

# Cartografia das espécies florestais na região do alentejo utilizando imagens de alta resolução espacial

Ana Margarida Coelho<sup>1</sup>, Adélia M. O. Sousa<sup>2</sup>, Ana Cristina Gonçalves<sup>3</sup>

<sup>1</sup>ICT – Instituto de Ciências da Terra, Instituto de Investigação e Formação Avançada, Departamento de Engenharia Rural, Escola de Ciências e Tecnologia, Universidade de Évora, Apartado 94, Évora, Portugal, ana.coelho@uevora.pt;

<sup>2</sup>MED – Mediterranean Institute for Agriculture, Environment and Development & CHANGE – Global Change and Sustainability Institute, Laboratório de Detecção Remota (EaRSLab), Instituto de Investigação e Formação Avançada, Departamento de Engenharia Rural, Escola de Ciências e Tecnologia, Universidade de Évora, Apartado 94, 7002-544 Évora, Portugal, asousa@uevora.pt

<sup>3</sup>MED – Mediterranean Institute for Agriculture, Environment and Development & CHANGE – Global Change and Sustainability Institute, Instituto de Investigação e Formação Avançada, Departamento de Engenharia Rural, Escola de Ciências e Tecnologia, Universidade de Évora, Apartado 94, 7002-544 Évora, Portugal, acag@uevora.pt.

## RESUMO

Em Portugal a floresta ocupa 35,8% do território nacional, 23% correspondendo a espécies resinosas e 64% a folhosas. Segundo o inventário florestal nacional em 2015, das principais espécies florestais são o eucalipto (*Eucalyptus spp.*) representando 26% da ocupação, o sobreiro (*Quercus suber*) e o pinheiro bravo (*Pinus pinaster*) com 22%.

A monitorização do uso/ocupação do solo, tem um papel preponderante na gestão dos recursos naturais, no estudo das alterações climáticas, no ordenamento do território e florestal, e no desenvolvimento sustentável. Atualmente, a vasta oferta de dados obtidos por deteção remota permite a cartografia da ocupação florestal a diferentes escalas, contribuindo para a avaliação da proteção e conservação de áreas florestais, e quantificação de biomassa e carbono. Este estudo tem como objetivos a delimitação e identificação das copas por espécie florestal dominante na região do Alentejo, com base em imagens de satélite de alta resolução espacial, 0,50 m (Worldview-3), utilizando os procedimentos de segmentação multiresolução de imagem e de classificação orientada ao objeto.

Na segmentação multiresolução foram testados diferentes conjuntos de variáveis de entrada (bandas originais, bandas e índices de vegetação, componentes principais), com diferentes valores nos parâmetros de ajuste aos objetos (espectral, espacial e dimensão) de forma a isolar os diferentes objetos na imagem. Posteriormente, procedeu-se à classificação orientada a objeto, isolando as copas das árvores por espécie florestal de todas as restantes classes.

**Palavras-chave:** Segmentação Multiresolução; WorldView-3; Classificação orientada a objeto; Espécies Florestais.

## ABSTRACT

In Portugal forest occupies 35,8% of the national territory, 23% corresponding to conifers and 64% to broadleaved species. According to the national forest inventory of 2015, the main forest species are eucalyptus (*Eucalyptus spp.*) representing 26%, cork oak (*Quercus suber*) and maritime pine (*Pinus pinaster*) with 22% of the forest area.

The soil land use/cover monitoring has a pivotal role in the natural resource's management, in the climatic changes study, in the territory and forest planning and in the sustainable development. Currently, the wide range of data sets derived from remote sensing allows the cartography of forest land use at different spatial scales, contributing to the evaluation of the protection and conservation of the forest areas, and the quantification of biomass and carbon. This study objective is the delimitation and identification of the crowns per forest species in Alentejo region, based on satellite images of high spatial resolution 0,50 m (Worldview-3), using the multiresolution segmentation and object-oriented classification.

In the multiresolution segmentation several set of input variables were tested (original bands, bands, vegetation indices, principal components), with different threshold parameters values (colour, form and dimension) in order to isolate the objects in the image. After, object-oriented classification was used to isolate the tree crowns from the other classes.

