

## Mapeamento de *Hakea Sericea* com Sentinel-2

Alain M. ALVES<sup>1</sup>, Luísa GONÇALVES<sup>2,3</sup>

<sup>1</sup> Instituto Politécnico de Tomar, Escola Superior de Tecnologia (Portugal)

<sup>2</sup> Câmara Municipal de Leiria, Leiria (Portugal)

<sup>3</sup> INESC Coimbra (Portugal)

([alainmartinsalves@gmail.com](mailto:alainmartinsalves@gmail.com), [lgoncalves@cm-leiria.pt](mailto:lgoncalves@cm-leiria.pt))

**Palavras-chave:** Incêndios, Espécie Invasora, *Hakea Sericea*, Mapeamento, Sentinel-2.

**Resumo:** O efeito das alterações climáticas, traduz-se num aumento de fenómenos meteorológicos extremos, que se refletem no surgimento, cada vez mais frequente, de condições propícias para o aparecimento de incêndios, resultando numa alteração do território e dos ecossistemas nele existentes. O trabalho desenvolvido visa explorar o potencial das imagens multiespectrais de grande resolução espacial, no mapeamento da espécie invasora *Hakea Sericea* no concelho de Mação, que tem sido, desde o ano de 2000, fustigada com incêndios de grande dimensão. Esta espécie, é caracterizada por apresentar mecanismos de sobrevivência e de disseminação de sementes eficazes contra incêndios, resultando numa expansão territorial entre ciclos de acontecimentos, modificando a paisagem, a erosão dos solos e biodiversidade existente.

No presente trabalho, foram utilizadas imagens multiespectrais (MSI) do Sentinel-2, com uma resolução espacial de 10m. Para o mapeamento da espécie invasora *Hakea Sericea*, foram utilizados classificadores não rígidos Bayclass e o MLP (*multi-layer perceptron*), aplicados a grupos de bandas distintos para avaliar que conjunto de bandas permite uma melhor identificação e quantificação desta espécie invasora.

A aplicação deste tipo de imagens e seus produtos derivados, surgem como uma ferramenta fulcral para auxiliar a deteção e quantificação desta espécie, possibilitando a adoção de medidas efetivas e exequíveis nos domínios do controlo da espécie invasora, gestão e planeamento do território.

## 1. Introdução

Os desenvolvimentos ocorridos nas últimas décadas, na área da informação e tecnologia, encaminham a informação geoespacial para um patamar onde esta se tornou numa ferramenta indispensável em questões de planeamento e gestão do território, afirmando o seu papel no desempenho efetivo de respostas a problemas sociais, tecnológicos e ambientais a uma escala global.

Nesse sentido, é pertinente destacar a importância da deteção remota e do desenvolvimento de metodologias e processos de extração de informação, na análise dos efeitos resultantes das alterações climáticas, contribuindo para a sua mitigação.

Uma das grandes problemáticas relacionadas com as alterações climáticas, consiste no desenvolvimento de condições climáticas propícias ao aparecimento de um número cada vez mais preocupante de incêndios de dimensões elevadas, resultando na alteração do território e ecossistemas, com consequências ao nível de espécies invasoras que, devido às suas características particulares (Alvarez-Taboada, Paredes, and Julián-Pelaz 2017), iniciam um domínio sobre as restantes espécies num período pós-incêndio, alterando profundamente a biodiversidade e o território.

Desde o ano de 2003, que o concelho de Mação tem sido fustigado com grandes incêndios, tendo-se verificado um crescimento exponencial da espécie *Hakea Sericea* devido às suas particularidades únicas de resistência ao fogo e processo de dispersão de sementes (Alvarez-Taboada et al. 2017). Segundo dados do ICNF o concelho de Mação sofreu em 2017 uma área ardida correspondente a 2/3 da sua área total, sendo desse modo expectável que nos próximos anos, se verifique um crescimento ainda mais acentuado da espécie.

O estudo das potencialidades do sensor MSI do Sentinel-2 tem sido testadas em trabalhos de identificação de espécies, nomeadamente com árvores e plantações tal como evidenciado por Immitzer, Vuolo e Atzberger (Immitzer, Vuolo, and Atzberger 2016). Ng et al. (Ng et al. 2017) constataram que a qualidade das imagens disponibilizadas pelos sensores do Sentinel-2, quando comparada com o seu valor de aquisição em relação a outros sensores cujas imagens não podem ser acedidas de modo gratuito, nomeadamente o Pléiades, evidencia viabilidade na sua utilização, apresentando níveis de eficácia e classificação plausíveis para a deteção das espécies *Prosopis* e *Vachellia*, no Quênia.

