

# Identificação de vegetação urbana com folha caduca e perene em imagens multiespectrais

## Extraction of urban deciduous and evergreen vegetation from multispectral images

Lopes, Ricardo<sup>1</sup> & Fonte, Cidália C.<sup>2</sup>

<sup>1</sup> Mestrado em Tecnologias de Informação Geográfica  
Departamento de Matemática – Faculdade de Ciências e Tecnologia da Universidade de Coimbra  
Departamento de Geografia - Faculdade de Letras da Universidade de Coimbra  
Email: Ricardo\_17665(at)hotmail.com

<sup>2</sup> Departamento de Matemática - Faculdade de Ciências e Tecnologia da Universidade de Coimbra  
Apartado 3008, EC Universidade, 3001-454 Coimbra, Portugal  
Instituto de Engenharia de Sistemas e Computadores de Coimbra (INESCC)  
Tel: +351 239791150; Fax: +351 239793069; Email: cfonte(at)mat.uc.pt

**Resumo:** Neste artigo apresentam-se resultados preliminares do trabalho desenvolvido com o objetivo de fazer a classificação da vegetação urbana, separando-a em vegetação de folha caduca e perene, utilizando apenas uma imagem multiespectral de inverno. Foi utilizada uma imagem do sensor *Quickbird* composta por quatro bandas espectrais, com uma resolução espacial de 0,6 metros. A abordagem usada consiste na combinação dos resultados obtidos com duas metodologias diferentes utilizando classificadores não rígidos, nomeadamente um classificador baseado na teoria de *Dempster – Shafer* e outro classificador baseado na análise da mistura espectral em cada pixel (*Spectral Mixture Analysis*) e uma árvore de decisão. A avaliação dos resultados obtidos foi feita através de análise visual. Os resultados mostram que foi possível identificar a maioria das zonas com os dois tipos de vegetação, havendo no entanto algumas dificuldades, principalmente nas zonas de sombra.

**Palavra-Chave:** Vegetação urbana, Folha caduca, Folha perene, Imagem multiespectral, Classificadores não rígidos

**Abstract:** In this article the preliminary results of the work developed to perform the classification of urban vegetation into deciduous and evergreen vegetation, using only a winter image, is presented. An image of the Quickbird sensor with four multispectral bands and a spatial resolution of 0.6 meters was used. The methodology used consists in combining the results obtained with two different approaches using soft classifiers, namely a classifier based on Dempster- Shafer theory, the spectral mixture analysis classifier and a decision tree model. The assessment of the results accuracy was made by visual analysis. The final result shows that, even though some difficulties were found due to the present of shadows in the image, the presented methodology enabled the correct

identification of most vegetation regions as well as its separation into evergreen and deciduous.

**Key-Words:** Urban vegetation, Deciduous, Evergreen, Multispectral image, Soft classifiers

## 1- Introdução

A vegetação em contexto urbano é sem dúvida um recurso importante. A sua existência tem benefícios, de carácter ecológico, social, estético e económico (Tryäinen, 2005), tais como a melhoria da qualidade do ar e a regulação da temperatura ambiente (Avisar, 1996; Grimmond *et al.*, 1996; Nowak & Dwyer, 2000), bem como a regulação da radiação solar que incide nos edifícios (Tooke & Voogt, 2009). As duas últimas variáveis podem ter influência significativa no consumo de energia (Akbari & Konopacki, 2004), tanto nos meses de inverno como de verão, assim como na possibilidade de utilização de energia solar para aquecimento ou produção de energia.

Contudo, alguns tipos de vegetação têm variações sazonais importantes, em que as suas características são alteradas. A vegetação de folha perenifolia mantém as suas folhas durante todo o ano, enquanto a vegetação caducifolia perde as suas folhas nos meses de inverno, pelo que os dois tipos de vegetação influenciam o meio urbano envolvente de formas diferentes, sendo essencial identificar os locais onde existe cada um.

Em trabalhos desenvolvidos com o objectivo da criação de mapas de vegetação urbana, com a separação em vegetação de folha caduca ou perene, foram utilizados diferentes tipos de dados, como imagens multiespectrais de inverno, provenientes de diversos sensores com diferentes resoluções espaciais (Ardila *et al.*, 2010; Small & Lu, 2005; Tooke *et al.*, 2009; Zhang, 2001). Nalguns casos, para além da utilização das imagens multiespectrais, os autores utilizaram ainda outro tipo de dados, tais como cartografia digital (Ardila *et al.*, 2010) e ainda dados altimétricos LiDAR (Tooke *et al.*, 2009). Os trabalhos desenvolvidos demonstram que a conjugação da informação espectral com a informação altimétrica obtida a partir de LiDAR permite obter bons resultados, porque consegue gerar informação relativa à extensão das áreas de vegetação, bem como a sua altura, permitindo também avaliar o efeito sazonal das sombras. Contudo, os dados LiDAR são muito dispendiosos e não são facilmente acessíveis.