**Keywords:** Multiresolution Segmentation; WorldView-3; Object-Oriented Classification; Forest Species.

## 1. INTRODUÇÃO

Em Portugal a floresta ocupa 35,8% do território nacional, 23% correspondendo a espécies resinosas e 64% a folhosas. Segundo o inventário florestal nacional em 2015, as principais espécies florestais são o eucalipto (*Eucalyptus* spp.) representando 26% da ocupação, o sobreiro (*Quercus suber*) e o pinheiro bravo (*Pinus pinaster*) com 22% (INF6, 2015). A floresta mediterrânea é conhecida pela alta heterogeneidade no espaço e no tempo em relação à composição de espécies e estrutura do povoamento. A influência antropogénica, a riqueza de espécies, o relevo e as condições climáticas criaram paisagens florestais complexas e fragmentadas, embora intercaladas com outros usos/ocupação do solo (Almeida *et al.*, 2016).

A monitorização do uso/ocupação do solo é fundamental na gestão dos recursos naturais, no estudo das alterações climáticas, no ordenamento do território e florestal, e no desenvolvimento sustentável (Gudmann *et al.*, 2020; Thenkabail, 2016). Atualmente, a elevada disponibilidade de dados obtidos por meio de deteção remota, permite a cartografia da ocupação florestal a diferentes escalas, contribuindo para a avaliação da proteção e conservação de áreas florestais, quantificação de biomassa e carbono (Isbaex & Coelho, 2019). Cartografar áreas muito heterogéneas com dados obtidos por satélites com baixa resolução espacial, tem sido uma tarefa difícil em deteção remota, especialmente à escala local, devido à configuração espacial da paisagem. Para imagens de satélite com baixa ou média resolução espacial o método mais utilizado é a classificação “pixel a pixel”, que tem em conta o valor espectral de cada pixel (Mallinis *et al.*, 2008).

Nos últimos anos, os avanços nas tecnologias, permitiram o desenvolvimento de novos satélites (WorldView, Pleiades, GeoEye, SuperView) de observação da Terra, permitindo o acesso a grandes quantidades de dados de alta resolução espacial (Belward & Skoien 2015; Hao *et al.*, 2021). O WorldView-3 é um satélite de alta resolução espacial (0,50 m) lançado em 2014, com um sistema multiespectral que, permite obter dados detalhados da superfície terrestre (Blaschke *et al.*, 2014). Para dados mais detalhados, como os fornecidos por estes satélites, é necessário o desenvolvimento de novos métodos para o seu processamento, por forma a ultrapassar os novos problemas que estes dados contêm (Ma *et al.*, 2017; Hao *et al.*, 2021). O método de classificação de imagem

com base no objeto, veio mostrar-se adequado para este tipo de dados permitindo agregar pixels com determinadas semelhanças, considerando esses conjuntos de pixels como objetos no processo de classificação de imagem (Blaschke, 2010; Blaschke *et al.*, 2014; Isnaen *et al.*, 2019). O método de segmentação multiresolução, para imagens de alta resolução espacial, permite fazer essa agregação dos pixels com base em algumas características importantes da análise da paisagem (espectral, espacial e dimensão), sendo mais apropriado para este tipo de imagens relativamente ao método “pixel a pixel” (Blaschke *et al.*, 2014; Isnaen *et al.*, 2019).


O presente estudo tem como objetivo geral a delimitação e identificação das copas por espécie florestal predominante na região do Alentejo, com base em imagens de satélite de alta resolução espacial, 0,50 m (Worldview-3), utilizando os procedimentos de segmentação multiresolução e de classificação de imagem orientada ao objeto. Na segmentação multiresolução testaram-se diferentes conjuntos de variáveis de entrada (bandas originais, em conjunto com índices de vegetação e com componentes principais), com diferentes valores nos parâmetros de ajuste aos objetos (espectral, espacial e dimensão) de forma a perceber as melhores variáveis a discriminar os objetos em estudo, as copas das espécies florestais. Posteriormente, procedeu-se à classificação de imagem orientada a objeto, para se obter a cartografia por espécie florestal.