Deste modo, o presente trabalho teve como objetivos principais a utilização de imagens multiespectrais do Sentinel-2 para testar classificações com base numa abordagem ao nível do pixel, determinar a influência da incorporação de grupos de bandas distintas nos resultados dos classificadores, efetuar a avaliação dos classificadores e por fim avaliar a viabilidade dos resultados obtidos e a sua pertinência no desenvolvimento de metodologias para auxiliar a identificação e quantificação de espécies invasoras.

## 2. Área de estudo

A área de estudo abrange a extensão total do concelho de Mação (figura 1), pertencente ao distrito de Santarém, Portugal. Segundo dados da Carta de Uso e Ocupação do Solo de 2015 (COS2015), a área é composta maioritariamente por zonas extensas de matos, densos povoamentos de pinheiro bravo e povoamentos de eucalipto, verificando-se apenas a existência de cursos de água de dimensão considerável a sul do concelho (rio Tejo) e a Este (ribeira do Ocreza).

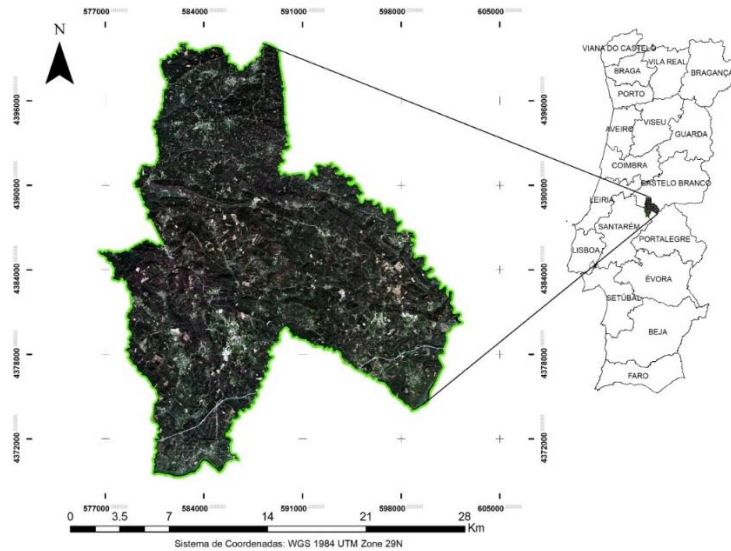


Figura 1 - A área de estudo compreende a extensão total do concelho de Mação, localizada no distrito de Santarém.

## 3. Materiais e Métodos

### 3.1 Dados

Foi utilizada uma imagem multiespectrais proveniente do Sentinel-2, obtidas a 5 de abril de 2017. A data escolhida deveu-se ao facto de possibilitar acentuar a diferenciação entre espécies, sendo que a *Hakea Sericea* tem o seu período de floração mais cedo (Alvarez-Taboada et al. 2017).

O conjunto de dados inicialmente descarregado encontrava-se no nível 1C, tendo sido utilizado o plugin Sen2Cor (*third party*) para efetuar os processamentos e respetivas correções atmosféricas, gerando um produto de nível 2A.

O quadro 1 refere as características das bandas utilizadas no trabalho, nomeadamente a resolução espectral e resolução espacial, sendo que o valor de resolução radiométrica era comum entre todas, 12bits.

Quadro 1- Bandas utilizadas e suas características

Nº de banda	2	3	4	5	6	7	8	8A	11	12
Comprimento médio de onda (nm)	496.6	560.0	664.5	703.9	740.2	782.5	835.1	864.8	1613.7	2202.4
Resolução espacial (m)	10	10	10	20	20	10	10	20	20	20

### 3.2 Métodos

A metodologia de trabalho foi dividida em 3 fases, tal como evidenciado pela figura 2, compreendendo as fases de “Pré-processamento”, “Classificação” e “Validação”.