Assim, é objectivo deste trabalho identificar metodologias que permitam construir mapas de vegetação urbana, fazendo a sua separação em folha caduca e perene, utilizando apenas uma imagem multiespectral de inverno. Com este propósito, foi feita a combinação dos resultados obtidos com duas metodologias para a classificação da vegetação existente numa imagem multiespectral *Quickbird* de uma parte da cidade de Coimbra, usando classificadores não rígidos. Apresentam-se neste artigo os resultados preliminares obtidos com ambas as metodologias e com uma combinação de ambas.

## 2- Metodologia de classificação

Neste trabalho são utilizados duas metodologias, utilizando dois classificadores não rígidos com o objetivo de diferenciar a vegetação urbana em vegetação com folha caduca e perene. Um classificador não rígido avalia o grau de pertença de cada pixel da imagem a cada uma das classes consideradas, ao contrário de um classificador rígido que dá uma decisão final sobre a classe a que pertence cada pixel da imagem. Um classificador não

rígido gera assim uma imagem para cada classe, representando para cada pixel o grau de pertença à classe em questão, normalmente numa escala de 0 (sem pertença) a 1 (pertença total).

Os classificadores não rígidos usados neste estudo foram o classificador *Spectral Mixture Analysis* (SMA), considerando uma modelação linear, e o *Belclass*, ambos classificadores supervisionados disponíveis no software IDRISI.

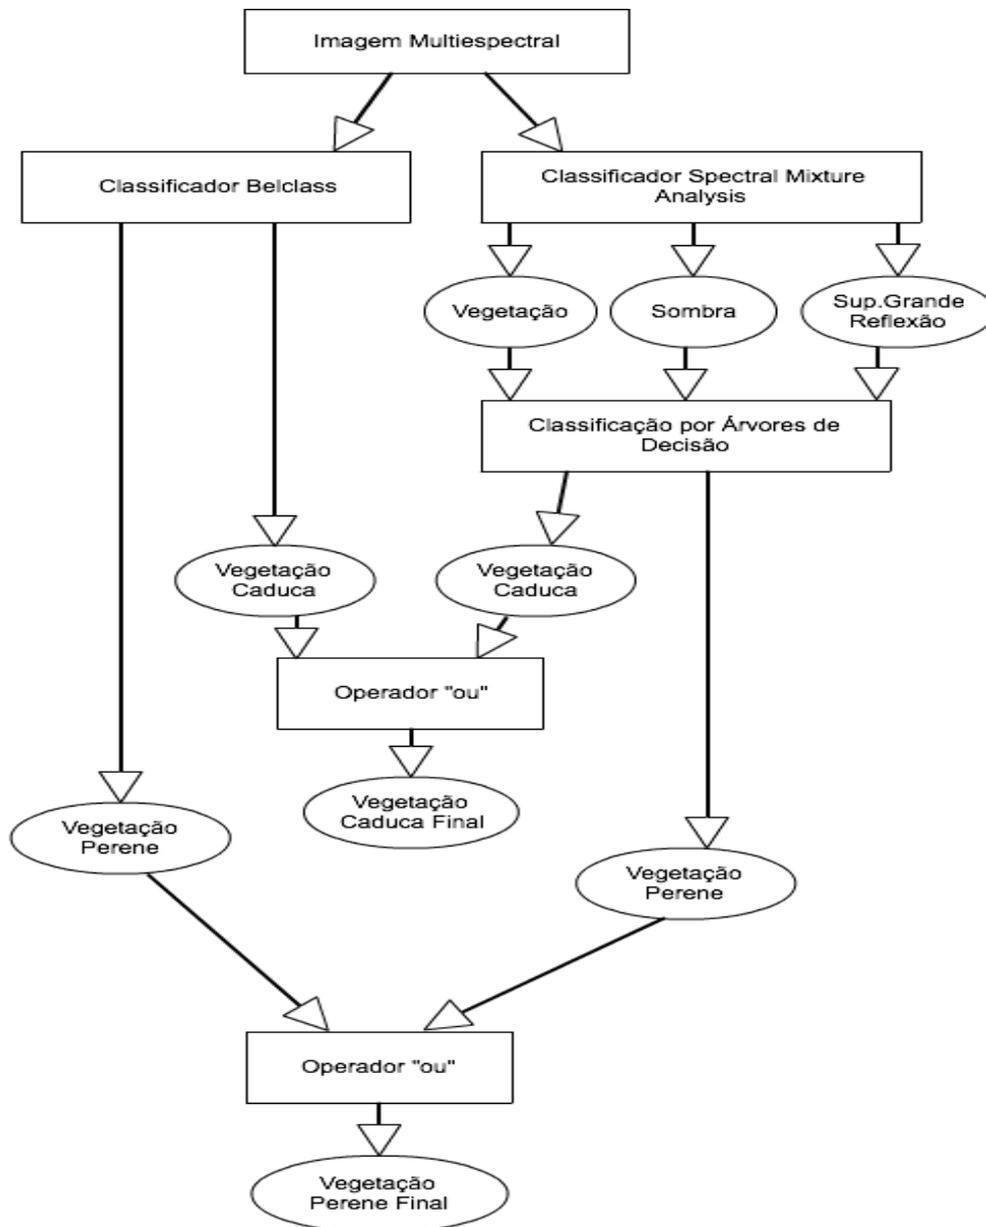


Figura 1 – Fluxograma da metodologia utilizada

### 2.1– Metodologia usando o classificador *Belclass*

Este classificador é baseado na teoria de *Dempster-Shafer* (Klir & Yuan, 1995). A utilização desta teoria permite considerar a existência de incerteza e ignorância no processo de classificação, e avaliar a crença (*belief*) ou a plausibilidade (*plausibility*) da associação de cada pixel da imagem a cada classe, usando a informação disponibilizada pelas amostras de treino. Os graus de crença traduzem em que medida a informação