## 2. MATERIAIS E METODOLOGIA

### 2.1 ÁREA DE ESTUDO

A área de estudo corresponde a uma área de 25 km<sup>2</sup>, localizada na região do Alentejo (Figura 1.), sul de Portugal. A região é caracterizada por um clima mediterrâneo, onde o verão é quente e seco e o inverno frio e húmido, com maiores amplitudes térmicas e intensidade no interior. O relevo é marcado por planícies, com uma elevação média de aproximadamente 200 m. No Alentejo predomina o montado, com povoamentos abertos de azinheira (*Quercus rotundifolia*) e o sobreiro (*Quercus suber*), e com menor área surge o pinheiro bravo (*Pinus pinaster*), pinheiro manso (*Pinus pinea*) e eucalipto (*Eucalyptus* spp.), quer em formações puras ou mistas (INF6, 2015).

**Figura 1** - Localização da área de estudo com imagem em composição colorida em falsa cor(RGB - V, IVP, VE)



## 2.2. DADOS DE SATÉLITE

Neste estudo foi utilizada uma imagem do satélite WorldView-3, com a data de 21 de setembro de 2020, com as bandas correspondente aos comprimentos de onda da região do espectro eletromagnético do azul (A) (491,9 nm), verde (VE) (541,1 nm), vermelho (V) (660,1nm) e infra-vermelho próximo (IVP) (824,0 nm). As bandas foram adquiridas com uma resolução espacial de 0,50 m resultante do processo de fusão com a banda pancromática. Este satélite pela sua alta resolução espacial, permite obter dados mais detalhados da superfície terrestre.

## 2.3. METODOLOGIA

### CÁLCULO DE VARIÁVEIS AUXILIARES

O primeiro procedimento baseou-se no cálculo de variáveis auxiliares a partir das bandas originais, tais como o cálculo dos índices de vegetação de diferenças normalizadas NDVI (*Normalized Diffence Vegetation Index*) (eq.1) e o ajustado ao solo SAVI (*Soil Adjusted Vegetation Index*) (eq.2), bem como as componentes principais.

Os índices de vegetação são formulações matemáticas que combinam duas ou mais bandas, essencialmente nas regiões do espectro do vermelho e do infra-vermelho, gerando uma nova imagem. Estes índices foram calculados com o objetivo de identificar e discriminar melhor os diferentes tipos de vegetação, nomeadamente as espécies florestais em estudo, contribuindo assim, para isolar as copas de todos os outros tipos de uso do solo (Fonseca & Fernandes, 2004; Marcussi *et al.*, 2010; Che *et al.*, 2019). O NDVI é um índice de vegetação muito utilizado na identificação e discriminação da vegetação, uma vez que realça as suas características, combinando a elevada reflectância na região do infra-vermelho próximo e em oposição, elevada absorção na região do vermelho (Rouse *et al.*, 1973). O SAVI é um índice também bastante utilizado, pois permite reduzir os efeitos de confusão com o solo, e áreas de vegetação menos densa (Huete, 1988).

$$NDVI = \frac{(IVP-V)}{(IVP+V)} \tag{Eq. 1}$$

$$SAVI = \frac{(IVP-V)}{(IVP+V+L)} \times (L + 1) \tag{Eq. 2}$$

Onde IVP e V, correspondem à banda do infra-vermelho próximo e vermelho, respetivamente; para a constante L foi considerado o valor 0,5.

No processo de classificação de imagem poderá existir redundância de informação, pela alta correlação existente entre as bandas originais. O método de análise de componentes principais permite reduzir a informação, eliminando a elevada correlação existente entre as bandas e gerar novas variáveis, as componentes principais (Thenkabail, 2016). Assim, foram calculadas quatro componentes principais a partir do conjunto de bandas originais disponíveis.

## SEGMENTAÇÃO MULTIRESOLUÇÃO

No método de classificação orientada ao objeto, a unidade mínima é o objeto, resultante do processo de segmentação multiresolução. O primeiro passo é a segmentação da imagem em objetos, ou seja, os pixels são agrupados considerando as suas características espectrais, espaciais e de dimensão (Ma *et al.*, 2017), representando cada grupo um objeto da superfície terrestre. Neste processo, foram considerados quatro conjuntos de dados de entrada, i) banda do infra-vermelho próximo, NDVI e segunda componente principal (IVP, NDVI, CP2); ii) a banda do infra-vermelho próximo, primeira e segunda componente principal (IVP, CP1, CP2); iii) NDVI, SAVI e segunda componente principal (NDVI, SAVI, CP2); iv) Banda do vermelho e infra-vermelho próximo e NDVI (V, IVP, NDVI). Foram considerados três parâmetros de ajuste, o pormenor espectral e espacial, e a dimensão mínima do segmento. O ajuste dos parâmetros da segmentação depende sempre de cada área de estudo. No presente estudo foram testados vários parâmetros e várias combinações entre si, por forma a obtermos o melhor ajuste dos segmentos à análise visual dos objetos na imagem.

