza resultante da classificação não rígida;
8. Dividir a imagem segmentada de acordo com diferentes níveis ou intervalos de incerteza.
9. Definir dados de referência e matrizes de confusão para cada um dos níveis de incerteza definidos anteriormente e obter uma avaliação da exatidão global, da exatidão do utilizador e do produtor para cada classe da classificação, de acordo com a variação da incerteza.

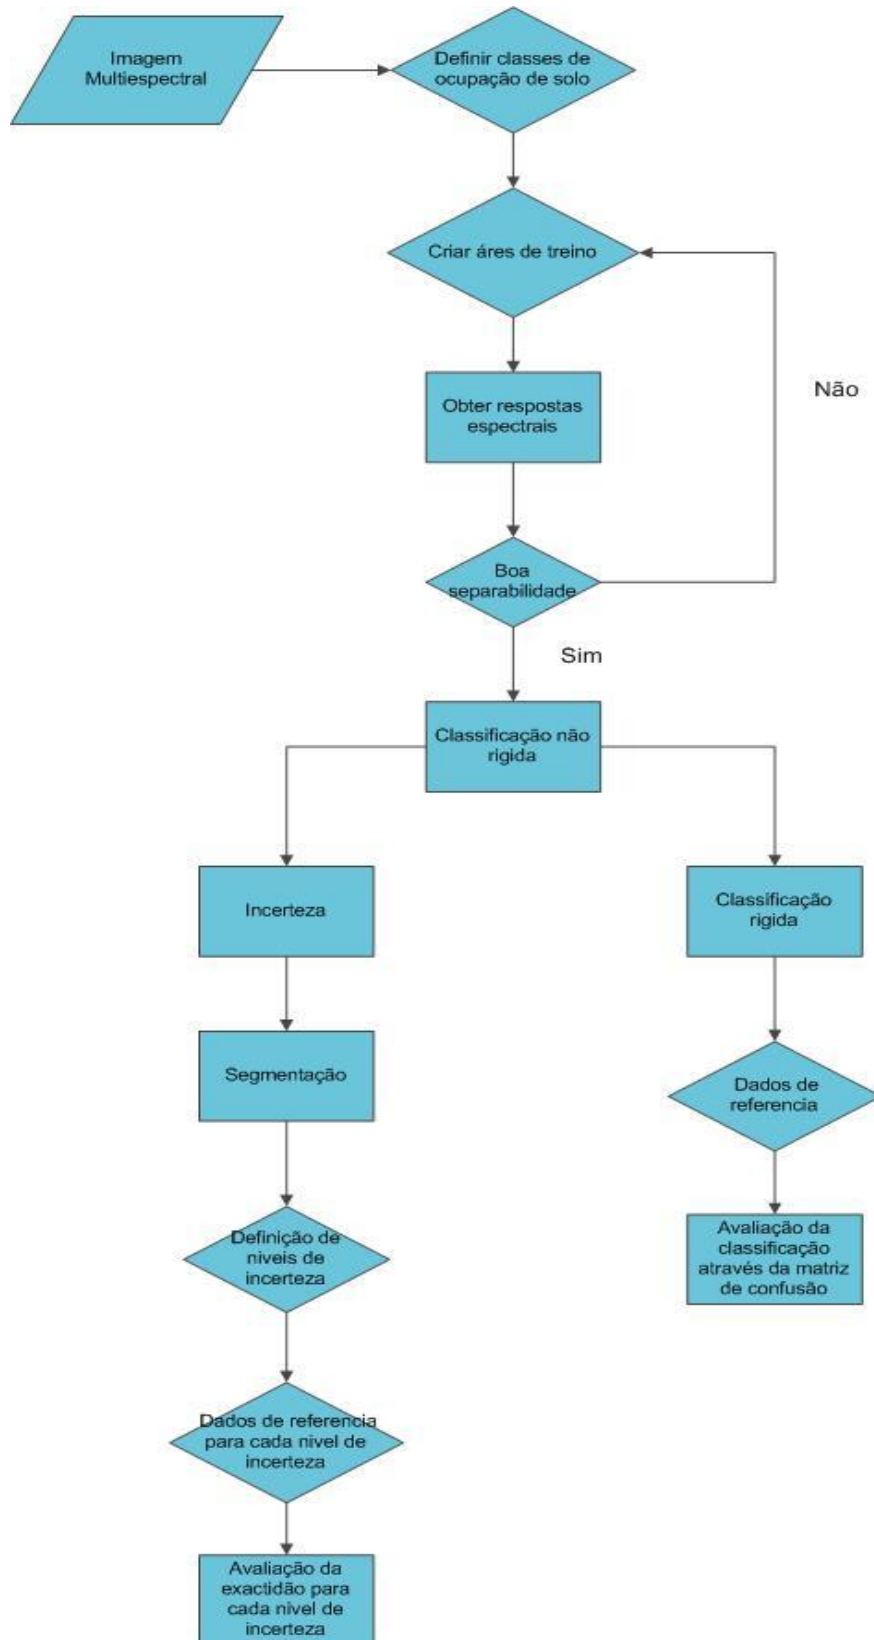


Figura 1 – Fluxograma da metodologia utilizada no decorrer da dissertação

4. Caso de estudo

4.1. Área de estudo

O estudo realizado no decorrer da dissertação teve como base uma região do concelho da Marinha Grande, situado no centro do distrito de Leiria, a 10 Km do mar e a uma altitude de 88 metros. Este concelho, implantado numa extensa planície de chão arenoso, encontra-se na margem esquerda do rio Lis, rodeado por imensas matas de pinheiros, destacando-se o pinhal de Leiria que cobre dois terços da sua superfície e se estende por 18724045 hectares. Assim, a região em questão é marcada por uma forte implementação de zona de florestas, essencialmente pinhal, mas que igualmente apresenta diversas zonas urbanas.

4.2. Dados Imagem

Para a realização do estudo foram utilizadas duas imagens multiespectrais de satélite da região da Marinha Grande, sendo a primeira, uma imagem Ikonos com 4 metros de resolução, e a segunda, uma imagem Spot com 20 metros de resolução. A utilização destas duas imagens permite a comparação de diferentes resultados para a mesma área, sendo que, pelo facto de terem resoluções diferentes, estas apresentam problemas diferentes, como por exemplo a existência mais evidente de *pixels* mistos nas imagens de mais baixa resolução, ou a quantidade de detalhe apresentada nas imagens de muito alta resolução.

A figura 2 representa uma composição em falsa cor (RGB 432) da imagem Ikonos da região em questão, cujas principais características são apresentadas na Tabela 2.




Figura 2 - Composição em falsa cor (RGB 432) da imagem Ikonos da região da Marinha Grande

Tabela 2- Características da imagem Ikonos utilizada no estudo

Banda 1 (azul)	0.45 μ m-0.52 μ m
Banda 2 (verde)	0.52 μ m-0.60 μ m
Banda 3 (Vermelho)	0.60 μ m-0.69 μ m
Banda 4 (infravermelho próximo)	0.76 μ m-0.90 μ m
Resolução Espacial	4m(B1, B2, B3, B4)
Resolução radiométrica	8 bits
Área da imagem	81.793.912,9m ²

A imagem Spot da região da Marinha Grande está representada na Figura 3, e as suas principais características resumidas na Tabela 3.




Figura 3- Composição em Falsa cor (RGB 432) da imagem Spot

Tabela 3 - Característica da imagem Spot utilizada no estudo

Banda 2 (verde)	0.50 μ m-0.59 μ m
Banda 3 (vermelho)	0.61 μ m-0.68 μ m
Banda 4 (infravermelho próximo)	0.78 μ m-0.89 μ m
Banda 5 (infravermelho médio)	1.58 μ m-1.75 μ m
Resolução Espacial	20m (B1,B2,B3,B4)
Resolução radiométrica	8 bits
Área da imagem	81.793.912,9m ²

4.3. Nomenclatura usada

Na implementação da metodologia atrás apresentada, o primeiro passo consiste na definição das classes de ocupação de solo mais representativas da região. Neste sentido, pela observação da realidade presente no terreno e, de acordo com os objetivos delineados para a dissertação, optou-se por fazer uma generalização das nomenclaturas propostas na Corinne Land Cover 2006 e pelo projeto Landeo, sendo decidido não fazer uma distinção entre os vários tipos de tecido urbano, agrupando todas as zonas de floresta numa só classe e fazer a distinção entre vegetação arbustiva e vegetação herbácea, sem haver uma clara referência a zonas agrícolas, pouco identificáveis na imagem. Assim as classes definidas para a realização do trabalho foram as seguintes:

- ✓ Tecido Urbano;
- ✓ Vegetação herbácea;
- ✓ Vegetação arbustiva/Matos;
- ✓ Florestas;
- ✓ Solo nu.

4.4. Classificação

Para realizar o processo de classificação foram definidas zonas de treino através da criação de pequenos polígonos em zonas facilmente identificáveis com determinada ocupação de solo, de forma a conterem toda a variação de valores espectrais de cada classe. Foram escolhidos um total de aproximadamente 100 *pixels* por classe (Lillesand *et al*, 2000). Este processo foi desenvolvido separadamente para as duas imagens, pelo que para as classificações da imagem Ikonos foram definidas umas zonas de treino e para as classificações da imagem Spot foram desenvolvidas outras áreas de treino distintas.

A figura 4 apresenta um exemplo de áreas de treino utilizadas para treino na classificação automática da imagem Ikonos.




Figura 4 - Exemplo de áreas de treino definidas para a imagem Ikonos

Foi analisada a separabilidade espectral das classes a partir das áreas de treino definidas. No caso das zonas definidas para treino das classificações da imagem Ikonos, analisando os diagramas de dispersão resultantes, em particular o diagrama utilizando as bandas do vermelho e Infravermelho próximo (NIR- *Near infrared*), representado na figura 5, é possível verificar que, regra geral, não existe uma sobreposição significativa das diversas classes. No entanto, a sobreposição entre as classes Urbano e Solo Nu é consideravelmente maior, o que poderá significar que o classificador não deverá ter grandes

dificuldades em classificar as diversas ocupações de solo, apesar de ser esperada uma maior dificuldade para distinguir as duas classes referidas.

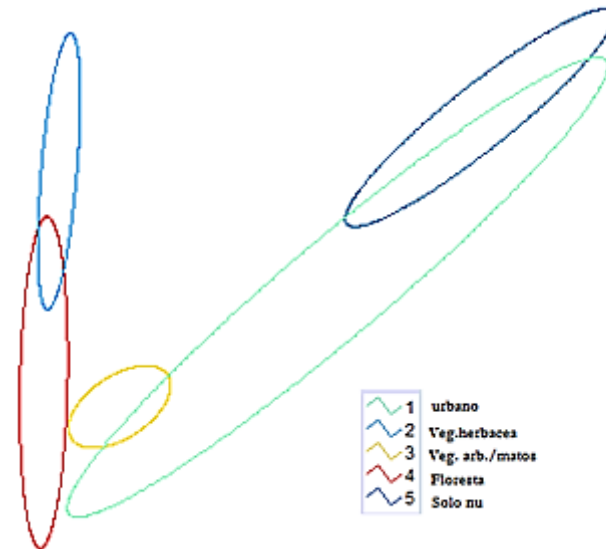


Figura 5 – Diagrama de dispersão da separabilidade das classes da imagem Ikonos (Bandas vermelho e infravermelho próximo)

No caso das zonas de treino definidas para a classificação da imagem Spot, uma primeira análise da separabilidade das classes ditou a necessidade de reformulação dessas zonas. Na Figura 6 apresentam-se dois diagramas de dispersão da versão final das zonas de treino definidas, onde se pode analisar e comparar a separabilidade espectral entre as classes. Neste caso, existe uma maior aproximação nos diferentes valores espectrais, comparativamente aos valores obtidos para as áreas de treino da imagem Ikonos, pelo que as classes apresentam uma separabilidade mais fraca. Assim, analisando o diagrama de dispersão resultante das bandas B2 e B3, podemos observar que a elipse da classe de ocupação Urbano engloba muitos valores espectrais das classes solo nu, arbustos matos, e herbáceas, no entanto no diagrama obtido com as bandas B2 e B4, apenas a classe Vegetação arbustiva/matos está completamente contida na classe Urbano, havendo uma mais clara distinção entre todas as outras classes.

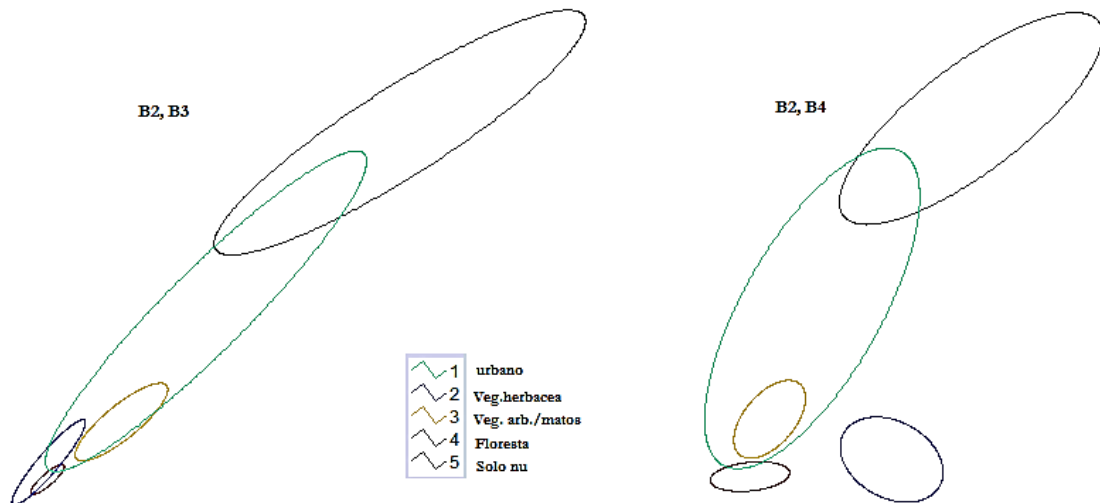


Figura 6- Diagrama de dispersão da separabilidade espectral entre bandas da imagem Spot

As classificações das imagens em estudo foram realizadas utilizando o classificador probabilístico da máxima verossimilhança, e o classificador baseado na teoria de Dempster-Shafer, que será referido no decorrer do trabalho como BelClass. Neste caso, as classificações foram realizadas utilizando os valores de confiança ou crença de pertença de um *pixel* a determinada classe, ou seja os valores de *belief*.

A Figura 7 mostra o resultado da classificação rígida da imagem Ikonos obtida através atribuição a cada *pixel* da classe mais provável, utilizando o classificador da Máxima Verossimilhança, sendo a Figura 8 referente aos resultados obtidos pela classificação utilizando o classificador BelClass.




Figura 7 - Imagem obtida da classificação da imagem Ikonos utilizando o classificador da Máxima Verossimilhança




Figura 8- Classificação da imagem Ikonos utilizando o classificador BelClass

A Figura 9 mostra o resultado da classificação rígida da imagem Spot obtida através atribuição a cada *pixel* da classe mais provável, utilizando o classificador da Máxima Verossimilhança, sendo a Figura 10 referente aos resultados obtidos pela classificação utilizando o classificador BelClass.




Figura 9- Imagem obtida da classificação da imagem Spot utilizando o classificador da Máxima Verossimilhança




Figura 10- Classificação da imagem Spot utilizando o classificador BelClass

4.5. Cálculo da incerteza

A incerteza resultante das classificações não rígidas das imagens foi calculada através da medida disponibilizada pelo *software* Idrisi Taiga, que ao longo do desenvolvimento do trabalho é referida como Ratio de Incerteza (RI).

Os valores de incerteza resultantes das classificações das duas imagens utilizando o classificador da máxima verossimilhança, são consideravelmente **inferiores** aos valores obtidos pela classificação com o classificador baseado na teoria de Dempster-Shafer (BelClass). Por outro lado, é também possível referir que das classificações da imagem Spot resultam índices de incerteza **superiores** comparativamente aos valores obtidos nas classificações da imagem Ikonos, com os dois classificadores. A Tabela 4 mostra uma comparação destes valores de incerteza resultantes das classificações das duas imagens em função do classificador utilizado.

Espacialização da exatidão da classificação automática de imagens multiespectrais usando medidas de incerteza e classificadores não rígidos

Tabela 4- Variação da incerteza em função da imagem e do classificador utilizado

	Mínimo	Máximo	Média	Desvio Padrão
Ikonos (M.V.)	0	0.52	0.07	0.05
Ikonos (BelClass)	0.39	0.98	0.84	0.10
Spot (M.V)	0	0.56	0.16	0.08
Spot (BelClass)	0.11	0.97	0.72	0.17

A Figura 11, mostra a incerteza obtida pela classificação da imagem Ikonos utilizando o classificador da máxima verosimilhança e a figura 12 apresenta a incerteza resultante da classificação da mesma imagem com o classificador BelClass.