disponível confirma a associação de cada pixel a cada uma das classes e os graus de plausibilidade traduzem em que medida a informação disponível não apoia a hipótese do pixel pertencer a outra classe (Eastman, 2009). Assim, quanto maiores forem os valores de crença e de plausibilidade maior será a confiança na atribuição de um pixel a uma classe. Neste trabalho foram apenas usados os valores de crença, que variam entre 0 e 1. Para obtenção de um mapa rígido, onde cada pixel é associado a uma classe, atribui-se a cada pixel a classe a que corresponde um maior valor de crença.

## **2.2 – Metodologia usando o classificador SMA e uma árvore de decisão**

Nesta metodologia podemos identificar dois passos distintos, o primeiro consiste na utilização do SMA para estimar os graus de pertença dos pixels da imagem às classes definidas como puras e no segundo a utilização de um modelo de árvores de decisão para classificar as classes temáticas pretendidas (vegetação perene e caduca) com base nos valores obtidos com o SMA.

O SMA assume que o perfil espectral de cada pixel da imagem é uma combinação do perfil espectral de cada uma das classes consideradas puras (Goodwin *et al.*, 2005). Os perfis espectrais das classes puras são obtidos através de uma amostra de treino para cada classe. O método pretende identificar a proporção de cada classe pura em cada pixel, permitindo fazer a classificação de pixels mistos. Existem várias abordagens que permitem calcular a proporção de cada classe em cada pixel, considerando, por exemplo, uma variação linear ou uma abordagem probabilística (Eastman, 2009). Neste trabalho utilizou-se o modelo de separação linear para calcular a proporção de cada classe em cada pixel, onde se considera que a combinação dos valores em cada banda é feita segundo uma variação linear. Assim, se por exemplo duas classes puras têm assinaturas em três bandas com valores de intensidade (24, 132, 86) e (56, 144, 98) respectivamente, então um pixel onde exista uma mistura de 50% de cada classe terá uma assinatura de 40, 138, 91, valores que são obtidos considerando as equações indicadas em (1).

$$0.5(24) + 0.5(56) = 40$$

$$0.5(132) + 0.5(144) = 138 \quad (1)$$

$$0.5(86) + 0.5(98) = 92$$

Da mesma forma, para um pixel com resposta espectral de, por exemplo, (32, 135, 89) a proporção de pertença à primeira classe (F1) e à segunda classe (F2) será obtida através da resolução do sistema de equações lineares indicado em (2).

$$F1(24) + F2(56) = 32$$

$$F1(132) + F2(144) = 135 \quad (2)$$

$$F1(86) + F2(98) = 89$$

Assim, teremos o número de variáveis igual ao número de classes e o número de equações igual ao número de bandas. Desta forma, para que o sistema tenha solução o número de classes não pode ser superior ao número de bandas utilizadas. Quando o

número de classes é menor que o número de bandas é possível obter valores ajustados para as variáveis.

Com esta abordagem o número de classes puras a considerar é limitado, pelo que Tooke *et al.*, (2009) propuseram a utilização de uma árvore de decisão que permita fazer a classificação de subclasses das classes puras, recorrendo a amostras de treino. Esta metodologia foi também utilizada neste trabalho, tendo-se recorrido ao software de árvores de decisão DTREG – *Predictive Modeling Software*. Quando se pretendem identificar classes de vegetação, onde o valor do índice de vegetação de diferença normalizada (NDVI) pode ser útil, este também poderá ser considerado nesta fase da classificação.

### **2.3 – Combinação dos resultados**

De modo que o resultado final tenha em consideração os resultados obtidos com as duas metodologias, fez-se a combinação dos resultados obtidos com ambas, através de uma sobreposição utilizando o operador lógico “ou”. Nos casos em que o pixel é classificado em classes de vegetação diferentes com as duas metodologias associa-se o pixel à classe a que correspondem um valor de crença mais elevado.

## **3 -Caso de estudo**

### **3.1 – Dados utilizados**

Foi utilizada uma imagem multiespectral do sensor *QuickBird* composta por quatro bandas multiespectrais (azul, verde, vermelho e infravermelho próximo), com resolução espacial de 0,6 metros (ver figura 2). A imagem, cedida pela Câmara Municipal de Coimbra, foi adquirida em Dezembro de 2004. O estudo foi feito numa zona urbana de Coimbra com uma área de aproximadamente 2,6km<sup>2</sup>.