O pormenor espectral e espacial tem um intervalo de valores entre 1 e 20. O pormenor espectral permite segmentar os objetos com base nos valores espectrais, baixo valor de detalhe espectral resulta em poucos segmentos, cada um abrangendo uma grande área. O pormenor espacial permite segmentar objetos com base na proximidade entre os objetos. Para objetos da mesma classe que estejam próximos, valores mais altos permitem identificar os dois objetos segmentando-os, para valores mais baixos permite

segmentar os objetos embora criando apenas um objeto. A dimensão mínima do segmento é indicada pelo número mínimo de pixels que cada segmento pode conter. Todos os segmentos com um número menor de pixels que o especificado, são agrupados com o segmento vizinho de melhor ajuste. Neste parâmetro não existe nenhum intervalo específico, contudo valores menores originam segmentos mais homogêneos (Visalli *et al.*, 2021).

## CLASSIFICAÇÃO ORIENTADA AO OBJETO

Com a imagem segmentada, procedeu-se ao processo de classificação orientada ao objeto. Para cada conjunto de dados de entrada foram selecionados objetos para treino aos quais foi atribuída uma classe. As classes consideradas foram oito: sobreiro, azinheira, pinheiro manso, eucalipto, água, solo, área urbana e agricultura. No processo de classificação orientada ao objeto foi utilizado o algoritmo de classificação de máxima verosimilhança, com base nas características espectrais de um conjunto de dados (quatro bandas originais, NDVI, SAVI e a primeira e segunda componente principal). O algoritmo utilizado calcula a probabilidade de um pixel pertencer a uma das classes, considerando que a média e covariância formam uma distribuição normal de um dos objetos selecionados para a classificação (Gorte *et al.*, 1999; Shine & Carr, 2002).

## AVALIAÇÃO DA PRECISÃO DA CLASSIFICAÇÃO DE IMAGEM

Por forma a avaliar a precisão dos quatro mapas de uso/ocupação do solo resultante da classificação orientada ao objeto, realizou-se uma amostragem aleatória de 50 pontos por cada classe, num total de 400 pontos, aos quais foi associada uma classe com base na análise visual da composição colorida, em cor verdadeira e falsa cor, e no basemap disponível no ARCGIS e Google Earth.

Esta informação foi comparada com os resultados das classificações da imagem através de uma matriz de confusão, do coeficiente *Kappa* (Eq. 3) e da precisão global (Eq. 4). A matriz de confusão (Congalton *et al.*, 1983, p. 1673; Stehman, 1997, p.1221) apresenta o número de pixels classificados corretamente em oposição ao número de pixels previstos para cada

classe no decorrer da classificação, avaliando assim, o grau de concordância com a realidade. A informação em linha representa a precisão do utilizador (erros de omissão), enquanto as colunas representam a precisão do produtor (erros de comissão). Um erro de comissão sucede quando os pixels são incluídos numa classe incorreta, e um erro de omissão ocorre quando os pixels são excluídos da classe a que pertencem (Fonseca & Fernandes, 2004).

A matriz de confusão permite o cálculo do coeficiente Kappa (Kappa) e da Precisão Global (PG).

$$Kappa = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} \cdot x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} \cdot x_{+i})} \times 100 \quad \text{Eq. 3}$$


$$PG = \sum_{i=1}^k \frac{N_{ii}}{N} \quad \text{Eq. 4}$$

Para os processos realizados na metodologia desenvolvida neste estudo, foram utilizadas as ferramentas do Sistemas de Informação Geográfica ARCGIS v10.8.