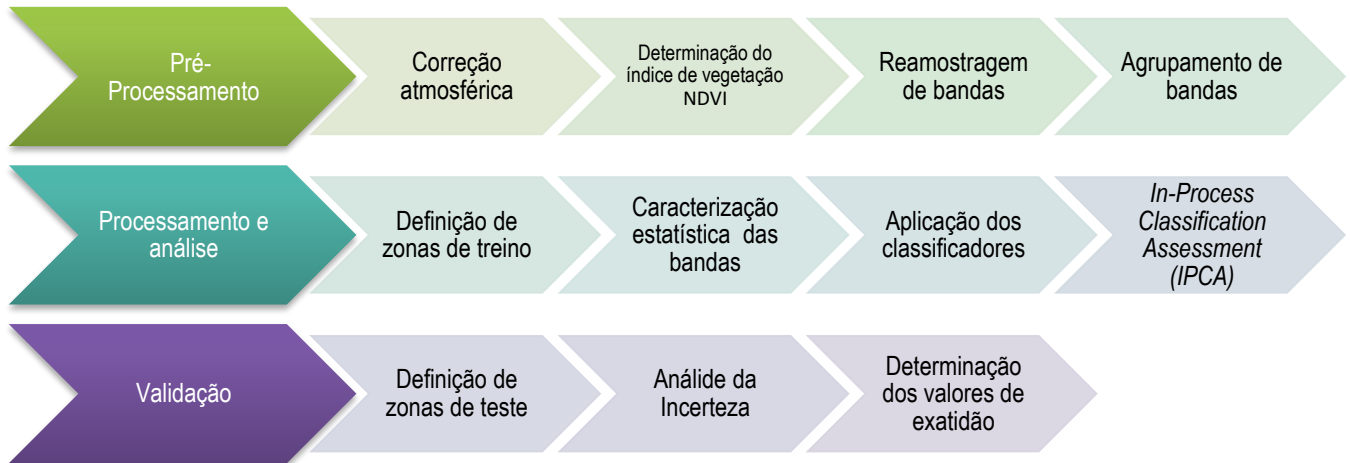


Figura 2 - Resumo da metodologia aplicada ao trabalho

#### 3.2.1 Pré-Processamento

As imagens de Sentinel-2 foram corrigidas atmosféricamente e transformadas para o nível 2A, tendo sido utilizado o plugin Sens2Cor do programa SNAP (Gascon and Ramoino 2017) da ESA (Agência Espacial Europeia), posteriormente foram exportadas para o software TerrSet versão 18.21. Foi calculado o Índice de Vegetação por Diferença Normalizada (NDVI) de forma a aumentar a abrangência espectral, tendo sido utilizadas as bandas 4 (vermelho) e 8 (Near Infra Red), com resolução espacial de 10m.

As bandas 5,6,7,8A, 11 e 12, com uma resolução espacial de 20m, foram reamostrados para 10m, permitindo a criação de dois grupos de bandas, tal como evidenciado pelo quadro 2. Este processo permitiu averiguar a influência dos diferentes grupos de bandas no processo de classificação.

Quadro 2 - Grupos de Bandas utilizadas no processo de classificação

Grupo	Bandas
G1	B2+B3+B4+B8+NDVI
G2	B2+B3+B4+B5+B6+B7+B8+B8A+B11+B12+NDVI

### 3.2.2 Processamento e análise (Classificação)

Os classificadores aplicados no presente trabalho baseiam-se numa abordagem ao nível do pixel. Foi escolhido o processo de classificação supervisionada e obtidas descrições estatísticas em relação às classes de ocupação expectáveis no resultado final da imagem. A primeira abordagem realizada no processo de classificação foi a da definição das áreas que seriam utilizadas como amostras de treino para cada classe de ocupação, quadro 3. Ao total de 711 amostras obtidas, foi designada uma percentagem de 50% para treino e os restantes 50% para teste.

Quadro 3 - Classes de ocupação, designação e elementos incluídos

Designação	Elementos de ocupação
Artificiais	Estradas, habitações e solo não ocupado
Água	Rios, barragens e outros planos de água
Vegetação	Matos e vegetação rasteira
Floresta	Povoamentos variados, contendo pinheiro-bravo e eucalipto
Hakea	Povoamento de <i>Hakea Sericea</i>

Foi aplicado o classificador não rígido *Bayclass* (Eastman 2015), baseando-se na teoria probabilística Bayesiana. Este classificador usa a média e a variância/covariância das assinaturas espectrais para estimar a probabilidade de cada pixel pertencer a cada classe.