Figura 2- Área de estudo em composição falsa RGB432

### 3.2- Classificação

Foi feita a classificação da imagem usando as metodologias indicadas na secção 2. Para aplicação do classificador *Belclass* foram consideradas as classes vegetação caduca, vegetação perene, água, sombra e substrato de grande reflexão. Para a classificação com o classificador SMA não foi possível considerar exatamente as mesmas classes pois, como se utilizou o modelo de variação linear, as classes puras a considerar têm de ser em número inferior ao número de bandas da imagem. Assim, foram consideradas as classes vegetação, sombra e substrato de grande reflexão. A escolha das classes está de acordo com trabalhos anteriores de Tooke *et al.* (2009) e Small *et al.* (2006). Para as duas últimas classes (sombra e substrato de grande reflexão) consideraram-se as mesmas amostras de treino usadas para o *Belclass*. Para a vegetação a amostra de treino consistiu na junção das amostras de treino para vegetação de folha caduca e perene usadas com o classificador *Belclass*. Não se considerou neste caso a classe água, pois não era importante para este trabalho. A aplicação das árvores de decisão foi feita usando as amostras para folha caduca e perene e o resultado obtido com o classificador SMA, o que permitiu identificar os valores de proporção das classes puras que correspondem a cada um dos tipos de vegetação de interesse. No que diz respeito à vegetação caduca, para além dos valores limiar de proporção correspondentes das classes puras do SMA obtidos pelas árvores de decisão, foram utilizados como parâmetros os valores máximos obtidos das amostras para as classes puras sombra e substrato de grande reflexão e o valor mínimo de proporção obtido para a classe pura vegetação (ver tabela 1).

Classes Puras	Vegetação Caduca		
	Proporção	Valor Max	Valor Min
Vegetação	<0.55		0.1
Sombra	>0.40	0.91	
S.G.Reflexão	>0.03	0.3	

Tabela I- Parâmetros para a classificação de vegetação caduca com a metodologia SMA mais árvores de decisão.

Para além dos valores indicados na tabela 1, foi utilizado um limiar de NDVI de 0.2. Em relação à vegetação perene, foi estimado com as árvores de decisão o limiar do valor de proporção da classe pura “superfície de grande reflexão” do SMA e foi ainda usado como parâmetro de classificação o valor mínimo da proporção obtido para a classe “vegetação” pelo SMA, pois sem este valor era incluída alguma sombra que não continha vegetação. Os valores são apresentados na tabela 2.

Classes Puras	Vegetação Perene	
	Proporção	Valor Min
Vegetação		0.04
Sombra		
S.G.Reflexão	<=0.03	

Tabela II – Parâmetros para a classificação de vegetação perene com a metodologia SMA mais árvores de decisão

No que diz respeito a metodologia do classificador *Belclass* depois da aplicação do algoritmo foi produzido um mapa temático, onde a atribuição das classes foi feita com o máximo de valor de crença para cada pixel.

### 3.3 – Resultados

Na figura 3 estão representados os graus de pertença às classes puras obtidas com o classificador SMA.