### 3. RESULTADOS E DISCUSSÃO

A imagem segmentada, com os objetos definidos correspondendo às copas isolados ou agregadas, pode ser analisado na figura 2, onde se ilustra para duas das espécies florestais em questão neste estudo: a) sobreiro e b) eucalipto. No processo de segmentação, os valores que melhor se ajustaram para o isolamento das copas, no pormenor espectral e espacial e na dimensão mínimo do segmento foi de 19, 10, 100 respetivamente. Em áreas menos densas (fig. 2 a)), é possível obter objetos correspondentes às copas isoladamente. Por outro lado, nas zonas de maior densidade, nos povoamentos florestais, onde as copas se tocam (fig. 2 b)) é difícil conseguir-se o isolamento de cada copa, obtendo-se a área para um conjunto de copas contíguas. Foram testados vários valores para os referidos parâmetros por forma a se obter a melhor combinação resultando na segmentação mais ajustada à imagem. Para os parâmetros de pormenor espectral e espacial (ambos podem variar entre 1 e 20) considerou-se para o primeiro um valor elevado (19) por forma a permitir a diferenciação espectral das várias classes de uso/ocupação, e para o segundo um valor médio (10) permite obter objetos de pequena dimensão, como as copas isoladas, ou objetos de maior dimensão para quando existem copas contíguas.

**Figura 2** - Ilustração do resultado do processo de segmentação multiresolução para duas espécies florestais: a) sobreiro e b) eucalipto.



Como resultado do processo de classificação orientada a objeto, utilizando o algoritmo de máxima verosimilhança e considerando os mesmos valores para os parâmetros de ajuste, obteve-se quatro mapas de uso/ocupação do solo. Numa análise comparativa entre algoritmos para uma classificação orientada ao objeto, Gibril *et al.* (2016), demonstram que o algoritmo de máxima verosimilhança é eficaz para este método de classificação utilizando imagens do satélite WorldView com um objetivo semelhante, obtendo uma precisão de 82%.

No presente estudo, os mapas foram avaliados pelo coeficiente *Kappa* e pela precisão global (tabela 1). O conjunto de variáveis que apresentaram melhor resultado foi a combinação das bandas do vermelho, infra-vermelho próximo e do NDVI com um coeficiente *Kappa* de 67% e uma precisão global de 79%. De acordo com Landiz & Koch (1977), que desenvolveram uma tabela qualitativa para os intervalos de valores do coeficiente *Kappa*, onde os valores obtidos neste estudo, são bons (coef. *kappa* entre 41- 60%) para as classificações resultantes dos conjuntos de variáveis IVP, CP1, CP2 e IVP, NDVI, CP2, e muito bons (coef. *kappa* entre 0,61- 0,80%) para NDVI, SAVI, CP2 e V, IVP, NDVI. Tal como o trabalho realizado por Sousa *et al.* (2010), num estudo semelhante utilizando imagens de alta resolução, do satélite Quickbird, considerando apenas 3 classes de uso/ocupação do solo, os resultados de validação foram superiores ao do presente estudo. Este facto deve-se à nossa área de estudo