Este classificador, permite obter o grau de probabilidade com que cada pixel é atribuído ao conjunto identificado pela assinatura e permitindo gerar, por sua vez, uma imagem que manifesta o grau de incerteza da classificação sobre a atribuição da classe a cada um dos pixels. Foi também obtida a respetiva classificação rígida, designada neste estudo por *Maxlike*, para permitir a avaliação da exatidão utilizando índices estatísticos. O outro classificador aplicado foi o *MLP* (*multi-layer perceptron* (Eastman 2015)), baseado em redes neuronais, que possibilitou também a obtenção de classificações rígidas e não rígidas.

Através dos dados obtidos pelos classificadores não rígidos foi aplicada uma medida de incerteza, possibilitando obter os valores médios da incerteza para cada classe.

Os dados resultantes permitem efetuar uma avaliação intermédia dos mesmos, baseando-se no valor da incerteza atribuída a cada classe pelo classificador, possibilitando no caso de existir necessidade, escolher o grupo de bandas mais adequado. No estudo, a incerteza foi obtida aplicando a seguinte medida de incerteza.

Equação 1 - Medida de incerteza

$$E = 1 - p(x_1)$$

Em que  $p(x_1)$  representa no classificador *MPL*, o nível de ativação com que cada pixel foi atribuído a uma determinada classe e no caso do classificador *Bayclass* representa o grau de probabilidade com que cada pixel foi atribuído a cada classe.



### 3.2.3 Avaliação da Exatidão

A avaliação da exatidão foi realizada através de índices estatísticos tendo sido utilizada uma amostra aleatória estratificada composta por um total de 711 amostras de áreas de teste (50% do total da amostragem), gerando uma matriz de confusão que possibilitou o cálculo da exatidão do produtor (EP), exatidão do utilizador (EU) e a exatidão global (EG).

## 4. Resultados

A avaliação intermédia dos resultados obtidos com o classificador Bayclass evidenciam que a classe “Hakea” apresentou os valores mais elevados de incerteza na atribuição de classe, independentemente do grupo de bandas analisado. Com as imagens do grupo “2” obtiveram-se os níveis de incerteza mais baixos na generalidade dos resultados, sendo apenas exceção a classe “Água”. Com as imagens do grupo “1” obteve-se uma variação mais acentuada de valores de incerteza para as classes de “Vegetação” e “Floresta” em comparação com o grupo “2”.

O classificador MLP aplicado às imagens do grupo “2” foi o que apresentou os valores de incerteza mais elevados, em todas as classes analisadas. É de salientar que não é possível efetuar uma comparação direta entre os valores apresentados nas figuras 3 e 4, pois foram aplicadas metodologias diferentes para a obtenção do valor de incerteza e os classificadores utilizam algoritmos diferentes para a obtenção das classificações.




Figura 3 - Valor médio da incerteza com o Bayclass, classificador não rígido

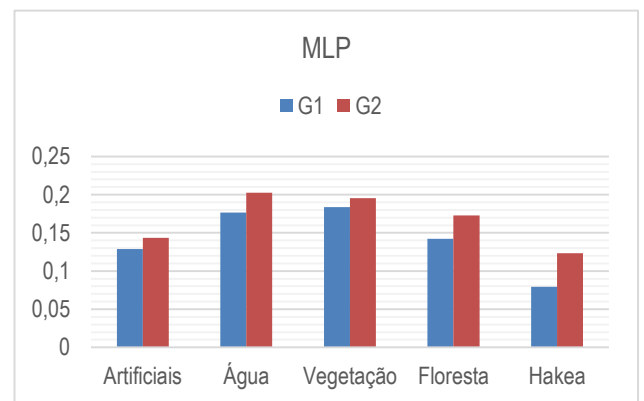


Figura 4 - Valor médio da incerteza com o MLP, classificador não rígido

O valor da exatidão do produtor, figura 5 e o valor da exatidão do utilizador, figura 6, evidenciam que a classe “Hakea” é a que apresenta valores mais baixos. A classe “Vegetação” foi a que apresentou melhores valores de exatidão do produtor e de utilizador, independentemente do classificador aplicado e do grupo de bandas utilizado.