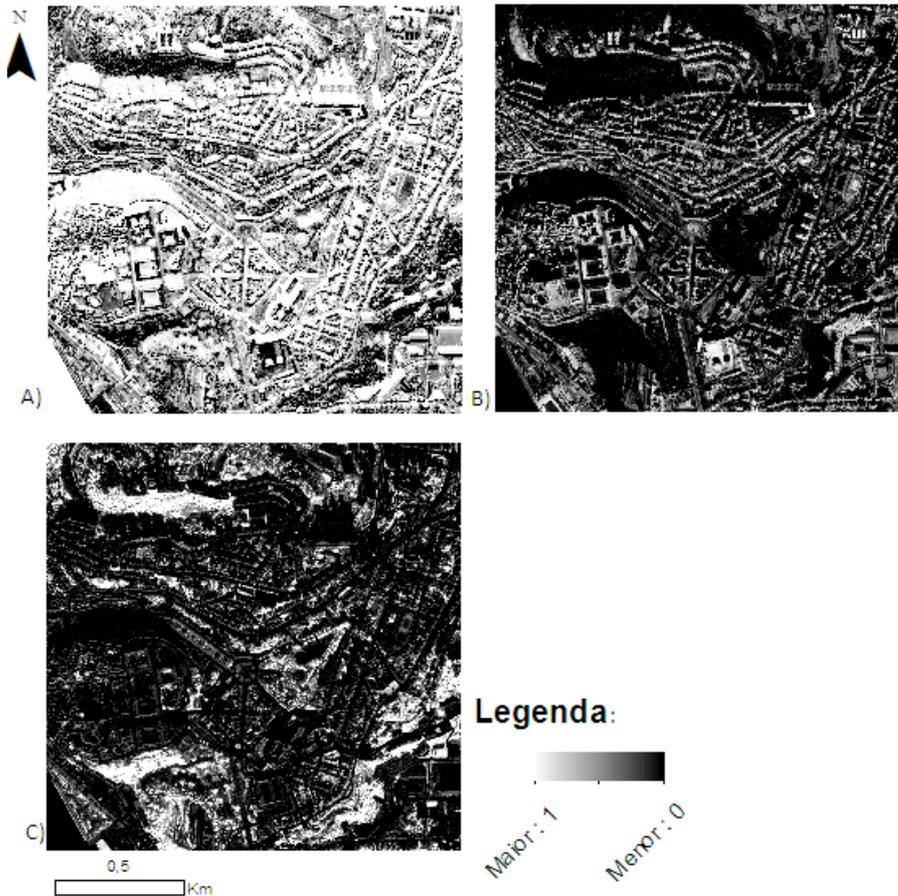


Figura 3 – Graus de pertença às classes puras obtidas do classificador SMA. A- Sombra, B- Substrato de grande reflexão e C- Vegetação

Depois de aplicadas as duas metodologias os resultados foram sobrepostos com a imagem multiespectral *QuickBird*, possibilitando assim a avaliação visual dos resultados. Nas figuras 4, 5, 6 e 7 apresentam-se os resultados obtidos para algumas zonas da área de estudo, representando-se com cores diferentes os pixéis que foram atribuídos a cada tipo de vegetação com cada um dos classificadores e com ambos, o que permite verificar que houve zonas que foram identificadas apenas por um dos classificadores.

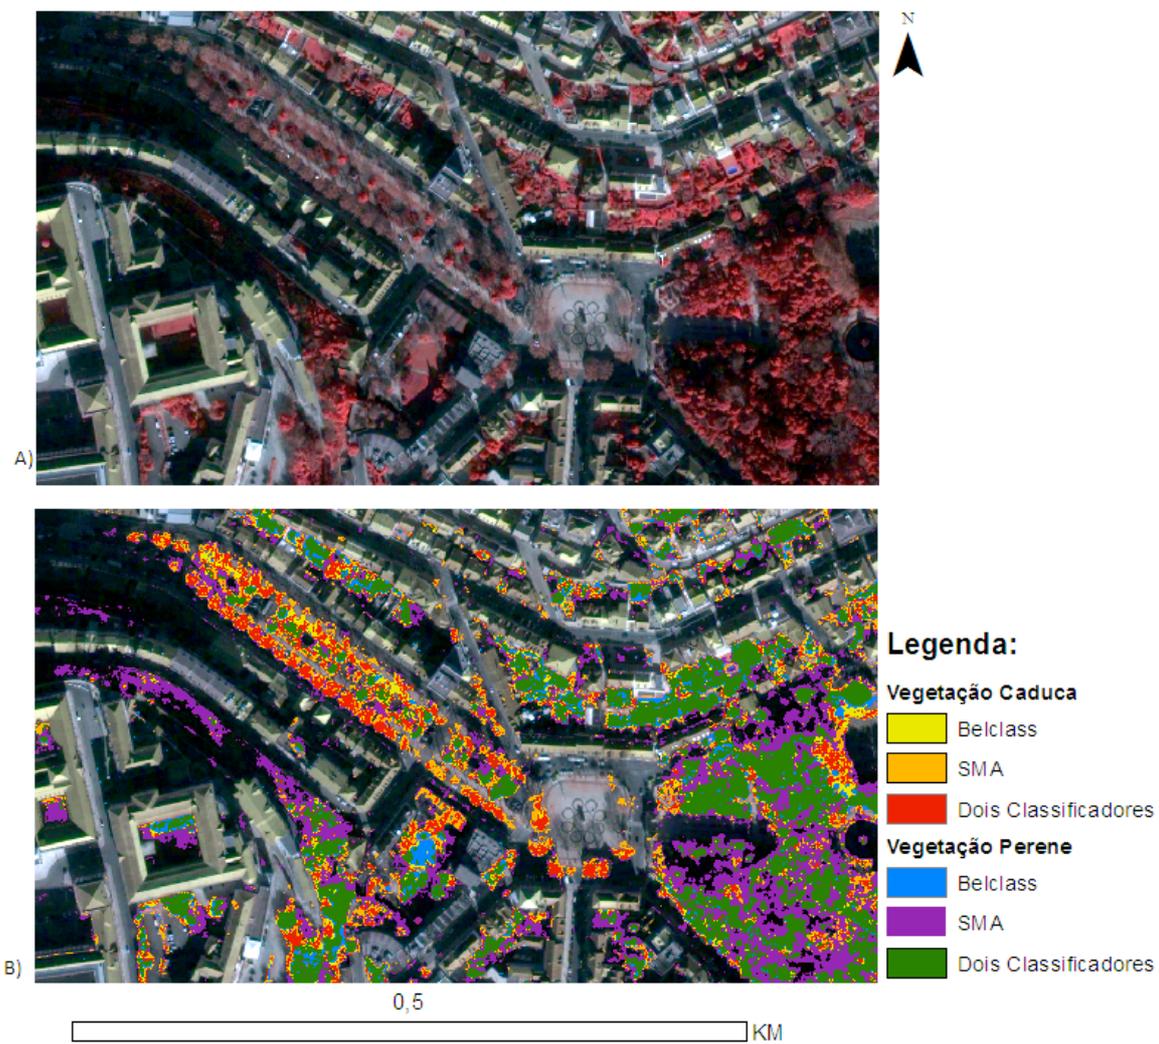


Figura 4- Detalhe mostrando os resultados obtidos na zona da Praça da Republica. A) imagem multiespectral em falsa cor (RGB 432), B) Resultados obtidos com a combinação de ambos os classificadores sobreposta com a imagem em falsa cor