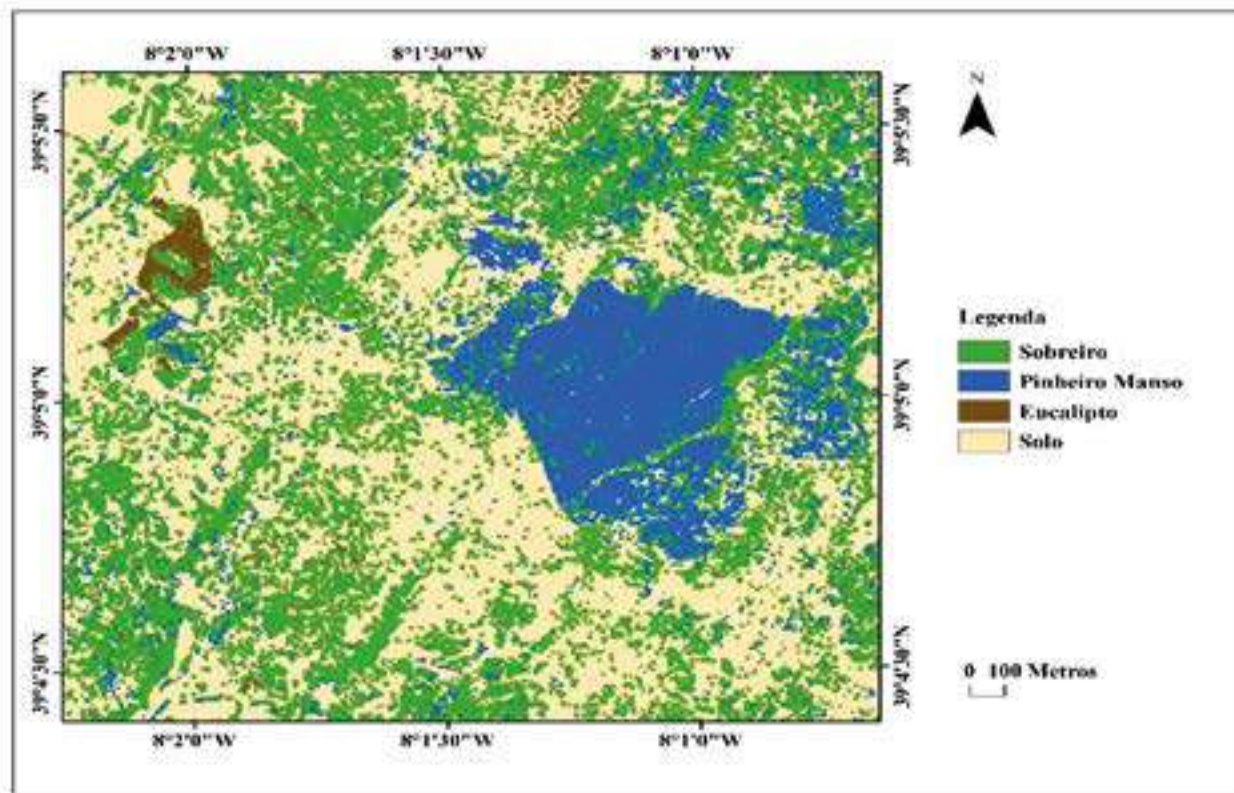
apresentar maior complexidade, devido à elevada variação espectral derivada da presença de várias classes de uso do solo e à variação espacial, decorrente da dimensão dos objetos. Tal como neste estudo, verificou-se alguns erros na bordadura das copas das árvores, que podem estar relacionados com as características irregulares das copas de cada espécie florestal, devido à sua forma, textura e iluminação.

Analisando os resultados de cada classificação, verifica-se que a precisão aumentou com a introdução dos índices de vegetação (NDVI e SAVI) no entanto verifica-se que a maior contribuição foi das bandas originais vermelho e infra-vermelho próximo em combinação com o NDVI. Também se verificou que as componentes principais não contribuíram de forma relevante para os bons resultados. Na figura 3 ilustra-se o resultado da classificação orientada ao objeto para o conjunto de variáveis 4 com os quais se obteve o melhor coeficiente *kappa* e precisão global.

**Figura 3** - Avaliação da classificação orientada ao objeto, coeficiente kappa e precisão global para os quatro conjuntos de variáveis testados.

N	Variáveis de entrada	Segmentação			Classificação	
		Pormenor Espetral	Pormenor Espacial	Tamanho Segmento	Coeficiente <i>Kappa</i>	Precisão Global
1	IVP, CP1, CP2				54%	69%
2	IVP, NDVI, CP2				58%	73%
3	NDVI, SAVI, CP2	19	10	100	64%	77%
4	V, IVP, NDVI				67%	79%

**Figura 4** - Ilustração do resultado do processo de classificação de imagem orientada ao objeto para o conjunto de variáveis 4.



#### 4. CONCLUSÕES

As mudanças que ocorrem ao longo do tempo na superfície terrestre, cada vez mais rápidas, torna importante estudos que permitam a obtenção de cartografia do uso/ocupação solo de forma precisa. Os dados de deteção remota têm um forte contributo, para a deteção, identificação e delimitação das espécies florestais. Estes dados são uma mais valia na obtenção de dados de inventário florestal, na gestão de povoamentos florestais e estimativa de biomassa e de carbono. Neste estudo foi possível identificar e delimitar as copas das espécies florestais presentes na imagem, através das ferramentas de segmentação e de classificação orientada ao objeto do programa ARCGIS v10.8. O processo de segmentação, com imagens de alta resolução, torna possível um ajuste detalhado aos objetos na superfície.