Figura 11- Incerteza resultante da classificação da imagem Ikonos utilizando o classificador da Máxima Verosimilhança




Figura 12- Incerteza resultante da classificação da imagem Ikonos utilizando o classificador BelClass

No que diz respeito à incerteza resultante das classificações da imagem Spot, a Figura 13 é referente à incerteza obtida da classificação utilizando o classificador da máxima verosimilhança e a Figura 14 é a incerteza da classificação com o classificador Belclass.




Figura 13- Incerteza resultante da classificação da imagem Spot utilizando o classificador da Máxima Verossimilhança




Figura 14- Incerteza resultante da classificação da imagem Spot utilizando o classificador BelClass

4.6. Segmentação da incerteza

As imagens da incerteza resultante de cada uma das classificações não rígidas das duas imagens, foram segmentadas de forma a serem obtidas zonas com características semelhantes, ou seja, regiões com valores de incerteza próximos, com o objetivo de estudar a variação da exatidão da classificação em zonas com diferentes valores de incerteza. Para este processo foi utilizado um método de segmentação disponibilizado pelo *software* Idrisi Taiga, baseado na segmentação por *WaterSheds* (bacias hidrográficas), onde o utilizador define as dimensões da janela que percorre a imagem, o limite ou valor de semelhança considerado para que *pixels* vizinhos sejam agrupados, bem como o peso da média e da variância nessa decisão. Para ficar apenas com um valor de incerteza para cada zona resultante da segmentação, foi calculada a média da incerteza dos *pixels* contidos nessa zona e, através da intersecção entre as zonas segmentadas e a classificação rígida obtida, foi possível ficar com a informação da classe de ocupação de solo atribuída pelo classificador utilizado.

Após a realização de várias experiências com o objetivo de obter uma segmentação que permitisse identificar visualmente uma imagem da incerteza, foi decidido realizar a segmentação da imagem da incerteza resultante da classificação da imagem Ikonos com o classificador da máxima verosimilhança utilizando uma janela de 3x3, com um limite de semelhança de 100 e com 0.5 de peso tanto para a média como para a variância. A Figura 15 apresenta os resultados obtidos, onde é possível verificar a predominância de zonas com baixa incerteza.




Figura 15- Segmentação da incerteza resultante da classificação da imagem Ikonos, obtida com o classificador da Máxima Verossimilhança

Para segmentar a imagem da incerteza da classificação da imagem Ikonos com o classificador BelClass, tal como no caso anterior, foi utilizada uma janela de 3x3, como um limite de semelhança de 100, e com 0.5 de peso tanto para a média como para a variância, estando na Figura 16 apresentados os resultados obtidos. Neste caso já existem muitas mais zonas de incerteza mais elevada, contrariamente ao verificado na segmentação da incerteza da classificação com o classificador da máxima verossimilhança.




Figura 16 -Segmentação da incerteza da resultante da classificação da imagem Ikonos, obtida com o classificador BelClass

No que diz respeito à segmentação das incertezas obtidas nas classificações da imagem Spot, os resultados são apresentados nas Figuras 17 e 18. Para segmentar as imagens da incerteza das classificações utilizando os dois classificadores, foram utilizadas janelas de 3x3, como um limite de semelhança de 50, com 0.5 de peso tanto para a média como para a variância. Mais uma vez é possível verificar um **maior nível** de incerteza na imagem da segmentação da incerteza resultante da classificação com o classificador BelClass, comparativamente aos resultados da segmentação da incerteza da classificação da máxima verossimilhança.




Figura 17- Segmentação da incerteza da resultante da classificação da imagem Spot, obtida com o classificador da máxima verossimilhança




Figura 18- Segmentação da incerteza da resultante da classificação da imagem Spot, obtida com o classificador BelClass

Uma vez que se pretendia identificar zonas com diferentes valores de incerteza e verificar se a exatidão era semelhante ou se existia uma relação com os valores de incerteza, foram identificadas regiões com valores baixos, médios e elevados de incerteza média. A escolha destas zonas de incerteza foi feita agrupando as zonas segmentadas em intervalos de incerteza, cada um deles com o mesmo número de polígonos. Assim, de acordo com o Histograma da Figura 19, foram calculados três quantis e ficou definido que a imagem resultante da classificação da Máxima Verosimilhança seria agrupada em valores de 0 a 0.05, de 0.05 a 0.09 e valores maiores que 0.09. Por outro lado, a imagem da classificação BelClass seria dividida em valores de 0 a 0.75, de 0.75 a 0.88 e valores maiores que 0.88 (ver Histograma da Figura 20).

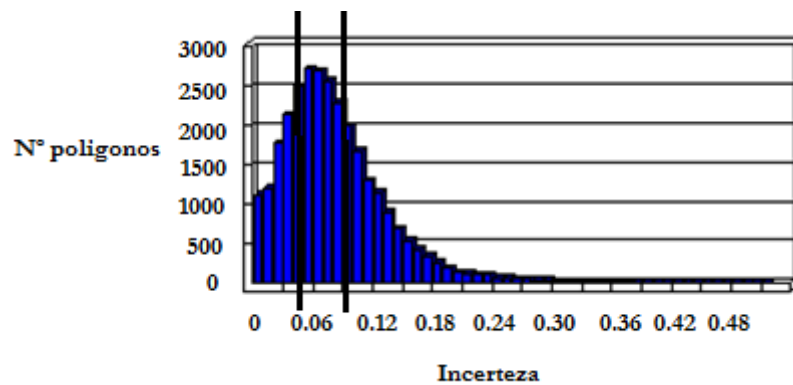


Figura 19- Histograma da distribuição da incerteza obtida na classificação da imagem Ikonos, utilizando o classificador da máxima verosimilhança

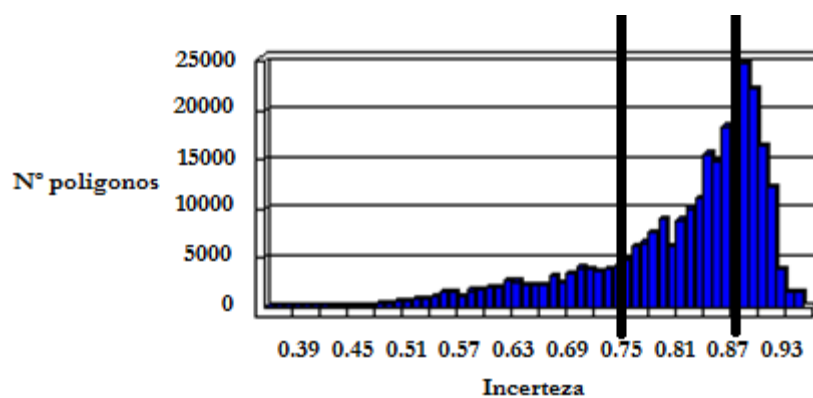


Figura 20 - Histograma da distribuição da incerteza obtida na classificação da imagem Ikonos, utilizando o classificador BelClass

As figuras 21 e 22 mostram a distribuição espacial destes intervalos de incerteza, indicando as regiões da imagem onde a incerteza resultante de cada uma das classificações é baixa, média ou elevada.




Figura 21- Representação dos intervalos de incerteza resultantes da classificação da imagem Ikonos, utilizando o classificador da máxima verosimilhança




Figura 22- Representação dos intervalos de incerteza resultantes da classificação da imagem Ikonos utilizando o classificador BelClass

No caso da incerteza resultante da classificação da imagem Spot, a escolha dos três intervalos ou níveis de variação de incerteza, tal como no caso da imagem Ikonos, foi feita com base na análise dos histogramas das distribuições de incerteza das classificações (ver Figura 23 e Figura 25), de forma a cada classe conter igual número de polígonos.

Assim ficou definido que a imagem resultante da classificação da Máxima Verossimilhança seria dividida em valores de 0 a 0.12, de 0.12 a 0.19 e valores maiores que 0.19, estando a representação destes níveis de incerteza representada na Figura 24.




Figura 23- Histograma da distribuição da incerteza obtida na classificação da imagem Spot, utilizando o classificador da máxima verossimilhança




Figura 24- Representação dos intervalos de incerteza resultantes da classificação da imagem Spot, utilizando o classificador da máxima verosimilhança

A Figura 25 é o histograma da distribuição da incerteza obtida na classificação da imagem Spot com o classificador BelClass, pelo que os níveis de variação de incerteza foram definidos com valores de 0 a 0.82, de 0.82 a 0.87 e valores maiores que 0.87. A Figura 26 é a respetiva representação espacial destas classes de incerteza.




Figura 25- Histograma da distribuição da incerteza obtida na classificação da imagem Spot, utilizando o classificador BelClass

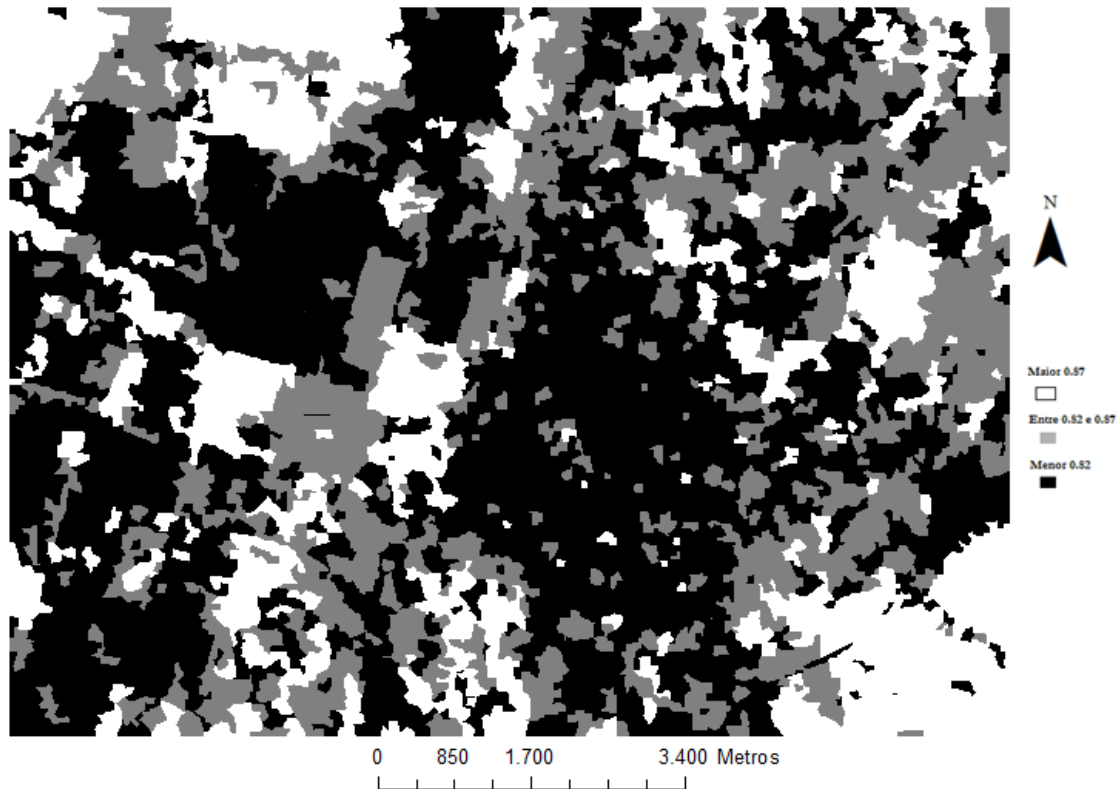


Figura 26- Representação dos intervalos de incerteza resultantes da classificação da imagem Spot, utilizando o classificador da máxima verosimilhança

De forma a poder estudar como é que os valores de exatidão da classificação podem variar de acordo com diferentes formas de definir as classes de incerteza, foram definidos **novos intervalos** de variação de incerteza. Assim, para a classificação da imagem Ikonos utilizando o classificador da Máxima Verosimilhança, foram definidas as classes com valores de incerteza de 0 a 0.10, de 0.10 a 0.15 e valores maiores que 0.15, ou seja foram agregados os anteriores valores de incerteza mais baixos e intermédios, e foi criada uma nova região com valores de incerteza superiores aos anteriores.

No caso da classificação da imagem Ikonos utilizando o classificador BelClass, os **novos níveis** de variação de incerteza ficaram definidas da seguinte forma: valores menores que 0.60, valores entre 0.60 e 0.80 e maiores que 0.80. Assim reduziu-se um pouco o valor de incerteza máxima do nível menor, bem como do valor de incerteza mínimo do nível maior.

Tal como no caso da classificação da Imagem Ikonos, foram também definidas **novas classes** de incerteza resultante da classificação da imagem Spot. Assim, para a classificação com o classificador da Máxima Verosimilhança, foram definidos os intervalos de 0 a 0.10, de 0.10 a 0.20 e valores maiores que 0.20, ou seja foi criada uma zona de incerteza ligeiramente mais baixa e uma nova região com valores de incerteza superiores aos anteriores.

No caso dos resultados obtidos na classificação da imagem Spot, utilizando o classificador BelClass, os **novos intervalos** de variação da incerteza ficaram definidos por valores menores que 0.65, valores entre 0.65 e 0.85 e maiores que 0.85. Assim foi reduzido o valor de incerteza máxima do nível menor, bem como do valor de incerteza mínimo do nível maior

4.7. Avaliação da exatidão

No decorrer do trabalho foram analisadas as exatidões das diferentes classificações rígidas, obtidas a partir das classificações não rígidas, da imagem Ikonos e da imagem Spot. Assim foi avaliada a totalidade da exatidão da classificação das duas imagens utilizando cada um dos classificadores (antes das sua divisão em intervalos de incerteza) e foi igualmente avaliada a exatidão da classificação das imagens com os dois classificadores em cada um dos intervalos de incerteza definidos.

A avaliação da exatidão foi realizada através de matrizes de confusão que permitem calcular índices de exatidão global (E.G.), coeficientes Kappa (overall Kappa) e exatidões do utilizador (E.U.) e do produtor (E.P.) para cada classe de ocupação de solo.

Foram lançadas amostras estratificadas por classe da imagem classificada e foram definidos dados de referência. Estes dados de referência foram obtidos por interpretação visual, sobrepondo os elementos da amostra à imagem da zona em questão e a uma imagem de muito alta resolução disponibilizada pelo *software* ArcGis. Desta forma foi possível decidir se cada elemento da amostra foi corretamente classificado, de acordo com a realidade da superfície do terreno.

No caso da avaliação da totalidade da exatidão das classificações das duas imagens (antes da divisão da em classes de incerteza), a dimensão das amostras foi de 100 pontos por classe, num total de 500 pontos (Congalton and Green, 1999). Para os intervalos de incerteza definidos para cada uma das classificações das imagens, a dimensão de cada

amostra foi de 50 pontos por classe, ou seja 250 pontos no total (Congalton and Green, 1999), exceto no caso dos últimos níveis de incerteza definidos para os resultados obtidos na classificação da imagem Ikonos com o classificador da máxima verossimilhança. Neste caso, devido à presença de poucas zonas no intervalo de incerteza maior que 0.15, optou-se por uma amostra de 20 pontos por classe para os três níveis de incerteza, pois se a amostra fosse de 50 pontos, muitos deles estariam demasiado concentrados na mesma área. Pela mesma razão foi também definida uma amostra de 25 pontos por classe para o intervalo de incerteza menor que 0.65, resultante da classificação da imagem Spot com o classificador BelClass.

De forma a estudar se a exatidão da classificação das imagens varia em função da amostra utilizada, foram definidas novas amostras estratificadas a partir da junção das amostras anteriormente definidas para os primeiros três intervalos de incerteza, resultantes da classificação das duas imagens com cada um dos classificadores. Assim, cada uma destas amostras tem dimensão de 150 pontos por classe, ou seja 50 pontos por cada uma das cinco classes em três níveis de incerteza, num total de 750 pontos.

Todas as matrizes de confusão calculadas no decorrer do trabalho são apresentadas como anexos.