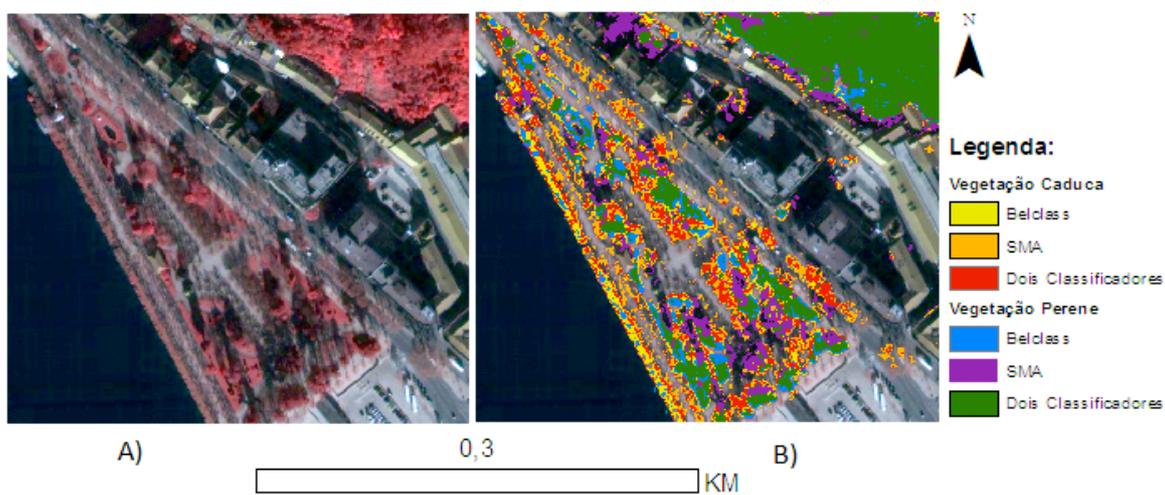


Figura 5 - Detalhe mostrando os resultados obtidos na zona do jardim Manuel Braga. A) imagem multiespectral em falsa cor (RGB 432), B) Resultados obtidos com a combinação de ambos os classificadores sobreposta com a imagem em falsa cor

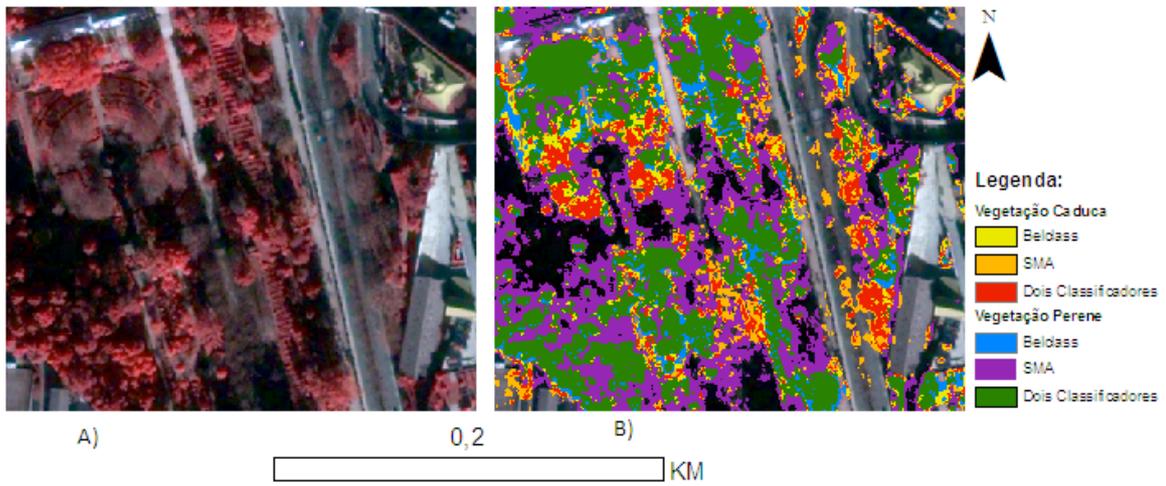


Figura 6 - Detalhe mostrando os resultados obtidos na zona do Jardim Botânico. A) imagem multiespectral em falsa cor (RGB 432), B) Resultados obtidos com a combinação de ambos os classificadores sobreposta com a imagem em falsa cor