A classificação orientada ao objeto com imagens do satélite WorldView-3 permitiu obter resultados satisfatórios na identificação das espécies florestais. O classificador de máxima verosimilhança, a combinação das bandas originais e dos índices de vegetação,

realçando o NDVI, permitiu obter mapas de uso/ocupação do solo, com uma boa precisão global de 77% e 79%. Os valores de refletância de cada classe obtidos da seleção de objetos para o treino do classificador permitiu discriminar de forma satisfatória, a maioria das classes identificadas. A data de aquisição da imagem, correspondente à estação seca, permite estabelecer um maior contraste entre as espécies florestais e as restantes classes, diminuindo alguma confusão com vegetação arbustiva e com o solo. Existindo ainda assim alguns erros resultantes devido a similaridade espectral de algumas espécies florestais (e.g sobreiro vs azinheira), características das copas e também devido à presença de sombra junto às copas.

Na continuação e aperfeiçoamento desta metodologia, seria importante utilizar mais bandas espectrais, contribuindo assim com mais informação espectral para melhor definição dos objetos e identificação das classes no processo de classificação das espécies florestais.

## AGRADECIMENTOS

O trabalho foi apoiado pelo Programa Operativo de Cooperação Transfronteiriço Espanha-Portugal (POCTEP); projeto CILIFO – Centro Ibérico la Investigación y Lucha contra Incendios Forestales

e pela FCT, Portugal, Fundação para a Ciência e Tecnologia, através do IDMEC, no âmbito do LAETA, projeto UIDB/05183/2020.

## REFERÊNCIAS BIBLIOGRÁFICAS

- Alrassi, F., Salim, E., Nina, A., Alwi, L., Danoedoro, P., & Kamal, M. (2016, November). GEOBIA For Land Use Mapping Using Worldview2 Image In Bengkak Village Coastal, Banyuwangi Regency, East Java. In *IOP Conference Series: Earth and Environmental Science* (Vol. 47, No. 1, p. 012009). IOP Publishing.
- Baatz, M., Schäpe, M., 2000. Multiresolution segmentation — na optimization approach for high quality multi-scale image segmentation. In: Strobl, J., Blaschke, T., Griesebner, G. (Eds.), *Angewandte Geographische Informations-Verarbeitung XII*. Wichmann Verlag, Karlsruhe, pp. 12–23.
- Belward, A. S., & Skøien, J. O. (2015). Who launched what, when and why; trends in global land-cover observation capacity from civilian earth observation satellites. *ISPRS Journal of Photogrammetry and Remote Sensing*, 103, 115-128.
- Blaschke, T. (2010). Object based image analysis for remote sensing. *ISPRS journal of photogrammetry remote sensing*, 65(1), 2-16.
- Blaschke, T., Hay, G. J., Kelly, M., Lang, S., Hofmann, P., Addink, E., ... & Tiede, D. (2014). Geographic object-based image analysis—towards a new paradigm. *ISPRS journal of photogrammetry and remote sensing*, 87, 180-191.
- Chen, L., Wang, Y., Ren, C., Zhang, B., & Wang, Z. (2019). Assessment of Multi-Wavelength SAR and Multispectral Instrument Data for Forest Aboveground Biomass Mapping Using Random Forest Kriging. *Forest Ecology and Management*, 447, 12–25. <https://doi.org/10.1016/j.foreco.2019.05.057>.
- Congalton, R. G., Oderwald, R. G., & Mead, R. A. (1983). Assessing Landsat classification accuracy using discrete multivariate analysis statistical techniques. *Photogrammetric engineering and remote sensing*, 49(12), 1671-1678.
- Dorren, L. K. A., Maier, B. and Seijmonsbergen, A. C. 2003. Improved Landsat-based forest mapping in steep mountainous terrain using object-based classification. *Forest Ecology and Management* 183: 31– 4.
- Fonseca, A. D., & Fernandes, J. C. (2004). *Deteção Remota* (LIDEL).
- Gibril, M. B. A., Shafri, H. Z., & Hamedianfar, A. (2017). New semi-automated mapping of asbestos cement roofs using rule-based object-based image analysis and Taguchi optimization technique from WorldView-2 images. *International Journal of Remote Sensing*, 38(2), 467-491.
- Gorte, B. (1999). Supervised image classification. In *Spatial statistics for remote sensing* (pp. 153-163). Springer, Dordrecht.
- Gudmann, A., Csikós, N., Szilassi, P., & Mucsi, L. (2020). Improvement in Satellite Image-Based Land Cover Classification with Landscape Metrics. *Remote Sensing*, 12(3580), 1–19. <https://doi.org/10.3390/rs12213580>.
- Hao, S., Cui, Y., & Wang, J. (2021). Segmentation Scale Effect Analysis in the Object-Oriented Method of High-Spatial-Resolution Image Classification. *Sensors*, 21(23), 7935.
- Huete, A. R. (1988). A soil-adjusted vegetation index (SAVI). *Remote sensing of environment*, 25(3), 295-309.
- ICNF.(2015). Inventário Nacional 6.
- Isbaex, C., & Coelho, A. (2019). The Potential of Sentinel-2 Satellite Images for Land-Cover/Land-Use and Forest Biomass Estimation: A Review. Em *Forest Biomass - From Trees to Energy*. <https://doi.org/10.5772/intechopen.93363>.
- Isnaen, Z., Utari, D., Ramadhan, A. F., Putri, R. C., Kusuma, D. W., & Kamal, M. (2019, July). Comparison of Mangrove and Other Objects Spectral Reflectance from Small Format Aerial Photography Image, WorldView-2 Image, and Field Measurement. In *2019 5th International Conference on Science and Technology (ICST)* (Vol. 1, pp. 1-5). IEEE.