As tabelas 5, 6 e 7 são referentes às exatidões globais, exatidões do utilizador e exatidões do produtor, respetivamente, para cada classe, dos resultados obtidos na classificação da imagem Ikonos, utilizando o classificador da máxima verossimilhança

Tabela 5-Exatidão global (%) dos diferentes intervalos de incerteza resultantes da classificação da imagem Ikonos, utilizando o classificador da máxima verossimilhança

	Amostra	Amostra	Inc.	Inc.	Inc.	Inc.	Inc.	Inc.
	500	750	0-0.05	0.05-0.09	>0.09	0-0.10	0.10-0.15	>0.15
Exat.Global	78	66	78	65	54	85	61	53

Espacialização da exatidão da classificação automática de imagens multiespectrais usando medidas de incerteza e classificadores não rígidos

Tabela 6- Exatidão do utilizador (%) para os diferentes intervalos de incerteza resultantes da classificação da imagem Ikonos, utilizando o classificador da máxima verosimilhança

	Amostra 500	Amostra 750	Inc 0-0.05	Inc 0.05-0.09	Inc >0.09	Inc 0-0.10	Inc 0.10-0.15	Inc >0.15
Urbano	81	59	76	58	42	80	45	55
Veg.Herb	72	64	74	68	50	95	65	50
Veg Arb	77	69	78	68	60	90	70	80
Floresta	86	78	92	74	68	90	70	20
Solo nu	74	59	68	56	52	70	65	60

Tabela 7- Exatidão do produtor (%) para os diferentes intervalos de incerteza resultantes da classificação da imagem Ikonos, utilizando o classificador da máxima verosimilhança

	Amostra 500	Amostra 750	Inc. 0-0.05	Inc. 0.05-0.09	Inc. >0.09	Inc. 0-0.10	Inc. 0.10-0.15	Inc. >0.15
Urbano	79	67	69	71	57	73	64	69
Veg.Herb	90	92	95	87	96	90	87	77
Veg Arb	76	50	63	47	41	82	50	39
Floresta	69	65	87	66	47	90	54	24
Solo nu	81	71	83	68	63	93	65	92

As tabelas 8, 9 e 10 traduzem os resultados obtidos na classificação da imagem Ikonos, utilizando o classificador BelClass.

Tabela 8- Exatidão global (%) dos diferentes intervalos de incerteza resultantes da classificação da imagem Ikonos, utilizando o classificador BelClass

	Amostra 500	Amostra 750	Inc. 0-0.75	Inc. 0.75-0.88	Inc. >0.88	Inc. 0-0.60	Inc. 0.60-0.80	Inc. >0.80
Exat.Global	72	60	69	61	53	72	68	60

Tabela 9- Exatidão do utilizador (%) para os diferentes intervalos de incerteza resultantes da classificação da imagem Ikonos, utilizando o classificador BelClass

	Amostra 500	Amostra 750	Inc 0-0.75	Inc 0.75-0.88	Inc >0.88	Inc 0-0.60	Inc 0.60-0.80	Inc >0.80
Urbano	64	68	76	72	58	72	68	66
Veg.Herb	69	53	52	56	56	58	54	56
Veg Arb	72	51	50	48	56	56	58	60
Floresta	87	68	90	70	44	94	86	58
Solo nu	69	62	76	60	50	82	72	62

Tabela 10- Exatidão do produtor (%) para os diferentes intervalos de incerteza resultantes da classificação da imagem Ikonos, utilizando o classificador BelClass

	Amostra 500	Amostra 750	Inc. 0-0.75	Inc. 0.75-0.88	Inc. >0.88	Inc. 0-0.60	Inc. 0.60-0.80	Inc. >0.80
Urbano	75	68	81	61	66	86	69	66
Veg.Herb	91	79	100	85	67	97	96	78
Veg Arb	61	47	81	49	33	78	64	41
Floresta	67	49	47	50	54	49	51	57
Solo nu	76	73	76	77	64	87	82	79

Relativamente às exatidões obtidas na classificação da imagem Spot, as tabelas 11, 12 e 13 são referentes às exatidões globais, exatidões do utilizador e exatidões do produtor, para cada classe, utilizando o classificador da máxima verosimilhança.

Tabela 11- Exatidão global (%) dos diferentes intervalos de incerteza resultantes da classificação da imagem Spot utilizando o classificador da máxima verosimilhança

	Amostra 500	Amostra 750	Inc. 0-0.12	Inc. 0.12-0.19	Inc. >0.19	Inc. 0-0.10	Inc. 0.10-0.20	Inc. >0.20
Exat.Global	67	59	68	59	49	77	61	50

Tabela 12- Exatidão do utilizador (%) para os diferentes intervalos de incerteza resultantes da classificação da imagem Spot utilizando o classificador da máxima verosimilhança

	Amostra 500	Amostra 750	Inc 0-0.12	Inc 0.12-0.19	Inc >0.19	Inc 0-0.10	Inc 0.10-0.20	Inc >0.20
Urbano	74	67	74	70	58	80	76	60
Veg.Herb	51	34	42	38	22	44	36	16
Veg Arb	65	64	68	62	62	67	64	62
Floresta	89	76	92	82	58	94	86	74
Solo nu	54	51	66	44	44	76	44	38

Espacialização da exatidão da classificação automática de imagens multiespectrais usando medidas de incerteza e classificadores não rígidos

Tabela 13- Exatidão do produtor (%) para os diferentes intervalos de incerteza resultantes da classificação da imagem Spot utilizando o classificador da máxima verosimilhança

	Amostra 500	Amostra 750	Inc. 0-0.12	Inc. 0.12-0.19	Inc. >0.19	Inc. 0-0.10	Inc. 0.10-0.20	Inc. >0.20
Urbano	69	66	82	61	63	85	66	59
Veg.Herb	77	91	100	19	69	95	90	73
Veg Arb	60	43	53	71	36	59	48	40
Floresta	59	53	58	72	44	56	57	46
Solo nu	81	75	83	27	63	85	76	63

Finalmente, as tabelas 14, 15 e 16 são referentes às exatidões globais, e exatidões do utilizador e do produtor, para cada classe, dos resultados obtidos na classificação da imagem Spot utilizando o classificador BelClass.

Tabela 14- Exatidão global (%) dos diferentes intervalos de incerteza resultantes da classificação da imagem Spot utilizando o classificador BelClass

	Amostra 500	Amostra 750	Inc. 0-0.82	Inc. 0.82-0.87	Inc. >0.87	Inc. 0-0.65	Inc. 0.65-0.85	Inc. >0.85
Exat.Global	62	51	61	51	40	71	39	42

Tabela 15- Exatidão do utilizador (%) para os diferentes intervalos de incerteza resultantes da classificação da imagem Spot utilizando o classificador BelClass

	Amostra 500	Amostra 750	Inc 0-0.82	Inc 0.82-0.87	Inc >0.87	Inc 0-0.65	Inc 0.65-0.85	Inc >0.85
Urbano	50	42	68	44	14	64	58	20
Veg.Herb	43	32	34	38	24	52	42	18
Veg Arb	67	57	62	58	52	80	68	58
Floresta	91	79	86	80	70	92	90	76
Solo nu	59	45	56	36	42	68	48	40

Tabela 16- Exatidão do produtor (%) para os diferentes intervalos de incerteza resultantes da classificação da imagem Spot utilizando o classificador BelClass

	Amostra 500	Amostra 750	Inc 0-0.82	Inc 0.82-0.87	Inc >0.87	Inc 0-0.65	Inc 0.65-0.85	Inc >0.85
Urbano	64	64	69	65	43	70	64	43
Veg.Herb	98	79	85	73	80	81	81	75
Veg Arb	60	39	50	38	31	71	49	44
Floresta	46	41	49	45	32	62	58	31
Solo nu	88	82	88	75	81	81	78	74

4.8. Análise de resultados

Neste ponto irão ser analisados os resultados obtidos nos procedimentos aplicados às duas imagens em estudo. Assim as principais questões a ser avaliadas serão as seguintes:

- ✓ Variação da incerteza e da exatidão em função do classificador utilizado;
- ✓ Avaliar a correlação entre valores elevados de incerteza e valores baixos de exatidão;
- ✓ Valores da exatidão global, do produtor e do utilizador para toda a imagem, bem como para as zonas segmentadas com diferentes níveis de incerteza;
- ✓ Relação entre o tipo de ocupação de solo e níveis de incerteza.

4.8.1. Comparação dos índices de exatidão global resultantes da classificação da imagem Ikonos

A tabela 17 apresenta os valores de exatidão global das classificações da imagem Ikonos, utilizando o classificador da máxima verosimilhança e o classificador BelClass. É possível verificar que o índice de exatidão Global da classificação da totalidade da imagem Ikonos obtida utilizando o classificador da Máxima Verosimilhança apresenta valores **superiores** aos obtidos pelo classificador BelClass e, por outro lado, verifica-se uma **diminuição da exatidão** das classificações da imagem Ikonos à medida que a **incerteza aumenta**.

No caso da classificação da máxima Verosimilhança, para os intervalos de incerteza definidos inicialmente (0-0.05; 0.05-0.09; >0.09), quando a **incerteza é mais baixa, a**

exatidão é máxima (E.G. 78%) e próxima da exatidão verificada para toda a imagem antes da sua divisão em função da incerteza (amostra estratificada de 100 pontos por classe, 500 pontos no total). A partir daqui, observa-se um **decréscimo** contínuo da exatidão com o aumento da incerteza, sendo de referir que a exatidão obtida no nível de incerteza entre 0.05 e 0.09 (E.G. 65%) é bastante semelhante à exatidão de toda a imagem, resultante da amostra obtida pela junção das amostras dos três níveis de incerteza (amostra 750 pontos).

Relativamente à classificação da imagem Ikonos utilizando o classificador BelClass, os resultados obtidos são similares, ou seja, para as classes de incerteza definidas inicialmente (0-0.75; 0.75-0.88; >0.88) a exatidão também **diminui em função do aumento da incerteza**. Quando a incerteza é mais baixa, a exatidão verificada é próxima da obtida para toda a imagem antes da divisão em diferentes níveis de incerteza e, mais uma vez, a exatidão da amostra conjunta dos três níveis de incerteza (amostra 750 pontos) é bastante semelhante à exatidão obtida no nível de incerteza intermédio.

A diferença dos valores de exatidão das classificações, obtidos a partir das amostras de 500 pontos, comparativamente aos valores obtidos a partir das amostras de 750 pontos, pode ser justificada pelo facto de, nesta amostra, estarem presentes 250 pontos de cada nível de incerteza, com diferentes exatidões. A diminuição da exatidão que se verifica nos níveis de incerteza mais baixos, justifica a presença de bastantes pontos mal classificados nestes níveis de incerteza, influenciando o valor da exatidão global da classificação. Este facto não ocorre de uma forma tão significativa nas amostras estratificadas com 500 pontos no total, uma vez que estes pontos foram distribuídos aleatoriamente por toda a imagem classificada.

Para cada um dos níveis de incerteza resultantes da classificação da imagem Ikonos com o classificador da Máxima Verosimilhança definidos posteriormente (0-0.10; 0.10-0.15; >0.15), mais uma vez se observa a **diminuição da exatidão** em função do **aumento da incerteza**. No intervalo de 0 a 0.10, a exatidão é de 85%, ou seja apresenta uma exatidão mais elevada comparativamente ao nível de 0 a 0.05, o que se poderá explicar pelo facto de ser uma zona bastante grande e a avaliação da exatidão ter sido feita com uma amostra de apenas 20 pontos.

Será também de referir, que nos outros intervalos com maiores valores de incerteza comparativamente aos definidos inicialmente, a exatidão baixou. No intervalo de incerteza de 0.05 a 0.09 a exatidão é de 65%, enquanto no nível intermédio de 0.10 a 0.15 a exatidão

é de 61%. Nos níveis de maior incerteza é também possível observar este facto, exatidão de 54% para incerteza maior que 0.09, e de 41% para incerteza maior que 0.15.

Relativamente aos valores observados na classificação da imagem Ikonos utilizando o classificador BelClass, verifica-se algo semelhante. Com incerteza entre 0.75 e 0.88 a exatidão é de 61% e com incerteza entre 0.60 e 0.80 a exatidão é de 68%. Nos intervalos de maior incerteza, valores maiores que 0.88 apresentam exatidão de 53%, enquanto valores maiores que 0.80 têm uma exatidão de 60%.

Tabela 17- Exatidão Global dos vários níveis de incerteza das classificações da imagem Ikonos, utilizando o classificador da Máxima Verosimilhança e o classificador BelClass

Máxima Verosimilhança	Exatidão Global (%)	(BelClass)	Exatidão Global(%)
Amostra 500	78	Amostra 500	72
Amostra 750	66	Amostra 750	60
0-0.05	78	0-0.75	69
0.05-0.09	65	0.75-0.88	61
>0.09	54	>0.88	53
0-0.10	85	0-0.60	72
0.10-0.15	61	0.60-0.80	68
>0.15	41	>0.80	60

4.8.2. Comparação dos índices de exatidão global resultantes da classificação da imagem Spot

Na tabela 18 são apresentados os valores de exatidão Global resultantes das classificações da imagem Spot utilizando cada um dos classificadores. Assim, verifica-se que, tal como foi observado nas classificações da imagem Ikonos, o índice de exatidão Global da classificação obtida utilizando o classificador da Máxima Verosimilhança é **superior** ao obtido pelo classificador BelClass, e observa-se uma **diminuição da exatidão** das classificações da imagem Spot em função do **aumento da incerteza**.

No caso dos níveis de incerteza resultantes da classificação da imagem Spot com o classificador da máxima Verosimilhança definidos inicialmente (0-0.12; 0.12-0.19; >0.19),

no nível de **incerteza menor**, verifica-se a **exatidão máxima** (68%), valor muito próximo da exatidão obtida para a classificação de toda a imagem Spot, antes da sua divisão em função da incerteza (amostra estratificada de 100 pontos por classe). Para os níveis de incerteza maiores, existe um **decréscimo da exatidão** com o **aumento da incerteza** e é possível salientar que a exatidão obtida no nível de incerteza intermédio (0.12-0.19) é igual à exatidão de toda a imagem, resultante da amostra obtida pela agregação das amostras dos três níveis de incerteza (amostra 750 pontos).

No que diz respeito à classificação utilizando o classificador BelClass, os resultados obtidos são bastante semelhantes, ou seja a exatidão também **diminui** em função do **aumento da incerteza**. Para os intervalos de incerteza definidos inicialmente (0-0.82; 0.82-0.87; >0.87), quando a incerteza é menor, a exatidão verificada é próxima da exatidão resultante da classificação de toda a imagem Spot antes da divisão em diferentes níveis de incerteza (61% e 62% respetivamente) e, tal com se verificou nos casos anteriores, a exatidão da amostra conjunta dos três níveis de incerteza (amostra 750 pontos) é igual à exatidão obtida no nível de incerteza intermédio.

Para os níveis de incerteza resultantes da classificação da imagem Spot com o classificador da máxima verosimilhança definidos posteriormente (0-0.10; 0.10-0.20; >0.20), é possível verificar que em intervalos com maiores valores de incerteza, comparativamente aos anteriormente definidos, a exatidão é menor (38% para incerteza > 0.20 e 49 para incerteza > 0.19).

No caso da classificação utilizando o classificador BelClass, para as classe de incerteza definidas posteriormente (0-0.65; 0.65-0.85; >0.85), verifica-se que na zona de incerteza de 0 a 0.65, a exatidão obtida é maior comparativamente ao intervalo anteriormente definido como menor, ou seja de 0 a 0.82 (64% contra 61%). No entanto, ao contrário do que seria expectável, no novo nível de incerteza maior, a exatidão decresce quando comparada com a exatidão obtida para o intervalo de incerteza maior definido anteriormente (28% para incerteza > 0.85 contra 40% para incerteza > 0.87).

Tabela 18- Exatidão Global dos vários níveis de incerteza das classificações da imagem Spot, utilizando o classificador da Máxima Verosimilhança e o classificador BelClass

Máxima Verosimilhança	Exatidão Global	(BelClass)	Exatidão Global
Amostra 500	67	Amostra 500	62
Amostra 750	59	Amostra 750	51
0-0.12	68	0-0.82	61
0.12-0.19	59	0.82-0.87	51
>0.19	49	>0.87	40
0-0.10	63	0-0.65	64
0.10-0.20	51	0.65-0.85	51
>0.20	38	>0.85	28

4.8.3. Exatidões do utilizador e do produtor, resultantes das classificações da imagem Ikonos, utilizando o classificador da máxima verosimilhança

É também importante analisar a exatidão do utilizador e do produtor, por classe, para cada um dos níveis de incerteza definidos na classificação da imagem Ikonos, utilizando os dois classificadores. Neste sentido, a Figura 27 mostra a exatidão do utilizador, resultante da totalidade da classificação da imagem Ikonos utilizando o classificador da máxima verosimilhança e para os três níveis de incerteza da classificação definidos inicialmente (0-0.05; 0.05-0.09;> 0.09).