Figura 5 - Exatidão do produtor (EP)

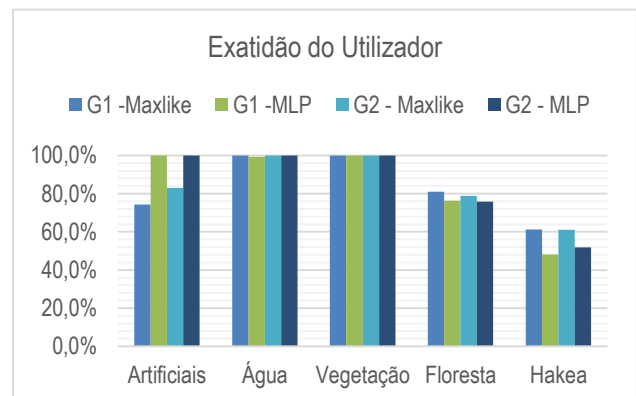


Figura 6 - Exatidão do utilizador (EU)

Analisando o quadro 4 é possível verificar os valores de exatidão global obtidos. A aplicação do classificador MLP ao grupo de bandas “2” registou o valor mais elevado de exatidão global, 90.2%, por sua vez a classificação através do Maxlike ao grupo de bandas “1” registou o valor de exatidão global mais baixo, 84.1%.

Quadro 4 - Resultados das exatidões dos classificadores, G1 e G2

Classificador	Classe	G1		Exatidão Global		G2		Classe	Classificador
		EP	EU	G1	G2	EP	EU		
Maxlike	Artificiais	98.1%	74.3%	84.1%	86.9%	100.0%	83.1%	Artificiais	Maxlike
	Água	65.8%	100.0%			79.5%	100.0%	Água	
	Vegetação	100.0%	100.0%			100.0%	100.0%	Vegetação	
	Floresta	87.3%	81.0%			87.3%	78.8%	Floresta	
	Hakea	52.8%	61.3%			45.8%	61.1%	Hakea	
MLP	Artificiais	95.1%	100.0%	89.5%	90.2%	100.0%	100.0%	Artificiais	MLP
	Água	100.0%	99.4%			100.0%	100.0%	Água	
	Vegetação	99.3%	100.0%			100.0%	100.0%	Vegetação	
	Floresta	87.3%	76.3%			84.9%	75.8%	Floresta	
	Hakea	37.5%	48.2%			37.5%	51.9%	Hakea	

A análise evidenciou ainda que, em relação às classes “Hakea”, os valores mais elevados foram obtidos com o classificador Maxlike em ambos os grupos de bandas onde foi aplicado, na figura 7 apresenta-se um excerto dos mapas produzidos.

Verificou-se um valor anormal na classe “Água”, do G1 através do classificador Maxlike (65.8%), devido à semelhança de valores de pixel entre essa classe e a classe “artificial”, bem como a própria base algorítmica do classificador aplicada.