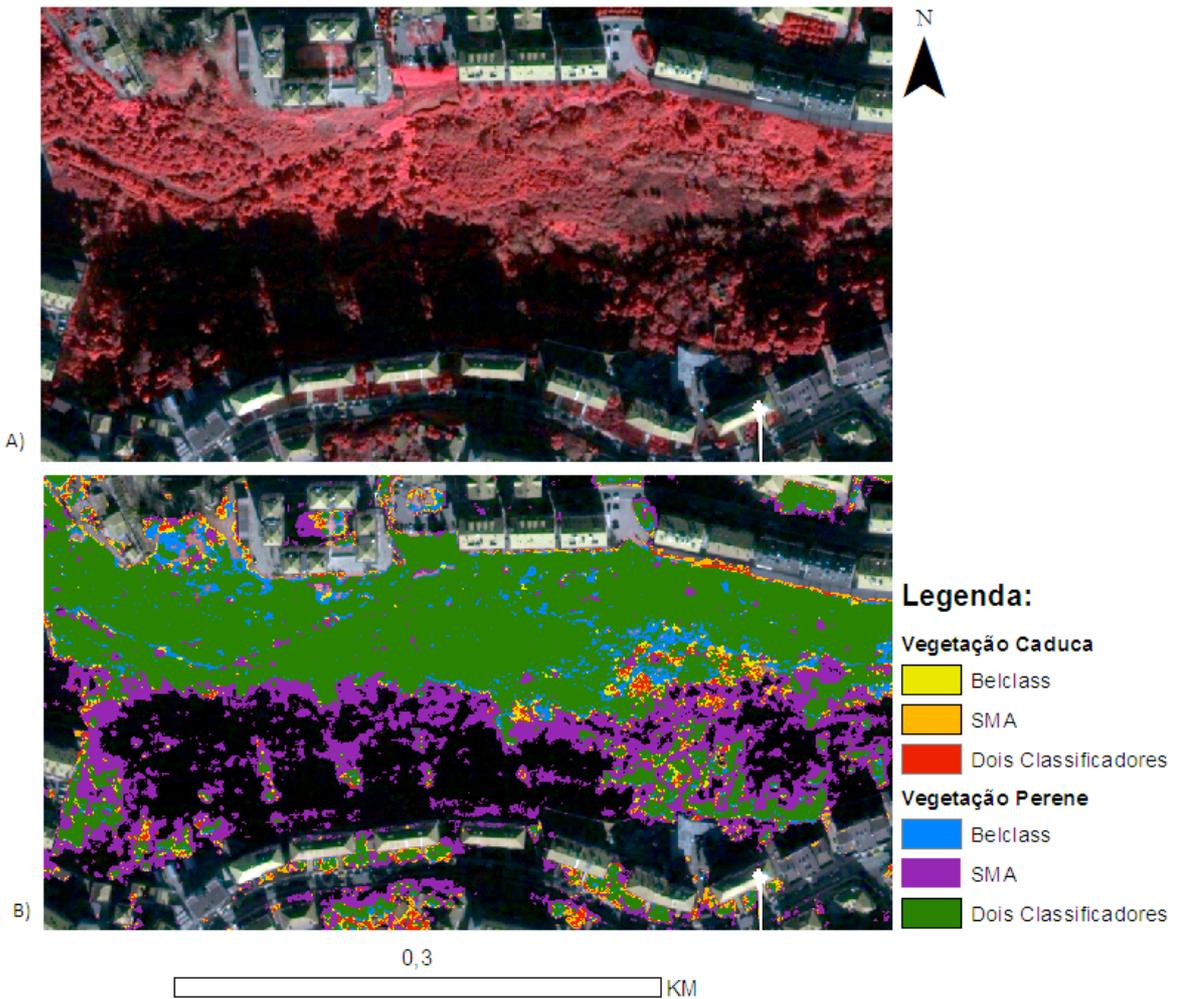


Figura 7 -Detalhe mostrando os resultados obtidos na zona fortemente afectada por sombra. A) imagem multiespectral em falsa cor (RGB 432), B) Resultados obtidos com a combinação de ambos os classificadores sobreposta com a imagem em falsa cor

Na figura 8 mostra-se o resultado final da classificação de toda área de estudo considerando a combinação de ambas as metodologias.



**Legenda:**

-  Vegetação Caduca
-  Vegetação Perene

0.7  
KM

Figura 8 – Classificação geral da área de estudo com junção dos dois classificadores através do operador lógico “ou” e o valor de maior de crença aos dois tipos de vegetação.

#### 4- Conclusões

O trabalho realizado permitiu identificar a maioria das zonas da área de estudo que têm vegetação com folha caduca e folha perene. Mostrou-se que com cada uma das duas metodologias de classificação utilizadas seria possível identificar algumas partes dessa vegetação. No entanto, utilizando apenas uma das metodologias os erros por omissão

seriam em maior número, pelo que a combinação dos resultados das duas metodologias permitiu melhorar os resultados da classificação da imagem.