Pela análise do gráfico, é possível verificar que as exatidões do utilizador de todas as classes, resultantes da classificação da imagem Ikonos, utilizando o classificador da máxima Verosimilhança **diminuem à medida que a incerteza aumenta.**

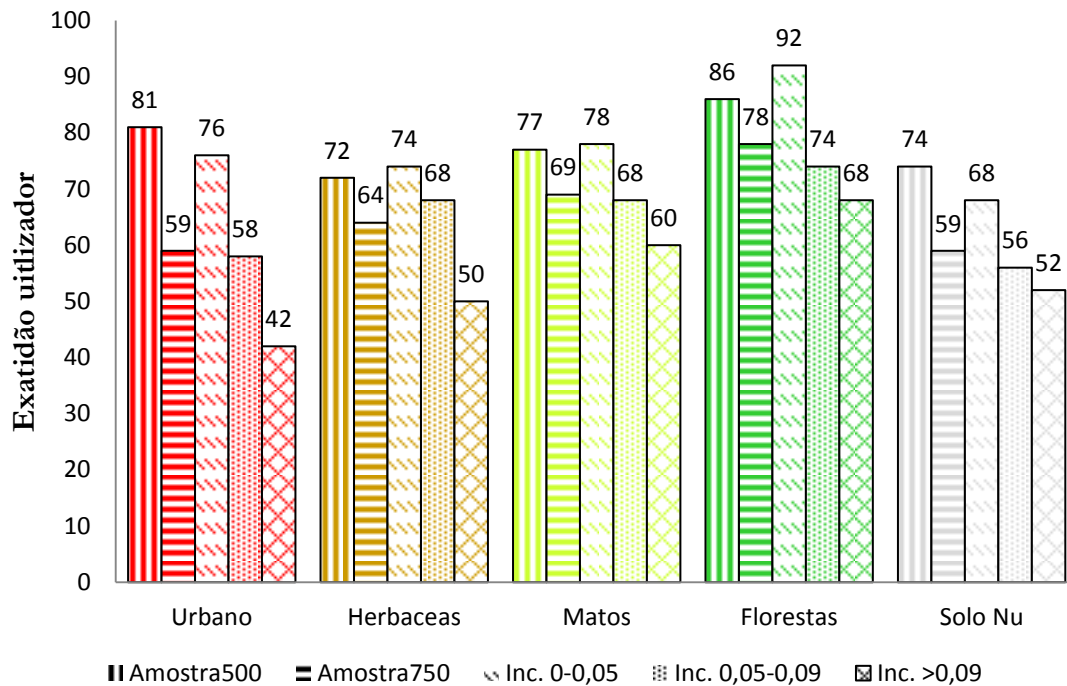


Figura 27- Exatidões do utilizador obtidas na totalidade da classificação e em cada intervalo de incerteza resultante da classificação da imagem Ikonos, utilizando o classificador da máxima verosimilhança

A figura 28 apresenta as exatidões do produtor, resultantes das diferentes classificações da imagem Ikonos com o classificador da máxima verosimilhança. Relativamente às classes Matos, Florestas e Solo Nu, a exatidão do produtor também diminui em função do aumento da incerteza; no entanto, o mesmo não se verifica para a classe urbano e vegetação herbácea. Este facto, poderá ser justificado pela presença reduzida da classe urbana no nível de incerteza entre 0.05 e 0.09 e, igualmente, pela existência de poucas zonas de vegetação herbácea nos intervalos de incerteza de 0.05 a 0.09 e > 0.09 resultantes da classificação da máxima verosimilhança (ver Figura 29).

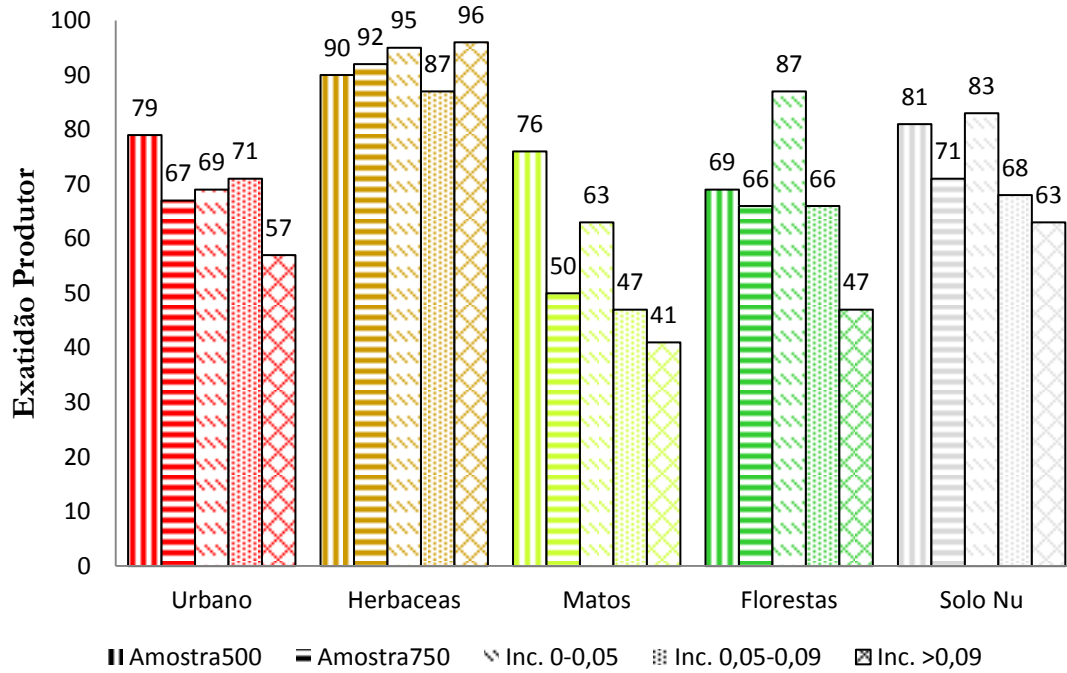


Figura 28- Exatidões do produtor obtidas na totalidade da classificação e em cada intervalo de incerteza resultante da classificação da imagem Ikonos, utilizando o classificador da máxima verossimilhança

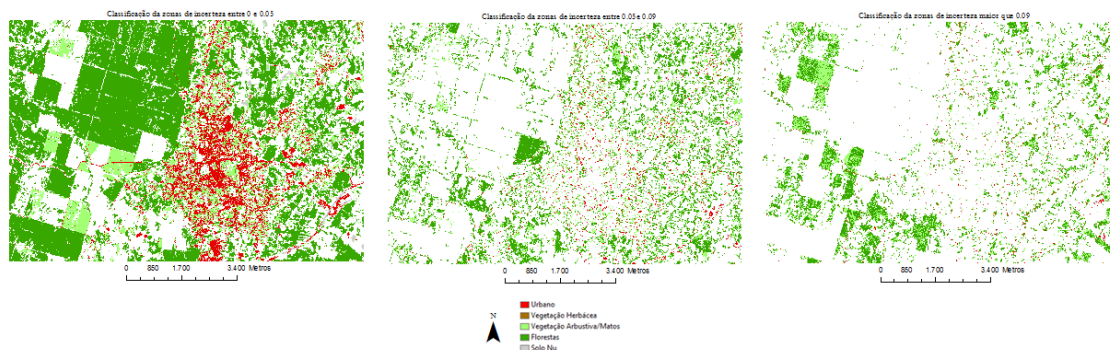


Figura 29- Classificação dos níveis de incerteza de 0 a 0.05 e de 0.05 a 0.09 e maior que 0.09 da imagem Ikonos, utilizando o classificador da máxima verossimilhança

4.8.4. Exatidões do utilizador e do produtor, resultantes das classificações da imagem Ikonos, utilizando o classificador BelClass

No que diz respeito à classificação da imagem Ikonos, obtida com o classificador BelClass, para os três níveis de incerteza definidos inicialmente (0-0.75; 0.75-0.88;> 0.88), a Figura 30 mostra que, no caso das exatidões do utilizador, não existe uma diminuição da exatidão para todas as classes.

A Figura 30 que contém os valores da exatidão do utilizador para toda a classificação, bem como para os diferentes intervalos de incerteza, mostra que, no caso da vegetação herbácea, a exatidão resultante da incerteza entre 0.75 e 0.88 é igual à exatidão resultante da incerteza maior que 0.88, apesar de em ambos os níveis ser pouco evidente a presença deste tipo de coberto de solo (ver Figura 31). Para a mesma classe importa também referir que a exatidão resultante da incerteza entre 0 e 0.75 é menor que a incerteza obtida para toda a classificação (amostra 500 pontos), no entanto já é bastante próxima da exatidão obtida para toda a classificação feita a partir da junção das amostras dos três níveis de incerteza (amostra 750 pontos), o que mais uma vez mostra a importância da amostra considerada e a influência, no valor da exatidão obtida, da existência de pontos pertencentes a intervalos de incerteza maiores, na amostra.

Este facto também ocorre quando se analisam as exatidões da vegetação arbustiva/matos, sendo também de salientar que a exatidão do utilizador resultante da incerteza maior que 0.88 é superior à exatidão da incerteza entre 0.75 e 0.88, no entanto, neste caso existe uma clara presença desta classe no nível mais elevado da incerteza (ver Figura 31), o que indica que, apesar do classificador ter dificuldades em classificar zonas com este tipo de ocupação de solo, elas foram razoavelmente bem classificadas.




Figura 30- Exatidões do utilizador obtidas na totalidade da classificação e em cada intervalo de incerteza resultante da classificação da imagem Ikonos, utilizando o classificador Belclass

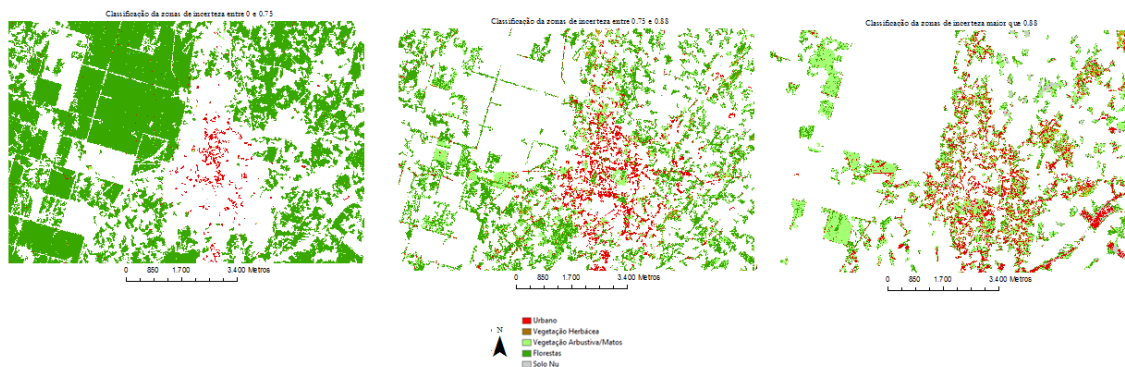


Figura 31- Classificação dos níveis de incerteza de 0 a 0.75 e de 0.75 a 0.88 e maior que 0.88 da imagem Ikonos, utilizando o classificador BelClass

Analisando a Figura 32, que contem os valores das exatidões do produtor resultantes da classificação da imagem Ikonos, utilizando o classificador BelClass, observa-se que a exatidão da classe urbano resultante do intervalo de incerteza maior que 0.88, é superior à exatidão resultante para o nível de incerteza entre 0.75 e 0.88, acontecendo algo semelhante para o nível entre 0 e 0.75 e para o nível entre 0.75 e 0.88 da classe solo nu.

No entanto, é no caso das exatidões da classe floresta que acontece algo mais inesperado. Em primeiro lugar, é possível verificar que a exatidão de toda a classificação, feita a partir da amostra de 500 pontos, é superior à exatidão do nível de incerteza entre 0 e 0.75 e, apesar de esta já ser mais próxima da exatidão resultante da amostra de 750 pontos, apenas 47% do que na realidade é floresta, foi classificado como tal, sendo bastantes zonas classificadas como vegetação herbácea e como vegetação arbustiva/matos (Tabela 32, Anexo B). Por outro lado, também é possível observar que a exatidão do produtor da classe floresta cresce com o aumento da incerteza, apesar da quase totalidade das zonas desta classe estarem no nível de incerteza de 0 a 0.75 e quase não se registar a sua presença nos outros intervalos de incerteza (ver Figura 31). Este facto indica que o classificador BelClass não teve dificuldades em classificar a floresta, apesar de existirem bastantes zonas neste intervalo de incerteza (0-0.75) que na realidade são floresta mas foram atribuídas a outras classes de ocupação de solo.




Figura 32- Exatidões do produtor obtidas na totalidade da classificação e em cada intervalo de incerteza resultante da classificação da imagem Ikonos, utilizando o classificador Belclass

4.8.5. Exatidões do utilizador e do produtor, resultantes das classificações da imagem Spot, utilizando o classificador da máxima verosimilhança

Tal como foi feito para a imagem Ikonos, é também necessário aferir a exatidão do utilizador e do produtor para cada um dos níveis de incerteza resultantes da classificação da imagem Spot. Assim, a Figura 33 representa a exatidão do utilizador da totalidade e dos intervalos de incerteza, inicialmente definidos (0-0.12; 0.12-0.19;> 0.19), resultantes da classificação da imagem Spot com o classificador da máxima verosimilhança.

No que diz respeito à exatidão do utilizador para cada classe, em função da variação da incerteza, a Figura 33 mostra um decréscimo da exatidão com o aumento da incerteza nas classes urbano, vegetação herbácea e floresta, sendo que nesta última classe existe uma **quebra bastante acentuada** na passagem do intervalo de incerteza entre 0.12 e 0.19 para nível de incerteza maior que 0.19 (de 82% para 58%). Este facto poderá ser justificado pela escassa presença de zonas de floresta neste último nível de incerteza, estando quase todas as regiões de floresta contidas no nível de incerteza entre 0 e 0.12 (ver Figura 34).

Por outro lado, é também possível referir que, nas classes vegetação arbustiva e solo nu, a exatidão dos dois maiores níveis de incerteza é igual.