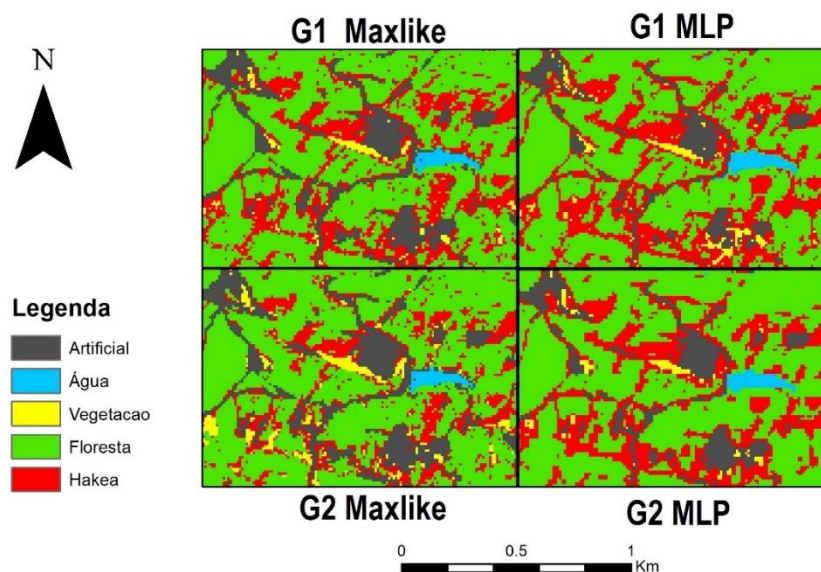


Figura 7 – Excerto dos mapas resultantes das classificações

## Discussão

### Influência da data de aquisição das imagens

Verificou-se que a data da aquisição das imagens poderá ter influenciado os resultados finais obtidos. A pertinência da escolha das imagens coincidiu com a época de floração antecipada da espécie invasora em relação às nativas, no entanto devido a condições climáticas e sazonais do próprio ano de 2017, é possível constatar que a diferenciação entre as espécies através desse fator poderá não ter sido tão eficaz quanto se considerou inicialmente. Futuros trabalhos poderão necessitar de utilizar metodologias de diferenciação diferentes, de acordo com as condicionantes climáticas e sazonais, pertinentes de cada ano em estudo.

### Influência da resolução espacial

A resolução espacial das imagens multiespectrais utilizadas, surgiu como fator restritivo em relação aos diferentes estudos de deteção de espécies invasoras abordados ao longo do trabalho, sendo que a resolução de 10m utilizada não possibilitou uma diferenciação eficaz entre a espécie invasora estudada e as classes de "Floresta" e "Vegetação". Tal constatação deve-se ao facto de que durante a operação de aquisição das áreas de treino, verificou-se uma dificuldade contínua na obtenção de zonas com bastante distinção entre classes, podendo este processo ter sido influenciado pela resolução espacial das imagens multiespectrais de Sentinel-2 utilizadas, sugerindo-se em aplicações futuras, a utilização de imagens de maior resolução espacial, provenientes de fontes não pagas.

### Influência dos grupos de bandas escolhidos

Quando comparados os resultados com o grupo de bandas que continha apenas as bandas 2,3,4 e 8, evidenciou-se que a adição das bandas 5,6,7,8A, 11 e 12 influenciou os resultados gerados pelos diferentes classificadores, permitindo obter uma classificação mais distinta entre as classes. A adição desse conjunto de bandas, permitiu um aumento significativo da informação espectral, refletindo-se nos resultados das exatidões dos classificadores aplicados.

## 6. Conclusões

Os resultados da classificação supervisionada, ao nível do pixel, de imagens adquiridas pelo Sentinel-2, com uma resolução espacial de 10m, possibilitaram a deteção de zonas ocupadas por espécies invasoras. No entanto, é fundamental conhecer as espécies, as suas características e os seus comportamentos no território para permitir uma boa escolha das áreas de treino, tendo-se constatado que a resolução espacial das imagens condiciona em parte a sua identificação.

O mapa produzido com o classificador MLP foi o que obteve melhor exatidão global, sendo melhorada a classificação com a introdução das bandas B5, B6, B7, B8a, B11 e B12. Destaque-se neste trabalho o facto de que a possibilidade de aceder a imagens de satélite com uma resolução de 10m de forma gratuita, permite a pesquisa e desenvolvimento de metodologias cada vez mais eficazes e com melhor aplicabilidade no contexto da deteção remota de espécies invasoras de pequena dimensão singular.

## Referências Bibliográficas

- Alvarez-Taboada, Flor, Claudio Paredes, and Julia Julián-Pelaz. 2017. "Mapping of the Invasive Species *Hakea Sericea* Using Unmanned Aerial Vehicle (UAV) and Worldview-2 Imagery and an Object-Oriented Approach." *Remote Sensing*.
- Eastman, J. Ronald. 2015. "TerrSet Manual." *Clark University*.
- Gascon, Ferran and Fabrizio Ramoino. 2017. "Sentinel-2 Data Exploitation with ESA 's Sentinel-2 Toolbox." *Geophysical Research Abstracts EGU General Assembly*.
- Immitzer, Markus, Francesco Vuolo, and Clement Atzberger. 2016. "First Experience with Sentinel-2 Data for Crop and Tree Species Classifications in Central Europe." *Remote Sensing* 8(3).
- Ng, Wai Tim et al. 2017. "Assessing the Potential of Sentinel-2 and Pléiades Data for the Detection of *Prosopis* and *Vachellia* Spp. In Kenya." *Remote Sensing* 9(1).