Apesar de as áreas de treino usadas para as classes correspondentes serem as mesmas para as duas metodologias, estas apresentam resultados diferentes. Se por um lado o SMA consegue classificar muita informação que está na sombra, por outro lado a vegetação sob forte efeito da radiação solar não é identificada com esta abordagem. Por outro lado, o classificador *Belclass* apresenta bons resultados na distinção da vegetação de folha caduca e folha perene, mas nas zonas afetadas pela sombra este classificador não consegue identificar muita da vegetação.

O SMA é um classificador flexível do que o *Belclass*, pois a definição das classes temáticas são produzidas através de limiares das classes puras e isto deixa ao utilizador maior margem para otimizar os resultados que pretende. Contudo, pode haver a necessidade de reajustar os parâmetros utilizados no SMA para a aplicação da metodologia proposta a outra imagem multiespectral.

A conjugação das duas metodologias propostas permitiu obter bons resultados utilizando apenas uma imagem multiespectral de inverno. No seguimento do trabalho desenvolvido pretende-se ainda testar a variabilidade dos resultados obtidos com a alteração das zonas de treino, nomeadamente da classe pura “vegetação” usada na metodologia que utiliza o SMA, na tentativa de eliminar alguns problemas que persistem ainda na classificação de algumas partes da imagem. Será ainda feita uma validação dos resultados recorrendo a uma matriz de confusão construída com dados de referência recolhidos na zona de estudo, o que permitirá quantificar a exactidão obtida através do cálculo de índices de exactidão globais e por classe.

## Agradecimentos

Este trabalho foi parcialmente apoiado pelo projecto de I&D EMSURE—Energy and Mobility for Sustainable Regions (CENTRO 07 0224 FEDER 002004) e pela Fundação para a Ciência e a Tecnologia (FCT) através do projecto PEst-OE/ EEI/UI308/2014. Agradece-se também à Câmara Municipal de Coimbra a disponibilização da imagem multiespectral.

## Referências bibliográficas

Akari, Hashem et al. (2001) - “Cool surfaces and shade trees to reduce energy and improve air quality in urban areas”. **Solar energy**, Vol 70, 295 – 310.

Akari, Hashem & Konopacki. (2004)- “ Energy effects of heat-island reduction strategies in Toronto, Canada”. **Energy**, Vol 29, 191 – 210.

Almeida, Ana. (2006) - “O valor das árvores e floresta urbana de Lisboa”. Tese de Doutoramento em Arquitectura Paisagística – Instituto Superior de Agronomia .

Ardila, Juan Pablo et al. (2010) - “Context-Sensitive extraction of tree crown objects in urban areas using VHR satellite images.” **The international archives of the photogrammetry, remote sensing and spatial information sciences**, Vol. XXXVIII-4/C7.

Avissar, Roni. (1996) - “Potencial effects of vegetation on the urban thermal

environment.” **Atmospheric Environment**, Vol.30, Nº3, 437-448.

Eastman, Ronald, 2009 “**IDRISI Taiga – Guide to GIS and Image Processing**”. Clark Labs. Clark University.

Goodwin, Nicholas et al. (2005) “Assessing plantation canopy condition from airborne imagery using spectral mixture analysis and fractional abundances.” **International Journal of Applied Earth Observation and Geoinformation**, Nº 7, 11-28.

Grimmond, Sue et al. (1996) “The influence of tree cover on summertime energy balance fluxes”. **Climate research**, Vol 6, 45-57.

Klir, G., Yuan, B., 1995, **Fuzzy Sets and Fuzzy Logic-Theory and Applications**. Prentice Hall PTR, New Jersey.

Nowak, David & Crane, Dwyer. (2000) - “The urban forest effects (UFORE) model: Quantifying urban forest structure and functions.” In M.Hans e T. Burks (eds) : Integrated tools for natural resources inventories in the 21 Century, ST Paul, Minnesota, 714-720.

Small, Christopher & Lu, Jacqueline.(2006)- “Estimation and vicarious validation of urban vegetation abundance by spectral mixture analysis.” **Remote Sensing of Environment**, Vol 100, 441-456.

Sherrod, Phillip. (2008) – “DTREG Predictive Modelling Software. Users Manual” **Disponível online** no url: ( [www.dtrege.com/DTREG.pdf](http://www.dtrege.com/DTREG.pdf)) (Acedido 28 Março 2014)

Tooke, Thoreau et al. - (2009) “Assessment of Urban Tree Shade Using Fused LIDAR and High Spatial Resolution Imagery”.**Joint Urban Remote Sensing Event**. IEEE Catalog Number CFP09RSD-PRT.

Tooke, Thoreau et al. -(2009) “Extracting urban vegetation characteristics using spectral mixture analysis and decision tree classifications”. **Remote Sensing of Environment**, Vol 113, 398–407.

Yun, Zhang - (2001) “Texture-Integrated Classification of Urban Treed Areas in High-Resolution Color-Infrared Imagery”. **Photogrammetric Engineering & Remote Sensing** Vol. 67, No. 12, 1359-1365.

Zihan HONG (2009)- “Extraction of Urban Street Trees from High Resolution Remote Sensing Image”. **Joint Urban Remote Sensing Event**. IEEE Catalog Number CFP09RSD-PR