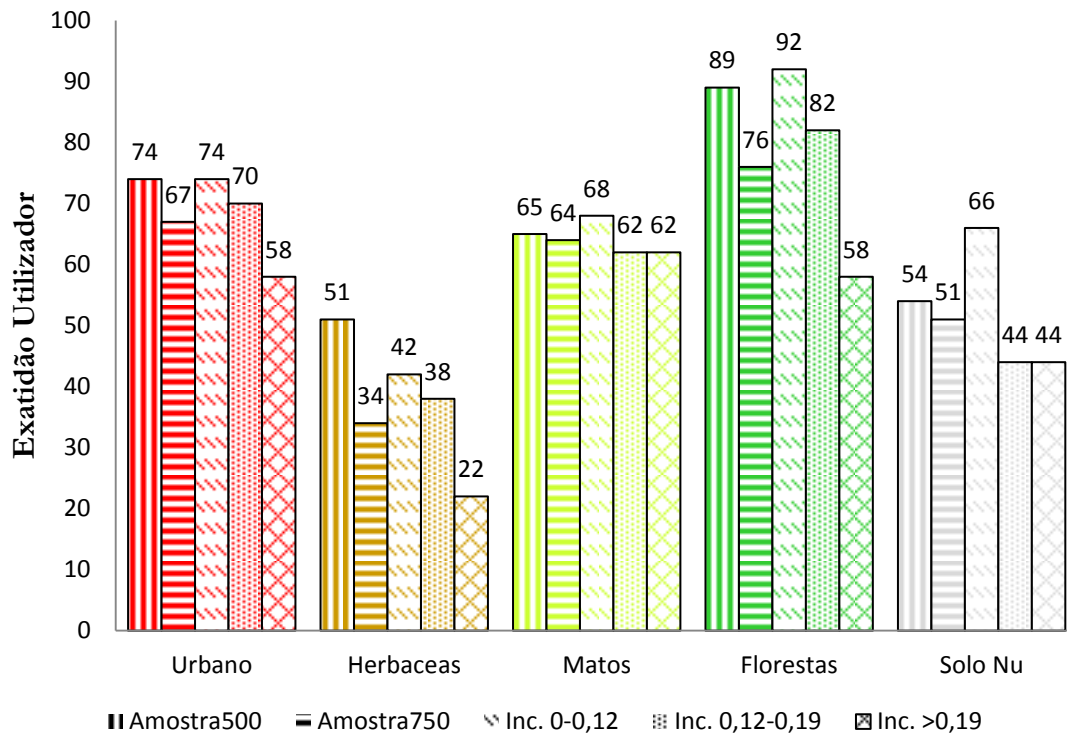


Figura 33- Exatidões do utilizador obtidas na totalidade da classificação e em cada intervalo de incerteza resultante da classificação da imagem Spot, utilizando o classificador da máxima verosimilhança

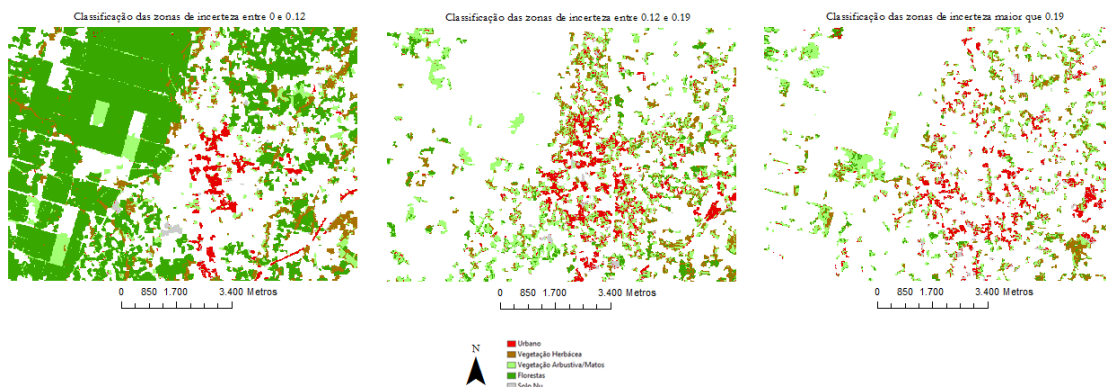


Figura 34- Classificação dos níveis de incerteza de 0 a 0.12, de 0.12 a 0.19 e maior que 0.19 da imagem Spot, utilizando o classificador da máxima verosimilhança

Relativamente à exatidão do produtor, para cada classe, resultante da classificação da imagem Spot, utilizando o classificador da máxima verosimilhança, na Figura 35 observa-se uma situação semelhante à ocorrida com a exatidão do utilizador, ou seja uma **diminuição da exatidão de acordo com o aumento da incerteza**. Neste caso, apenas

na classe urbano se verifica um aumento da exatidão do nível de incerteza entre 0.12 e 0.19, para o nível de incerteza maior que 0.19. É também possível observar que nas classes vegetação arbustiva e floresta, a exatidão do produtor, resultante da amostra de 500 pontos, é maior que exatidão do menor nível de incerteza, apesar de, mais uma vez, a exatidão obtida a partir da amostra de 750 pontos, ser menor e bastante semelhante à exatidão do nível de incerteza médio.




Figura 35- Exatidões do produtor obtidas na totalidade da classificação e em cada intervalo de incerteza resultante da classificação da imagem Spot, utilizando o classificador da máxima verossimilhança

4.8.6. Exatidões do utilizador e do produtor, resultantes das classificações da imagem Spot, utilizando o classificador BelClass

Para a exatidão do utilizador, resultante das classificações da imagem Spot, utilizando o classificador BelClass, a Figura 36 mostra que, na classe vegetação herbácea, a exatidão aumenta na passagem do nível de incerteza de 0 a 0.82 para o nível de incerteza entre 0.82 e 0.87, ainda que apenas em 4 %. No caso do solo nu, a exatidão também aumenta na transição do nível de incerteza entre 0.82 e 0.87, para o intervalo de incerteza maior que 0.87.

Em todos os outros casos se observa que a exatidão diminui com o aumento da incerteza, sendo de referir o **decréscimo acentuado** de exatidão do nível de incerteza entre 0.82 e 0.87 para o nível de incerteza maior que 0.87 da classe urbano (de 44% para 14%), ocorrendo algo semelhante do nível de incerteza entre 0 e 0.82 para o nível de 0.82 a 0.87 da classe solo nu (de 56% para 36%).

A figura 37 mostra a classificação de cada intervalo de incerteza, definido para a classificação da imagem Spot, utilizando o classificador BelClass.




Figura 36- Exatidões do utilizador obtidas na totalidade da classificação e em cada intervalo de incerteza resultante da classificação da imagem Spot, utilizando o classificador BelClass

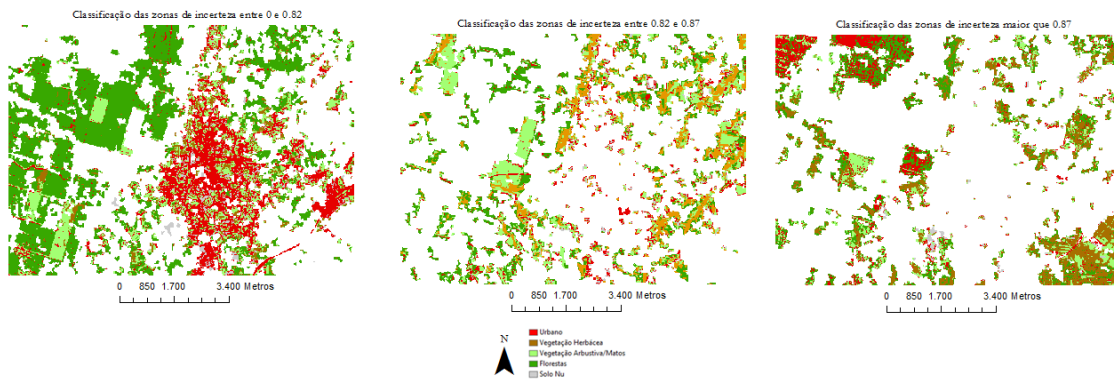


Figura 37- Classificação dos níveis de incerteza de 0 a 0.82, de 0.82 a 0.87 e maior que 0.87 da imagem Spot, utilizando o classificador BelClass

No que diz respeito à exatidão do produtor, na Figura 38, pode verificar-se que mais uma vez, regra geral, a **exatidão diminui com o aumento da incerteza**, sendo que apenas na passagem do nível de incerteza entre 0.82 e 0.87 para o nível de incerteza maior que 0.87, das classes vegetação herbácea e solo nu, este facto não ocorre. É também de referir que, para as classes vegetação herbácea e vegetação arbustiva, a exatidão resultante da amostra de 500 pontos é maior que a exatidão obtida para o menor nível de incerteza. Mais uma vez fica demonstrada a influência da amostra na exatidão da classificação, pois a exatidão obtida para a amostra de 750 pontos é menor que a exatidão do menor nível mas mais próxima da exatidão do nível de incerteza médio.

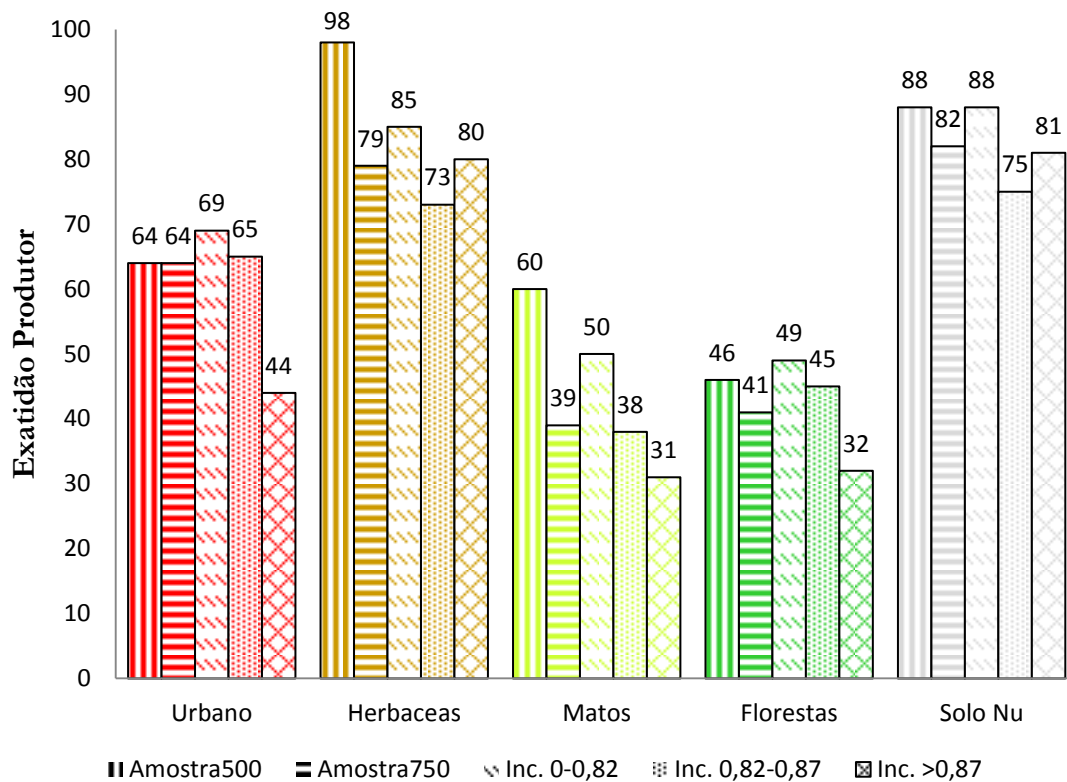


Figura 38- Exatidões do produtor obtidas na totalidade da classificação e em cada intervalo de incerteza resultante da classificação da imagem Spot, utilizando o classificador BelClass

4.8.7. Espacialização da exatidão obtida em cada intervalo de incerteza resultante da classificação da imagem Ikonos, utilizando o classificador da máxima verosimilhança

No sentido de espacializar a exatidão resultante da classificação da imagem Ikonos, com o classificador da máxima verosimilhança, em cada intervalo de incerteza definido inicialmente (0-0.05; 0.05-0.09;>0.09), é importante analisar a localização de cada uma destas zonas de incerteza e, conseqüentemente, estudar que tipo de ocupação de solo se encontra presente e que tenha determinado os respectivos valores de incerteza atribuídos pelo classificador.

A figura 37, relativa à classificação do nível de incerteza menor (0-0.05), resultante da classificação a imagem Ikonos, com o classificador da máxima verosimilhança, mostra uma grande predominância de zonas classificadas como floresta mas mostra, igualmente, que a maioria das zonas urbanas foram classificadas neste intervalo de incerteza, o que

poderá ser confirmado pela Figura 39 e pela tabela 19 que apresenta o total e a percentagem de área urbana para cada um dos níveis de incerteza da classificação. Este facto indica que o classificador da máxima verosimilhança não teve dificuldades para classificar as zonas urbanas e as exatidões do utilizador (76%) e do produtor (69%) (ver Figura 27 e 28 ou Tabela 24, Anexo A) confirmam que estas zonas foram bem classificadas.




Figura 39 – Ocupação de solo das zonas de incerteza menor que 0.05, resultante da classificação da imagem Ikonos, utilizando o classificador da máxima Verosimilhança

Tabela 19 – Área urbana total e percentagem por cada nível de incerteza resultante da classificação da imagem Ikonos, com o classificador da máxima verosimilhança

	Área (m ²)	%
Incerteza 0-0.05	5881216	82
Incerteza 0.05-0.09	933808	13
Incerteza > 0.09	329072	5
Total	7144096	100

Na classificação da imagem Ikonos utilizando o classificador da máxima verosimilhança para níveis de incerteza entre 0.05 e 0.09, representada na Figura 40, observa-se a presença das regiões de fronteira que delimitam várias parcelas, e uma maior incidência de *pixels* classificados como floresta (E.U 74% e E.P. 66%, ver Figura 27 e 28), havendo também bastantes regiões classificadas como vegetação arbustiva/matos, o que pode ser confirmada através da tabela 20, que apresenta os valores das áreas de cada classe para este nível de incerteza.

Tabela 20 - Valor das áreas de cada classe na incerteza entre 0.05 e 0.09, resultante da classificação da imagem Ikonos, utilizando o classificador da máxima verossimilhança

	Área (m ²)	%
Urbano	933808	5
Veg. Herbácea	533584	3
Veg. Arb/matos	4870192	26
Floresta	11595392	63
Solo Nu	56384	3
Total	18493360	100

Uma vez que a maioria das zonas de floresta foram classificadas no intervalo de incerteza entre 0 e 0.05, é relevante verificar o que está presente no terreno das áreas de floresta classificadas no intervalo de 0.05 a 0.09 e que tenha levado o classificador a atribuir-lhe valores de incerteza superiores. Assim, na figura 40 foram definidas duas zonas com estas características (zona 1 e zona 2). No caso da zona 1, representado pela figura 41, é possível observar que esta é uma zona de floresta baixa, apresentando algumas zonas com respostas espectrais características de vegetação herbácea e de vegetação arbustiva/matos. Relativamente à zona 3, a Figura 42 mostra que esta é uma região com diversos tipos de coberto de solo, principalmente floresta, vegetação herbácea e vegetação arbustiva/matos.




Figura 40- Ocupação de solo das zonas de incerteza entre 0.05 e 0.09, resultante da classificação da imagem Ikonos, utilizando o classificador da máxima Verossimilhança




Figura 41- Imagem da ocupação de solo relativa à zona 1, demarcada na Figura 40




Figura 42 – Imagem da ocupação de solo relativa à zona 2, demarcada na Figura 40

Relativamente à classificação da imagem Ikonos utilizando o classificador da máxima verossimilhança, apenas falta analisar os resultados obtidos para o intervalo de incerteza maior que 0.09. Na Figura 43 que mostra a classificação com o classificador da máxima verossimilhança e na tabela 21 que contém os valores das áreas de cada classe neste intervalo de incerteza, observa-se que, tal como nos níveis de incerteza inferiores, a maioria das regiões são classificadas como florestas (E.U. 68% E.P.47% ver Figura 27 e 28) ou como vegetação arbustiva/matos (E.U 60% E.P 41%).

Tabela 21 - Valor das áreas de cada classe no intervalo de incerteza maior que 0.09, resultante da classificação da imagem Ikonos, utilizando o classificador da máxima verossimilhança

	Área (m ²)	Percentagem
Urbano	329072	2
Veg. Herbácea	518992	4
Veg. Arb/matos	4657968	34
Floresta	7976064	58
Solo Nu	237424	2
Total	13713520	100

Tal como foi feito anteriormente, importa também verificar que tipo de ocupação de solo está presente nestas zonas e que conduziu o classificador a atribuir-lhes valores de incerteza mais elevados. Neste sentido, foram definidas 3 zonas na figura 43 e foi observado o seu tipo de coberto de solo. Nas figuras 44 e 45, referentes às zonas 1 e 2, respetivamente, é possível verificar que são regiões com zonas de floresta, vegetação arbustiva/matos e alguma vegetação herbácea. Este facto ocorre igualmente na figura 46, relativa à zona 3, no entanto neste caso é também de referir a confusão evidente entre o solo nu e os *pixels* classificados com urbano.




Figura 43- Ocupação de solo das zonas de incerteza entre maior que 0.09, resultante da classificação da imagem Ikonos, utilizando o classificador da máxima Verossimilhança




Figura 44- Imagem da ocupação de solo relativa à zona 1, demarcada na Figura 43

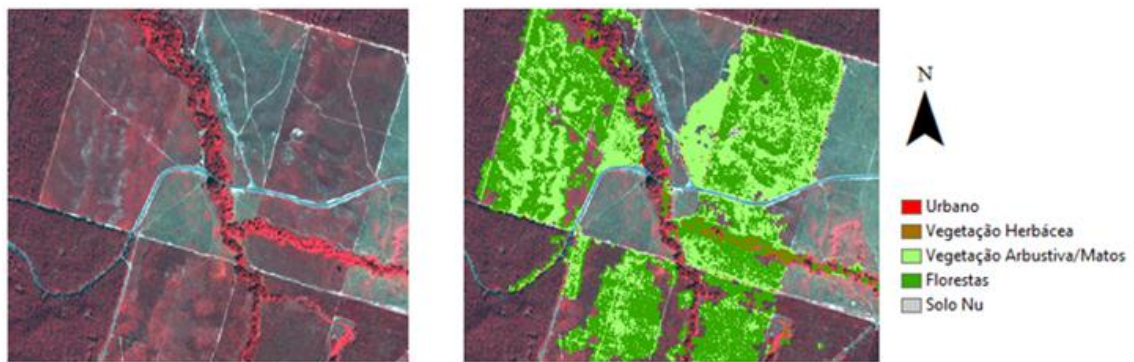


Figura 45- Imagem da ocupação de solo relativa à zona 2, demarcada na Figura 43




Figura 46- Imagem da ocupação de solo relativa à zona 3, demarcada na Figura 43

4.8.8. Espacialização da exatidão obtida em cada intervalo de incerteza resultante da classificação da imagem Ikonos, utilizando o classificador BelClass

No caso da classificação da imagem Ikonos obtida utilizando o classificador BelClass para o nível de incerteza entre 0 e 0.75, contrariamente aos resultados obtidos na classificação com o classificador da máxima verosimilhança para o intervalo de menor incerteza (incerteza 0-0.05), somente pequenas zonas são classificadas como urbano, o que pode ser confirmado pela figura 47, mas com uma elevada exatidão quer do utilizador, quer do produtor (E.P 81% e E.U. 76% ver Figura 30 e 32).