- Landis, J. R., & Koch, G. G. (1977). The measurement of observer agreement for categorical data. *biometrics*, 159-174.
- Ma, L., Li, M., Ma, X., Cheng, L., Du, P., & Liu, Y. (2017). A review of supervised object-based land-cover image classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 130, 277-293.
- Mallinis, G., Koutsias, N., Tsakiri-Strati, M., & Karteris, M. (2008). Object-based classification using Quickbird imagery for delineating forest vegetation polygons in a Mediterranean test site. *ISPRS Journal of Photogrammetry and Remote Sensing*, 63(2), 237-250.
- Marcussi, A. B., Bueno, C. R. P., Miqueloni, D. P., & Arraes, C. L. (2010). Utilização de Índices de Vegetação para os Sistemas de Informação Geográfica. *Caminhos de Geografia*, 11(35), 41-53.
- Meyer, L. H., Heurich, M., Beudert, B., Premier, J., & Pflugmacher, D. (2019). Comparison of Landsat-8 and Sentinel-2 data for Estimation of Leaf Area Index in Temperate Forests. *Remote Sensing*, 11(10), 1-6. <https://doi.org/10.3390/rs11101160>.
- Rouse Jr, J. W., Haas, R. H., Schell, J. A., & Deering, D. W. (1973). *Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation* (No. NASA-CR-132982).
- Shine, James A., and Daniel B. Carr. "A Comparison of Classification Methods for Large Imagery Data Sets." *JSM* (2002): 3205-3207.
- Sousa, A., Mesquita, P., Gonçalves, A. C., & Marques da Silva, J. R. (2010). Segmentação e classificação de tipologias florestais a partir de imagens Quickbird. *IX Seminário de Atualização em Sensoriamento Remoto e Sistemas de Informações Geográficas Aplicados à Engenharia Florestal, Curitiba, Paraná (Brasil)*, 19-21.
- Stehman, S. (1996). Estimating the kappa coefficient and its variance under stratified random sampling. *Photogrammetric Engineering and Remote Sensing*, 62(4), 401-407.
- Thenkabail, P. S. (2016). Remotely Sensed Data Characterization, Classification, and Accuracies. Em L. Taylor & Francis Group (Ed.), *Remote Sensing Handbook* (Vol. 1). <https://doi.org/10.1201/b19294>.
- Visalli, R., Ortolano, G., Godard, G., & Cirrincione, R. (2021). Micro-Fabric Analyzer (MFA): A new semiautomated ArcGIS-based edge detector for quantitative microstructural analysis of rock thin-sections. *ISPRS International Journal of Geo-Information*, 10(2), 51.