A Figura 47 mostra também, uma grande predominância de zonas de Floresta, com uma exatidão do utilizador muito boa mas a exatidão do produtor sofre uma quebra assinalável (ver Figura 30 e 32, E.U. 90% e E.P. 47%). Este facto significa que houve um grande número de *pixels* que, na realidade, são floresta mas foram classificados como outras classes, nomeadamente vegetação herbácea e vegetação arbustiva/matos (ver tabela 32, Anexo B), como é demonstrado no exemplo da Figura 48. Por outro lado, será também de referir que, apesar de haver poucas zonas classificadas como matos, apenas 50% dessas zonas são na realidade matos.




Figura 47- Ocupação de solo das zonas de incerteza menor que 0.75, resultante da classificação da imagem Ikonos, utilizando o classificador BelClass




Figura 48 – Exemplo de *pixels* que na realidade são floresta, apesar de serem classificados pelo classificador BelClass, como vegetação arbustiva (zona demarcada na imagem 47)

Na figura 49, referente à classificação da imagem Ikonos obtida pelo classificador BelClass, para o nível de incerteza entre 0.75 e 0.88, verifica-se que, ao contrário do que sucedeu com a classificação da máxima verosimilhança, existem muitas zonas classificadas como urbano, sendo 72% delas, realmente urbanas (E.U 72% e E.P. 61% ver Figura 30 e 32). Por outro lado, é também possível observar uma considerável presença de zona de floresta, com um bom nível de exatidão do utilizador (70%) mas com um assinalável decréscimo de exatidão do produtor (50%). Assim, do que realmente é floresta neste nível de incerteza, bastantes zonas foram classificadas como vegetação arbustiva/matos ou como vegetação herbácea. (ver tabela 33, Anexo B).




Figura 49- Ocupação de solo das zonas de incerteza entre 0.75 e 0.88, resultante da classificação da imagem Ikonos, utilizando o classificador BelClass

No caso das zonas incerteza maior que 0.88 resultante da classificação da imagem Ikonos obtida com o classificador BelClass, a Figura 50 mostra que quase não existem zonas classificadas como floresta, contrariamente ao que sucede com os resultados obtidos com o classificador da máxima verosimilhança, onde a presença de muitos *pixels* classificados como floresta é transversal aos três níveis de incerteza (0-0.05; 0.05-0.09;> 0.09).

É também possível referir a forte presença de zonas classificadas como urbano neste nível de incerteza (E.U. 58% E.P. 66% ver Figura 30 e 32), sendo este facto também contrário ao que se verifica na classificação da máxima verosimilhança, onde a zona urbana está, maioritariamente, classificada no nível de incerteza mais baixa (0-0.05). Assim, importa verificar a área total de zona urbana classificada pelos dois classificadores, sendo a área total da zona classificada como urbano, nos três níveis de incerteza da classificação da máxima verosimilhança, de 7144096m² e de 8730224 m², no caso da classificação utilizando o classificador BelClass.




Figura 50- Ocupação de solo das zonas de incerteza maior que 0.88, resultante da classificação da imagem Ikonos, utilizando o classificador BelClass

4.8.9. Espacialização da exatidão obtida em cada intervalo de incerteza resultante da classificação da imagem Spot, utilizando o classificador da máxima verosimilhança

Analisando as zonas de incerteza entre 0 e 0.12 resultantes da classificação da imagem Spot utilizando o classificador da máxima verosimilhança, apresentada na Figura 51, observa-se uma clara presença de todas as classes. No entanto, existe uma menor incidência de *pixels* classificados como urbano, comparativamente à classificação das zonas de menor incerteza (incerteza 0-0.05) da imagem Ikonos com o classificador da máxima verosimilhança. A exatidão da classe urbana é bastante boa (E.U. 74% e E.P. 82%, ver Figuras 33 e 35), sendo também de referir que a classe floresta está igualmente bem classificada do ponto de vista do utilizador, com uma exatidão de 92%. Do ponto de vista da exatidão do produtor, apenas 58% do que na realidade é floresta, foi classificado como tal, sendo muitas destas zonas classificadas como vegetação herbácea ou como vegetação arbustiva/matos (ver Tabela 40, Anexo C).




Figura 51- Ocupação de solo das zonas de incerteza menor que 0.12, resultante da classificação da imagem Spot, utilizando o classificador da máxima Verossimilhança

No que diz respeito à classificação das zonas de incerteza entre 0.12 e 0.19, resultantes da classificação da imagem Spot, utilizando o classificador da máxima verossimilhança, a Figura 52 mostra que existe uma considerável redução do número de regiões classificadas como Floresta (E.U. 82% e E.P. 57%, ver Figuras 33 e 35) e um aumento significativo das regiões classificadas como zona urbana (E.U. 70% E.P. 57%), comparativamente às zonas de incerteza menor que 0.12. No que diz respeito às zonas classificadas como solo nu, apenas 44% são solo nu, sendo que muitos destes *pixels* são na realidade zona urbana (ver tabela 41, Anexo C).

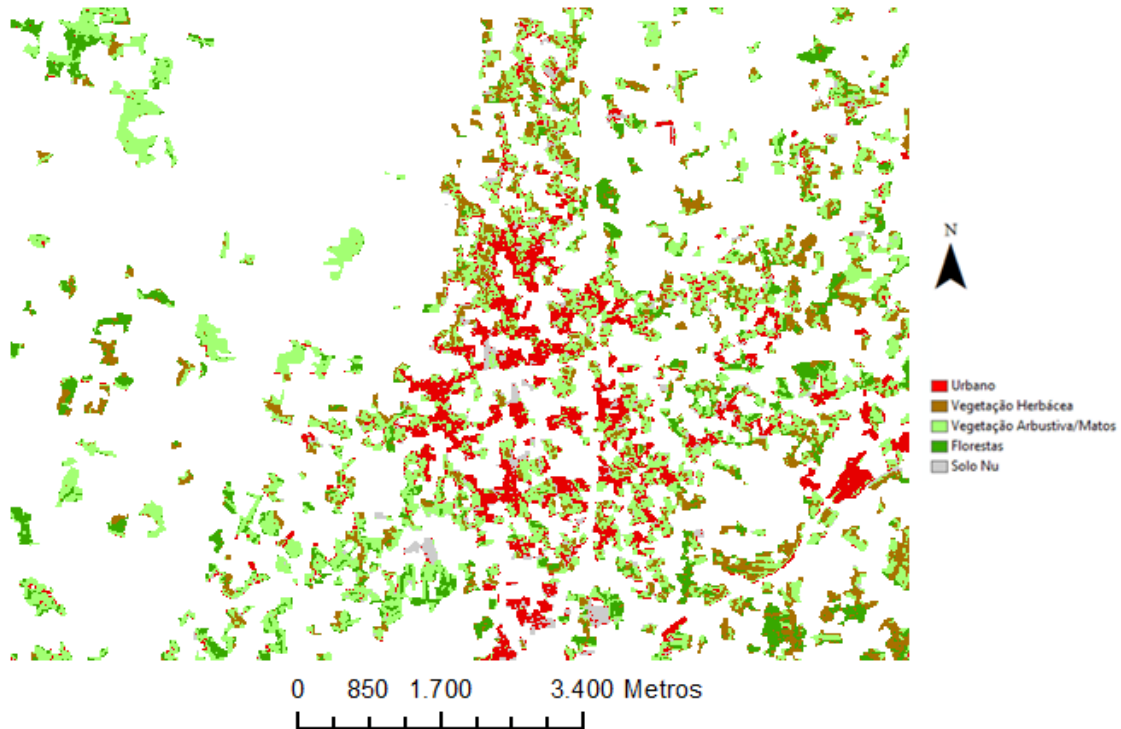


Figura 52- Ocupação de solo das zonas de incerteza entre 0.12 e 0.19, resultante da classificação da imagem Spot, utilizando o classificador da máxima Verossimilhança

No intervalo de incerteza maior que 0.19 resultante da classificação da imagem Spot com o classificador da máxima verossimilhança, podemos verificar a existência de muitas zonas classificadas como urbano (E.U. 58% E.P. 63% ver Figuras 33 e35), sendo confundidas, principalmente, com solo nu (ver tabela 42, Anexo C). No que diz respeito às zonas classificadas como floresta, apesar de serem muito poucas, estas estão bastante confundidas com a vegetação arbustiva/matos (ver tabela 42, Anexo C) e daqui resulta uma exatidão do utilizador de 58%. Relativamente à vegetação herbácea, com uma exatidão do utilizador de 22%, muitas das zonas classificadas como tal, são na realidade vegetação arbustiva/matos ou floresta. Para ilustrar este facto foi delineada uma região na Figura 53, sendo possível verificar, pela figura 54, que nesta região existe uma mistura entre zonas de floresta, de arbustos/matos e de vegetação herbácea.

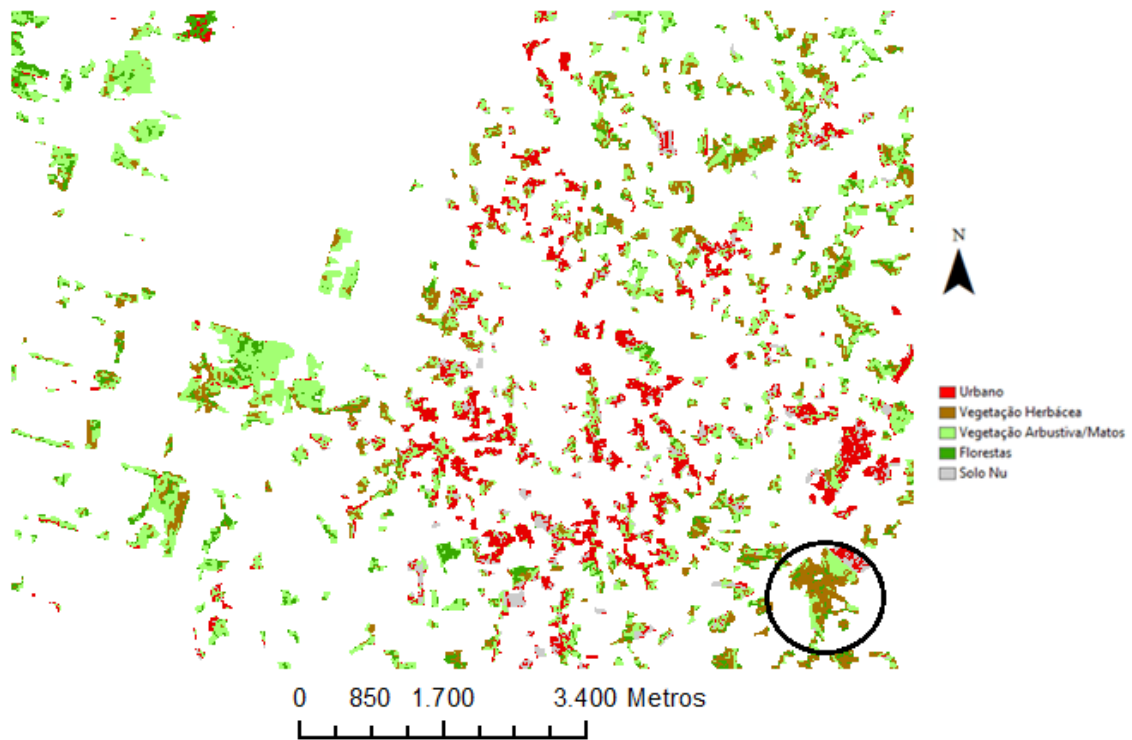


Figura 53- Ocupação de solo das zonas de incerteza entre maior que 0.19, resultante da classificação da imagem Spot, utilizando o classificador da máxima Verossimilhança




Figura 54 – Ocupação de solo presente na zona demarcada na Figura 63

4.8.10. Espacialização da exatidão obtida em cada intervalo de incerteza resultante da classificação da imagem Spot, utilizando o classificador BelClass

A Figura 55, referente à classificação das zonas de incerteza entre 0 e 0.82 da imagem Spot com o classificador BelClass, mostra que, contrariamente ao que ocorreu na classificação da incerteza menor (0-0.12) da imagem Spot com o classificador da máxima verosimilhança, a maior parte da zona urbana foi classificada neste nível de incerteza (E.U. 68% e E.P. 69% ver figuras 36 e 38). Por outro lado, é também notória a presença clara de todos os tipos de ocupação de solo, apesar de ocorrer uma predominância evidente da classe floresta (E.U.86% e E.P.49%, ver Figura 36 e 38) e que da área classificada como vegetação herbácea/matos, apenas 34% o é na realidade, sendo esta classe bastante confundida com floresta (ver tabela 48, Anexo D).

Através da intersecção da classificação das zonas de incerteza entre 0 e 0.12 resultante da classificação da imagem Spot, utilizando o classificador da máxima verosimilhança (Figura 51) e da classificação das zonas de incerteza entre 0 e 0.82 resultante da classificação com o classificador BelClass (Figura 55), foi possível encontrar as zonas de menor incerteza comuns às duas classificações da imagem Spot. Na figura 56, encontram-se representadas estas zonas comuns, com a ocupação de solo atribuída por cada um dos classificadores. Assim é possível observar que, apesar de a maioria das zonas serem classificadas da mesma forma, existem áreas classificadas de uma forma pelo classificador da máxima verosimilhança e de outra forma pelo Belclass. Um exemplo desta situação foi assinalado na Figura 56, onde um dos classificadores atribui a classe floresta à quase totalidade dos *pixels* e outro classificador, para além da floresta, também classifica vários *pixels* como urbano. A Figura 57 é representativa da real ocupação de solo da zona em questão, onde se verifica que existe muita floresta mas, igualmente, uma estrada, o que justifica a diferença entre os resultados obtidos por cada classificador.




Figura 55- Ocupação de solo das zonas de incerteza menor que 0.82, resultante da classificação da imagem Spot, utilizando o classificador BelClass

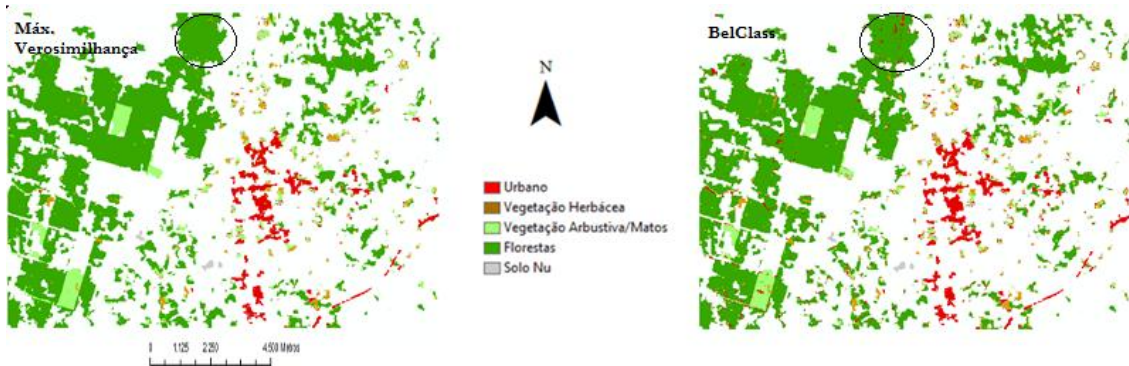


Figura 56- Zona de menor incerteza comum à classificação da imagem Spot com os dois classificadores




Figura 57- Imagem da ocupação de solo da região demarcada na Figura 56

A figura 58, referente à classificação das zonas de incerteza entre 0.82 e 0.87 resultante da imagem Spot, utilizando o classificador BelClass, mostra que, neste caso, existem muito poucas zonas classificadas como floresta e, apesar de esta classe apresentar uma muito boa exatidão do utilizador (80%, ver Figura 36 e 38), apenas 45% das zonas que realmente são floresta foram classificadas como tal, sendo classificadas como vegetação herbácea, vegetação arbustiva ou como urbano (ver tabela 49, Anexo D). Por outro lado, apesar de existirem muito poucas zonas classificadas como solo nu, apenas 36% o são na realidade, e a exatidão do utilizador da vegetação herbácea é de 36%, sendo que na realidade o restante é floresta ou vegetação arbustiva/matos (ver tabela 49, Anexo D).

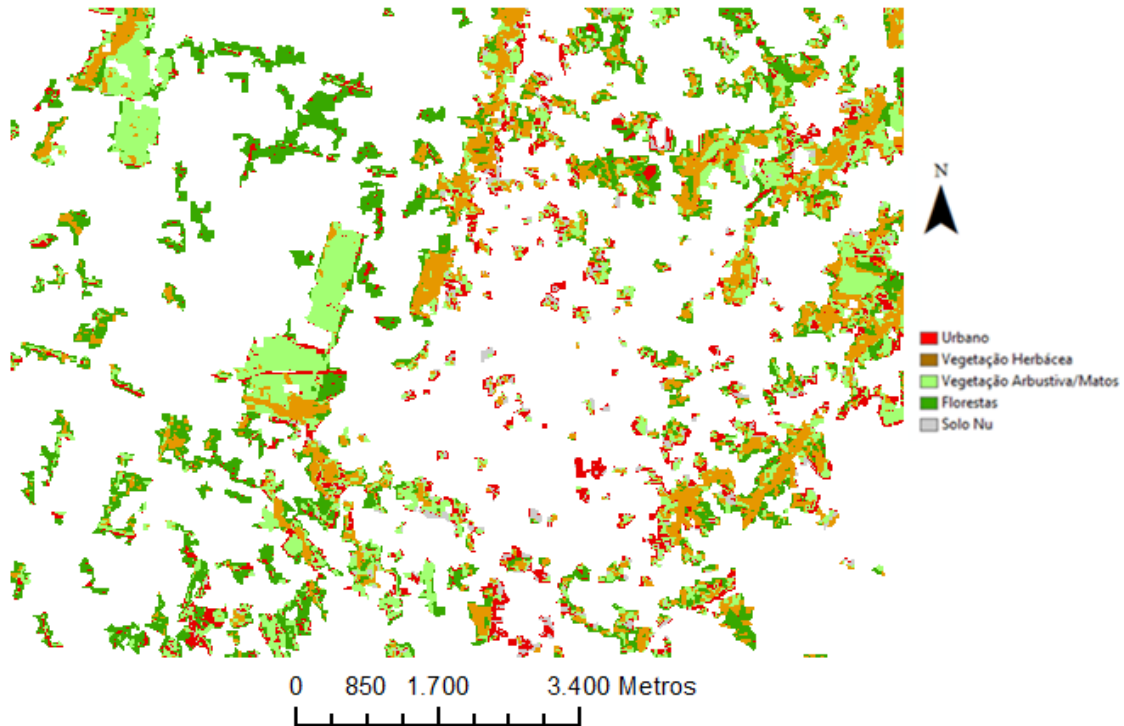


Figura 58- Ocupação de solo das zonas de incerteza entre 0.82 e 0.87, resultante da classificação da imagem Spot, utilizando o classificador BelClass

A Figura 59 que representa a classificação das zonas de incerteza maior que 0.87 obtida pelo classificador BelClass, mostra uma maior incidência de *pixels* classificados como zona urbana e como vegetação herbácea. No entanto, existem várias regiões mal classificadas como zona urbana, como é possível ver pela Figura 60 referente à Zona 1, demarcada na Figura 59. Aqui houve uma evidente confusão da classe urbano com vegetação arbustiva e com floresta (ver Tabela 50, Anexo D), o que pode ser confirmado pela exatidão do utilizador (14% ver Figura 36). Relativamente às zonas classificadas como vegetação herbácea, apenas 24% o são realmente (ver Figura 36), o que pode ser confirmado pela Figura 63, alusiva à zona 4, demarcada na Figura 59, onde é evidente a mistura entre zona de floresta, matos e herbáceas.

No que diz respeito às zonas classificadas como vegetação arbustiva/matos, as figuras 61 e 62, referentes às zonas 2 e 3, demarcadas na Figura 59, mostram uma certa confusão com vegetação herbácea, florestas e urbano, confirmada pela exatidão do utilizador desta classe que é de 52% (ver Figura 36 e Tabela 50, Anexo D).




Figura 59 - Ocupação de solo das zonas de incerteza maior que 0.87, resultante da classificação da imagem Spot, utilizando o classificador BelClass




Figura 60 - Imagem da ocupação de solo relativa à zona 1, demarcada na Figura 59




Figura 61 - Imagem da ocupação de solo relativa à zona 2, demarcada na Figura 59




Figura 62 - Imagem da ocupação de solo relativa à zona 3, demarcada na Figura 59




Figura 63 - Imagem da ocupação de solo relativa à zona 4, demarcada na Figura 59

A Figura 64 mostra as zonas de maior incerteza comuns às duas classificações da imagem Spot, obtida pela intersecção das zonas de incerteza maior que 0.19 da classificação da imagem Spot, utilizando o classificador da máxima verosimilhança e as zonas de incerteza maior que 0.87, da classificação com o BelClass. É possível observar que existem zonas classificadas de forma diferente pelos dois classificadores, sendo a zona demarcada um exemplo deste facto, onde o classificador da máxima verosimilhança atribui a classe floresta ou vegetação arbustiva, o classificador BelClass atribuiu principalmente a classe urbano (ver Figura 64).




Figura 64 - Zona de maior incerteza comum à classificação da imagem Spot com os dois classificadores

5. Conclusões

Os resultados obtidos e apresentados ao longo da dissertação revelam que a informação da incerteza da classificação das imagens em questão, utilizando o classificador probabilístico da máxima verosimilhança e o classificador não rígido baseado na teoria de Dempster-Shaffer (BelClass), pode ser utilizada como indicador da exatidão da classificação. Neste sentido, é possível verificar um decréscimo da exatidão global das classificações em função do aumento da incerteza, para as duas imagens em estudo e utilizando os dois classificadores.

Comparando os dois classificadores, observa-se que a incerteza resultante da classificação das duas imagens, utilizando o classificador da máxima verosimilhança, apresenta valores de incerteza menores e, em qualquer dos casos, exatidões superiores aos resultados obtidos com o classificador baseado na teoria de Dempster-Shaffer. Por outro lado, observou-se também que, as exatidões resultantes das classificações da imagem Ikonos com os dois classificadores, são superior às exatidões globais obtidas nas classificações da imagem Spot com os mesmos classificadores.

Relativamente às exatidões do utilizador e do produtor das classificações da imagem Ikonos e da imagem Spot, utilizando o classificador da máxima verosimilhança e o classificador BelClass, apesar de não se verificar sempre um decréscimo da exatidão em função do aumento da incerteza, regra geral é possível observar que para cada intervalo de incerteza resultante de cada classificação, as exatidões da maioria das classes de ocupação de solo também sofre uma quebra, de acordo com valores de incerteza mais elevados.

Uma vez que, com um aumento da incerteza, se verifica uma consequente diminuição da exatidão, foi necessário estudar o terreno presente em cada intervalo de incerteza resultante das classificações das duas imagens, no sentido de averiguar que fatores poderiam ter influenciado estes resultados. Assim, foi possível verificar que zonas com piores índices de exatidão e maior incerteza apresentam evidentes misturas e confusão entre diversos tipos de coberto de solo, o que poderá confirmar que a informação da incerteza resultante da classificação das imagens com os dois classificadores em estudo,

pode ser um indicador, não só da exatidão da classificação, mas pode ser também utilizada como um indicador para espacializar essa exatidão, em função da realidade do terreno.

Bibliografia

BO, Y.C. AND WANG, J.F., (2008) A general method for assessing uncertainty in classified remotely sensed data at pixel scale, in: Proceedings of the “8 th International Symposium on Spatial Accuracy Assessment in Natural Resources and Environmental Sciences, Shangai, China, D. Li, Y. Ge and G.M. Foody (Ed.), (World Acad Union-World Acad Press), pp. 186-194.

COMBER, A., FISHER, P., BRUNSDON, C., KHMAG, A. (2012) Geographically weighted methods for examining the spatial variation in land cover accuracy in: Proceedings of the “10th International Symposium on Spatial Accuracy assessment in Natural Resources and Environmental Sciences”, Florianopolis-SC, Brazil.

EASTMAN, J.R.,(2009) Classification of Remotely Sensed Imagery, in *Idrisi Taiga Guide to Gis and Image Processing*, Clark Labs, Clark University.

FOODY ET AL, (1992) Derivation and applications of Probabilistic Measures of Class Membership from the Maximum-Likelihood Classification, *Photogrammetric Engineering and Remote Sensing*, 58, 1335-1341.

FOODY, G. (2000b) Mapping land cover from remotely sensed data with a softened feedforward neural network classification, *Journal of Intelligent & Robotic Systems*, 29, 433-449.

FOODY, G. (2005) Local characterization of thematic classification accuracy through spatially constrained confusion matrices, *International Journal of Remote Sensing*, 26, 1217-1228.

- FONTE, C.C., GONÇALVES, L.M.S. (2011) Assessing the spatial variability of the accuracy of multispectral images classification using the uncertainty information provided by soft
- GOETZ ET AL (2010) IKONOS imagery for resource management: Tree cover, impervious surfaces, and riparian buffer analyses in the mid-Atlantic region, *Remote Sensing of Environment*, 88, 195-208.
- GONÇALVES, L.M.S., FONTE, C.C., JÚLIO, E., CAETANO, M. (2009) On the information provided by uncertainty measures in the classification of Remote Sensing Images, in: Proceedings of the “International Fuzzy Systems association World Congress 2009”(IFSA 2009)/ ”European Society for Fuzzy Logic and Technology Conference” (EUSFLAT 2009), Lisboa, Portugal, pp. 1551-1556.
- GONÇALVES, L.M.S., FONTE, C.F, JÚLIO, E., CAETANO, M. (2010) Evaluation of soft possibilistic classifications with non-specificity uncertain measures, *International Journal of Remote Sensing*, 31, 5199-5219.
- HIGACHI, M. AND KLIR, G., (1982) Measures of uncertainty and information based on possibility distributions, *International Journal of General Systems*, 9, 43-58.
- IBRAHIM ET AL, (2005) Estimating and accommodating uncertainty through the soft classification of remote sensing data, *International Journal of Remote Sensing*, 26, 2995-3007.
- KLIR, G.J.,(1999) Uncertainty and Information Measures for Imprecise Probabilities: An overview in: “1st International Symposium on Imprecise Probabilities and Their Applications”, Ghent, Belgium.
- KLIR, G.J.,(2004), Generalized information theory: aims, results, and open problems, *Reliability Engineering & System Safety*, 85, 21-38.

LILLESAND ET AL, (2000) The training Stage, in *Remote Sensing and Image Interpretation*, John Wiley & Sons Inc.

RUSS, J. C.(1998) *The Image Processing Handbook.*, Boca Raton: CRC Press.

RUSSEL G. CONGALTON AN KASS GREEN (1999) Cap v in *Assessing the accuracy of remotely sensed data: Principles and practices*, Boca Raton, Flor : Lewis/CRC Press.

SANTOS, R.L. ET AL. A teoria da incerteza aplicada a classificação de imagens de satélites.

SOILLE, P.(1999) *Morphological Image Analysis - Principles and Applications*. Barcelona: . Springer.

TSO,B. AND MATTER, P.M., (2001) *Classification Methods for Remotely Sensed Data*. London: Taylor & Francis.

WANG, F.,(1999), Improving remote sensing image analysis through fuzzy information representation, *Photogrammetric Engineering and Remote Sensing*, 56, 1163-1169.

WOODCOCK,C., MACOMBER, S.A., PAX-LENNEY, M., COHEN, W.B. (2001) Monitoring large areas for forest change using Landsat: Generalization across space, time and Landsat sensors, *Remote Sensing of Environment*, 78, 194-203.

C.M.M.G Página da Camara municipal da Marinha Grande, <http://www.cm-mgrande.pt>
Acedida a 13 de Julho de 2012

Página de Embrapa, monitoramento por Satélite,
<http://www.sat.cnpem.embrapa.br/conteudo/spot.htm> Acedida a 13 de Julho de 2012

Anexos

Anexo A – Matrizes de confusão obtidas a partir da classificação da imagem Ikonos, utilizando o classificador da máxima verossimilhança.

Tabela 22- Matriz de confusão da classificação da imagem Ikonos, utilizando o classificador da Máxima verossimilhança (amostra 500)

	Urbano	Herbáceas	Matos	Florestas	Solo nu	Total	E.U. (%)
Urbano	81	0	2	0	17	100	81
Herbáceas	0	72	6	22	0	100	72
Matos	0	6	77	17	0	100	77
Florestas	0	2	12	86	0	100	86
Solo nu	22	0	4	0	74	100	74
Total	103	80	101	125	91	500	
E.P. (%)	79	90	76	69	81		78
Overall Kappa (%)	73						

Tabela 23- Matriz de confusão obtida a partir da amostra de 750 pontos, resultante da classificação da imagem Ikonos, utilizando o classificador da Máxima Verossimilhança

	Urbano	Herbáceas	Matos	Florestas	Solo nu	Total	E.U. (%)
Urbano	89	0	26	1	34	150	59
Herbáceas	1	96	21	32	0	150	64
Matos	8	7	104	29	2	150	69
Florestas	0	1	32	117	0	150	78
Solo nu	35	0	25	1	89	150	59
Total	133	104	208	180	125	750	
E.P. (%)	67	92	50	65	71		66
Overall Kappa (%)	58						

Espacialização da exatidão da classificação automática de imagens multiespectrais usando medidas de incerteza e classificadores não rígidos

Tabela 24- Matriz de confusão da incerteza menor ou igual que 0.05, resultante da classificação da imagem Ikonos, com o classificador da Máxima Verosimilhança

	Urbano	Herbáceas	Matos	Florestas	Solo nu	Total	E.U. (%)
Urbano	38	0	7	0	5	50	76
Herbáceas	0	37	8	5	0	50	74
Matos	5	2	39	2	2	50	78
Florestas	0	0	4	46	0	50	92
Solo nu	12	0	4	0	34	50	68
Total	55	39	62	53	41	250	
E.P. (%)	69	95	63	87	83		78
Overall Kappa (%)	72						

Tabela 25- Matriz de confusão da incerteza entre 0.05 e 0.09 resultante da classificação da imagem Ikonos, utilizando o classificador da Máxima Verosimilhança

	Urbano	Herbáceas	Matos	Florestas	Solo nu	Total	ErroC
Urbano	29	0	8	0	13	50	58
Herbáceas	1	34	6	9	0	50	68
Matos	1	5	34	10	0	50	68
Florestas	0	0	13	37	0	50	74
Solo nu	10	0	12	0	28	50	56
Total	41	39	73	56	41	250	
ErroO	71	87	47	66	68		65
Overall Kappa (%)	56						

Tabela 26- Matriz de confusão da incerteza maior que 0.09 resultante da classificação, da imagem Ikonos, utilizando o classificador da Máxima Verosimilhança

	Urbano	Herbáceas	Matos	Florestas	Solo nu	Total	E.U. (%)
Urbano	21	0	13	1	15	50	42
Herbáceas	0	25	7	18	0	50	50
Matos	2	0	30	18	0	50	60
Florestas	0	1	15	34	0	50	68
Solo nu	14	0	9	1	26	50	52
Total	37	26	74	72	41	250	
E.P. (%)	57	96	41	47	63		54
Overall Kappa (%)	43						

Espacialização da exatidão da classificação automática de imagens multiespectrais usando medidas de incerteza e classificadores não rígidos

Tabela 27- Matriz de confusão da incerteza menor que 0.10 resultante da classificação, da imagem Ikonos, utilizando o classificador da Máxima Verossimilhança

	Urbano	Herbáceas	Matos	Florestas	Solo nu	Total	E.U. (%)
Urbano	16	0	3	0	1	20	80
Herbáceas	0	19	18	1	0	20	95
Matos	1	0	18	1	0	20	90
Florestas	0	2	0	18	0	20	90
Solo nu	5	0	1	0	14	20	70
Total	22	21	22	20	15	100	
E.P. (%)	73	90	82	90	93		85
Overall Kappa (%)	81						

Tabela 28- Matriz de confusão da incerteza menor entre 0.10 e 0.15 resultante da classificação, da imagem Ikonos, utilizando o classificador da Máxima Verossimilhança

	Urbano	Herbáceas	Matos	Florestas	Solo nu	Total	E.U. (%)
Urbano	9	0	6	0	5	20	45
Herbáceas	0	13	1	6	0	20	65
Matos	0	0	14	6	0	20	70
Florestas	0	1	4	14	1	20	70
Solo nu	5	1	3	0	11	20	65
Total	14	15	28	26	17	100	
E.P. (%)	64	87	50	54	65		61
Overall Kappa (%)	49						

Tabela 29- Matriz de confusão da incerteza maior que 0.15 resultante da classificação, da imagem Ikonos, obtida com o classificador da Máxima Verossimilhança

	Urbano	Herbáceas	Matos	Florestas	Solo nu	Total	E.U. (%)
Urbano	11	0	8	0	1	20	55
Herbáceas	0	10	1	9	0	20	50
Matos	0	0	16	4	0	20	80
Florestas	0	3	13	4	0	20	20
Solo nu	5	0	3	0	12	20	60
Total	16	13	41	17	13	100	
E.P. (%)	69	77	39	24	92		53
Overall Kappa	41						

Anexo B - Matrizes de confusão obtidas a partir da classificação da imagem Ikonos, utilizando o classificador BelClass

Tabela 30- Matriz de confusão da classificação da imagem Ikonos utilizando o classificador BelClass (amostra 500)

	Urbano	Herbáceas	Matos	Florestas	Solo nu	Total	E.U.(%)
Urbano	64	0	13	4	19	100	64
Herbáceas	0	69	13	18	0	100	69
Matos	2	3	72	20	3	100	72
Florestas	0	4	9	87	0	100	87
Solo nu	19	0	12	0	69	100	69
Total	85	76	119	129	91	500	
E.P. (%)	75	91	61	67	76		72
Overall Kappa (%)	65						

Tabela 31- Matriz de confusão obtida a partir da amostra de 750 pontos resultante da classificação, da imagem Ikonos, utilizando o classificador BelClass

	Urbano	Herbáceas	Matos	Florestas	Solo nu	Total	E.U. (%)
Urbano	102	0	19	2	27	150	68
Herbáceas	0	80	19	51	0	150	53
Matos	8	8	76	52	6	150	51
Florestas	0	13	33	102	2	150	68
Solo nu	39	0	16	2	93	150	62
Total	149	101	163	209	128	750	
E.P. (%)	68	79	47	49	73		60
Overall Kappa (%)	51						

Espacialização da exatidão da classificação automática de imagens multiespectrais usando medidas de incerteza e classificadores não rígidos

Tabela 32- Matriz de confusão da incerteza menor ou igual que 0.75 resultante da classificação da imagem Ikonos, utilizando o classificador BelClass

	Urbano	Herbáceas	Matos	Florestas	Solo nu	Total	E.U.(%)
Urbano	38	0	1	2	9	50	76
Herbáceas	0	26	0	24	0	50	52
Matos	0	0	25	23	2	50	50
Florestas	0	0	4	45	1	50	90
Solo nu	9	0	1	2	38	50	76
Total	47	26	31	96	50	250	
E.P (%)	81	100	81	47	76		69
Overall Kappa (%)	61						

Tabela 33- Matriz de confusão da incerteza entre 0.75 e 0.88 resultante da classificação da imagem Ikonos, utilizando o classificador BelClass

	Urbano	Herbáceas	Matos	Florestas	Solo nu	Total	E.U. (%)
Urbano	36	0	7	0	7	50	72
Herbáceas	0	28	5	17	0	50	56
Matos	6	1	24	18	1	50	48
Florestas	0	4	10	35	1	50	70
Solo nu	17	0	3	0	30	50	60
Total	59	33	49	70	39	250	
E.P. (%)	61	85	49	50	77		61
Overall Kappa (%)	51						

Tabela 34- Matriz de confusão da incerteza maior que 0.88 resultante da classificação da imagem Ikonos, utilizando o classificador BelClass

	Urbano	Herbáceas	Matos	Florestas	Solo nu	Total	E.U. (%)
Urbano	29	0	10	0	11	50	58
Herbáceas	0	28	13	9	0	50	56
Matos	2	7	28	10	3	50	56
Florestas	0	7	21	22	0	50	44
Solo nu	13	0	12	0	25	50	50
Total	44	42	84	41	39	250	
E.P. (%)	66	67	33	54	64		53
Overall Kappa (%)	41						

Espacialização da exatidão da classificação automática de imagens multiespectrais usando medidas de incerteza e classificadores não rígidos

Tabela 35- Matriz de confusão da incerteza menor que 0.60 resultante da classificação da imagem Ikonos, utilizando o classificador BelClass

	Urbano	Herbáceas	Matos	Florestas	Solo nu	Total	E.U. (%)
Urbano	36	0	2	6	6	50	72
Herbáceas	0	29	0	21	0	50	58
Matos	0	1	28	21	0	50	56
Florestas	0	0	3	47	0	50	94
Solo nu	6	0	3	0	41	50	82
Total	42	30	36	95	47	250	
E.P. (%)	86	97	78	49	87		72
Overall Kappa (%)	66						

Tabela 36- Matriz de confusão da incerteza entre 0.60 e 0.80 resultante da classificação da imagem Ikonos, utilizando o classificador BelClass

	Urbano	Herbáceas	Matos	Florestas	Solo nu	Total	E.U. (%)
Urbano	34	1	5	2	8	50	68
Herbáceas	1	27	4	18	0	50	54
Matos	0	0	29	21	0	50	58
Florestas	0	0	7	43	0	50	86
Solo nu	14	0	0	0	36	50	72
Total	49	28	45	84	44	250	
E.P. (%)	69	96	64	51	82		68
Overall Kappa (%)	60						

Tabela 37- Matriz de confusão da incerteza maior que 0.80 resultante da classificação da imagem Ikonos, utilizando o classificador BelClass

	Urbano	Herbáceas	Matos	Florestas	Solo nu	Total	E.U. (%)
Urbano	33	0	12	0	5	50	66
Herbáceas	2	28	7	13	0	50	56
Matos	4	4	30	9	3	50	60
Florestas	0	3	18	29	0	50	58
Solo nu	11	1	7	0	31	50	62
Total	50	36	74	51	39	250	
E.P. (%)	66	78	41	57	79		60
Overall Kappa (%)	51						

Anexo C - Matrizes de confusão obtidas a partir da classificação da imagem Spot, utilizando o classificador da máxima verosimilhança

Tabela 38 -Matriz de confusão da classificação da imagem Spot, utilizando o classificador da Máxima verosimilhança (amostra 500)

	Urbano	Herbáceas	Matos	Florestas	Solo nu	Total	E.U. (%)
Urbano	74	0	2	12	12	100	74
Herbáceas	0	51	19	30	0	100	51
Matos	9	8	65	17	1	100	65
Florestas	0	2	9	89	0	100	89
Solo nu	25	5	14	2	54	100	54
Total	108	66	109	150	67	500	
E.P. (%)	69	77	60	59	81		67
Overall Kappa (%)	58						

Tabela 39- Matriz de confusão com a amostra de 750 pontos resultante da classificação da imagem Spot, utilizando o classificador da Máxima Verosimilhança

	Urbano	Herbáceas	Matos	Florestas	Solo nu	Total	E.U. (%)
Urbano	101	0	24	5	20	150	67
Herbáceas	1	51	42	56	0	150	34
Matos	9	4	96	36	5	150	64
Florestas	0	0	36	114	0	150	76
Solo nu	41	1	26	5	77	150	51
Total	152	56	224	216	102	750	
E.P. (%)	66	91	43	53	75		59
Overall Kappa (%)	48						

Espacialização da exatidão da classificação automática de imagens multiespectrais usando medidas de incerteza e classificadores não rígidos

Tabela 40- Matriz de confusão da incerteza menor ou igual que 0.12 resultante da classificação da imagem Spot, utilizando o classificador da Máxima Verossimilhança

	Urbano	Herbáceas	Matos	Florestas	Solo nu	Total	E.U. (%)
Urbano	37	0	8	0	5	50	74
Herbáceas	0	21	9	20	0	50	42
Matos	1	0	34	13	2	50	68
Florestas	0	0	4	46	0	50	92
Solo nu	7	0	9	1	33	50	66
Total	45	21	64	80	40	250	
E.P. (%)	82	100	53	58	83		68
Overall Kappa (%)	61						

Tabela 41- Matriz de confusão da incerteza entre 0.12 e 0.19 resultante da classificação da imagem Spot, utilizando o classificador da Máxima Verossimilhança

	Urbano	Herbáceas	Matos	Florestas	Solo nu	Total	E.U. (%)
Urbano	35	0	10	0	5	50	70
Herbáceas	0	19	13	18	0	50	38
Matos	7	0	31	12	0	50	62
Florestas	0	0	9	41	0	50	82
Solo nu	19	0	8	1	22	50	44
Total	61	19	71	72	27	250	
E.P. (%)	57	100	44	57	81		59
Overall Kappa (%)	49						

Tabela 42- Matriz de confusão da incerteza maior que 0.19 resultante da classificação da imagem Spot, utilizando o classificador da Máxima Verossimilhança

	Urbano	Herbáceas	Matos	Florestas	Solo nu	Total	E.U. (%)
Urbano	29	0	6	5	10	50	58
Herbáceas	1	11	20	18	0	50	22
Matos	1	4	31	11	3	50	62
Florestas	0	0	21	29	0	50	58
Solo nu	15	1	9	3	22	50	44
Total	46	16	87	66	35	250	
E.P. (%)	63	69	36	44	63		49
Overall Kappa (%)	36						

Espacialização da exatidão da classificação automática de imagens multiespectrais usando medidas de incerteza e classificadores não rígidos

Tabela 43- Matriz de confusão da incerteza menor que 0.10 resultante da classificação da imagem Spot, utilizando o classificador da Máxima verosimilhança

	Urbano	Herbáceas	Matos	Florestas	Solo nu	Total	E.U. (%)
Urbano	40	0	6	0	4	50	80
Herbáceas	0	22	5	23	0	50	44
Matos	0	1	34	13	2	50	67
Florestas	0	0	3	47	0	50	94
Solo nu	7	0	9	1	33	50	76
Total	47	23	56	84	39	249	
E.P. (%)	85	95	59	56	85		77
Overall Kappa (%)	63						

Tabela 44- Matriz de confusão da incerteza entre 0.10 e 0.20 resultante da classificação, da imagem Spot, utilizando o classificador da Máxima verosimilhança

	Urbano	Herbáceas	Matos	Florestas	Solo nu	Total	E.U. (%)
Urbano	38	0	4	1	7	50	76
Herbáceas	0	18	13	19	0	50	36
Matos	5	2	32	11	0	50	64
Florestas	0	0	7	43	0	50	86
Solo nu	15	0	11	2	22	50	44
Total	58	20	67	76	29	250	
E.P. (%)	66	90	48	57	76		61
Overall Kappa (%)	52						

Tabela 45- Matriz de confusão da incerteza maior que 0.20 resultante da classificação da imagem Spot, utilizando o classificador da Máxima verosimilhança

	Urbano	Herbáceas	Matos	Florestas	Solo nu	Total	E.U. (%)
Urbano	30	0	9	0	11	50	60
Herbáceas	0	8	12	30	0	50	16
Matos	4	3	31	12	0	50	62
Florestas	0	0	13	37	0	50	74
Solo nu	17	0	13	1	19	50	38
Total	51	11	78	80	30	250	
E.P. (%)	59	73	40	46	63		50
Overall Kappa (%)	38						

Anexo D - Matrizes de confusão obtidas a partir da classificação da imagem Spot, utilizando o classificador BelClass

Tabela 46- Matriz de confusão da classificação da imagem Spot, utilizando o classificador BelClass (amostra 500)

	Urbano	Herbáceas	Matos	Florestas	Solo nu	Total	E.U. (%)
Urbano	50	0	8	38	4	100	50
Herbáceas	0	43	14	43	0	100	43
Matos	3	1	67	25	4	100	67
Florestas	0	0	9	91	0	100	91
Solo nu	25	0	13	3	59	100	59
Total	78	44	111	200	67	500	
E.P. (%)	64	98	60	46	88		62
Overall Kappa	53						

Tabela 47- Matriz de confusão com a amostra de 750 pontos resultante da classificação da imagem Spot, utilizando o classificador BelClass

	Urbano	Herbáceas	Matos	Florestas	Solo nu	Total	E.U. (%)
Urbano	63	0	32	47	8	150	42
Herbáceas	0	48	31	71	0	150	32
Matos	6	8	86	44	6	150	57
Florestas	0	0	31	118	1	150	79
Solo nu	30	5	43	5	67	150	45
Total	99	61	223	285	82	750	
E.P. (%)	64	79	39	41	82		51
Overall Kappa (%)	39						

Espacialização da exatidão da classificação automática de imagens multiespectrais usando medidas de incerteza e classificadores não rígidos

Tabela 48- Matriz de confusão da incerteza menor ou igual que 0.82 resultante da classificação da imagem Spot, utilizando o classificador BelClass

	Urbano	Herbáceas	Matos	Florestas	Solo nu	Total	E.U. (%)
Urbano	34	0	6	6	4	50	68
Herbáceas	0	17	7	26	0	50	34
Matos	5	2	31	12	0	50	62
Florestas	0	0	7	43	0	50	86
Solo nu	10	1	11	0	28	50	56
Total	49	20	62	87	32	250	
E.P. (%)	69	85	50	49	88		61
Overall Kappa (%)	52						

Tabela 49- Matriz de confusão da incerteza entre 0.82 e 0.87 resultante da classificação da imagem Spot, utilizando o classificador da BelSpot

	Urbano	Herbáceas	Matos	Florestas	Solo nu	Total	E.U. (%)
Urbano	22	0	11	13	4	50	44
Herbáceas	0	19	12	19	0	50	38
Matos	1	5	29	13	2	50	58
Florestas	0	0	10	40	0	50	80
Solo nu	11	2	15	4	18	50	36
Total	34	26	77	89	24	250	
E.P. (%)	65	73	38	45	75		51
Overall Kappa (%)	39						

Tabela 50- Matriz de confusão da incerteza maior que 0.87 resultante da classificação da imagem Spot, utilizando o classificador da BelSpot

	Urbano	Herbáceas	Matos	Florestas	Solo nu	Total	E.U. (%)
Urbano	7	0	15	28	0	50	14
Herbáceas	0	12	12	26	0	50	24
Matos	0	1	26	19	4	50	52
Florestas	0	0	14	35	1	50	70
Solo nu	9	2	17	1	21	50	42
Total	16	15	84	109	26	250	
E.P. (%)	44	80	31	32	81		40
Overall Kappa (%)	26						

Espacialização da exatidão da classificação automática de imagens multiespectrais usando medidas de incerteza e classificadores não rígidos

Tabela 51- Matriz de confusão da incerteza menor que 0.65 resultante da classificação da imagem Spot, utilizando o classificador BelClass

	Urbano	Herbáceas	Matos	Florestas	Solo nu	Total	E.U. (%)
Urbano	16	0	3	3	3	25	64
Herbáceas	0	13	1	11	0	25	52
Matos	2	3	20	0	0	25	80
Florestas	0	0	1	23	1	25	92
Solo nu	5	0	3	0	17	25	68
Total	23	16	28	37	21	125	
E.U. (%)	70	81	71	62	81		71
Overall Kappa (%)	64						

Tabela 52- Matriz de confusão da incerteza entre 0.65 e 0.85 resultante da classificação da imagem Spot, utilizando o classificador BelClass

	Urbano	Herbáceas	Matos	Florestas	Solo nu	Total	E.U. (%)
Urbano	29	0	9	9	3	50	58
Herbáceas	1	21	11	17	0	50	42
Matos	3	4	34	5	4	50	68
Florestas	0	0	5	45	0	50	90
Solo nu	12	1	12	1	24	50	48
Total	45	26	71	77	31	250	
E.P. (%)	64	81	49	58	78		39
Overall Kappa (%)	52						

Tabela 53- Matriz de confusão da incerteza maior que 0.85 resultante da classificação da imagem Spot, utilizando o classificador BelClass

	Urbano	Herbáceas	Matos	Florestas	Solo nu	Total	E.U. (%)
Urbano	10	0	5	33	2	50	20
Herbáceas	0	9	10	31	0	50	18
Matos	0	2	29	15	4	50	58
Florestas	0	1	10	38	1	50	76
Solo nu	13	0	12	5	20	50	40
Total	23	12	66	122	27	250	
E.P. (%)	43	75	44	31	74		42
Overall Kappa (%)	28						