

# Detecção e delimitação de corpos de água em imagens de satélite de alta resolução com aprendizagem profunda. Um estudo preliminar com o Detectron2

REVISTA **MAPPING**

Vol.32, 214, 10-24

2023

ISSN: 1131-9100

*Detection and delineation of water bodies in high-resolution satellite images with deep learning. A preliminary study with Detectron2*

Samuel Fernandes, Alice Fialho, Isabel Patriarca

## Resumo

A delimitação de corpos de água com recurso a imagens de satélite desempenha um papel crucial em diversas aplicações, como monitorização ambiental, planeamento de recursos hídricos, planeamento na defesa contra a incêndios e na análise das alterações climáticas. Neste trabalho, pretendemos explorar a aplicação da aprendizagem profunda tendo por base o Framework Detectron2, na geração automática de polígonos que representam corpos de água como pequenas albufeiras, lagos, charcos e reservatórios. A caracterização eficiente das disponibilidades hídricas dos reservatórios, albufeiras e barragens permite uma melhor e mais eficiente monitorização dos Planos de Água (PA), bem como a boa gestão desses mesmos recursos. A área geográfica de estudo e as metodologias desenvolvidas, encontra-se enquadrada nas áreas de jurisdição da Administração da Região Hidrográfica do Alentejo, Departamentos desconcentrados da Agência portuguesa do Ambiente, I.P.

Foi desenvolvido um conjunto de dados abrangente e personalizado composto por imagens de satélite de alta resolução e rótulos anotados manualmente, identificando as áreas correspondentes aos corpos de água, para treinar o modelo. Foi utilizada a arquitetura ResNet-50 combinada com a Mask R-CNN, presentes no Detectron2, para realizar a tarefa de deteção de objetos em geral e segmentação respetivamente. Em seguida, treinamos o modelo de aprendizagem profunda utilizando o nosso conjunto de dados na plataforma Google Colab, aproveitando o poder computacional das unidades de processamento gráfico (GPU).

A vantagem de usar a Framework Detectron2 é a sua capacidade rápida e eficiente de delimitação de corpos de água em grandes volumes de dados, comparativamente ao método tradicional, o qual envolve um processo manual de análise e marcação dos polígonos nas imagens de satélite através de pessoal especializado, apresentando elevados custos em termos de recursos humanos, económicos e com elevada morosidade.

Na (Figura-1) é possível observar dois corpos de água corretamente segmentados utilizando o método proposto. Esta abordagem pode impulsionar o desenvolvimento de técnicas mais precisas e eficientes para a deteção e delimitação de características hidrológicas em imagens de satélite uma vez que conseguimos segmentar corpos de água com dimensões de até 121 m<sup>2</sup>. A abordagem implementada

neste trabalho pode ser aplicada a outras áreas temáticas como por exemplo a deteção de incêndios, blooms de algas, identificação de estruturas urbanas, delimitação de florestas e cultivos agrícolas.

## Abstract

*The segmentation of water bodies through satellite imagery plays a crucial role in various applications, including environmental monitoring, water resource planning, defence against fires, and climate change analysis. In this article aims to explore the application of deep learning based on the Detectron2 framework for the automatic generation of polygons representing water bodies such as small reservoirs, lakes, ponds, and reservoirs. Efficient characterization of water resources in small reservoirs, and dams allows a better and more effective monitoring of Water Plans (PA) and the proper management of these resources. The geographical area of study and the developed methodologies are situated within the jurisdictions of the Administração da Região Hidrográfica do Alentejo, decentralized departments of the Agência Portuguesa do Ambiente, I.P..*

*A comprehensive and customized dataset was developed, consisting of high-resolution satellite images with manually annotated labels identifying areas corresponding to water bodies, used for model training. The ResNet-50 architecture was combined with Mask R-CNN available in Detectron2, to perform the task of object detection in general and segmentation respectively. Subsequently, we trained the deep learning model using our dataset on the Google Colab platform, leveraging the computational power of Graphics Processing Units (GPUs).*

*The advantage of employing the Detectron2 framework lies in its swift and efficient capacity for of water bodies segmentation within extensive datasets, in contrast to the conventional approach which involves the analysis and marking of polygons in satellite images by specialized personnel, incurring substantial costs in terms of human resources and economic resources while also being notably time-consuming.*

*Two water bodies segmented using the proposed procedure can be observed in (Figure 1). This approach has the potential to drive the development of more precise and efficient techniques for the detection and segmentation of hydrological features in satellite images, as it allows the segmentation of water bodies with dimensions as small as 121 m<sup>2</sup>. The methodology implemented in this work can be applied to other thematic areas, such as fire detection, algae blooms, identification of urban structures, delineation of forests, and agricultural crop mapping.*

Palavras-chave: Segmentação de Imagem, Imagens de Satélite, Detectron2, Corpos de Água, Aprendizagem Profunda, Recursos Hídricos, Visão Computacional, Machine Learning

Keywords: Image Segmentation, Satellite Images, Detectron2, Bodies of Water, Deep Learning, Water Resources, Computer Vision, Machine Learning

Samuel Fernandes

Agência Portuguesa do Ambiente

[samuel.fernandes@apambiente.pt](mailto:samuel.fernandes@apambiente.pt)

Alice Fialho

Agência Portuguesa do Ambiente ARH Alentejo

[alice.fialho@apambiente.pt](mailto:alice.fialho@apambiente.pt)

Isabel Patriarca

Agência Portuguesa do Ambiente/ ARH Tejo e Oeste

[isabel.patriarca@apambiente.pt](mailto:isabel.patriarca@apambiente.pt)

Recepción 20/11/2023

Aprobación 12/12/2023

## 1. INTRODUÇÃO

A água doce armazenada nos continentes é um recurso essencial para a vida na Terra, ecossistemas, biodiversidade e sociedade humana. Setores como a agricultura, indústria, ambiente doméstico, turismo, produção de energia, aquacultura e a pastorícia apresentam uma dependência significativa deste recurso. As massas de água superficiais desempenham um papel fundamental no ciclo global da água[1,2], realizando trocas constantes de massa com a atmosfera, biosfera, litosfera e hidrosfera terrestre, o que as torna um componente essencial do sistema climático e da sua variabilidade[3–5]. No entanto, o armazenamento e o fluxo de água doce, bem como a sua distribuição espacial e variabilidade, continuam largamente desconhecidos em muitas regiões do mundo[6,7], o que impede o desenvolvimento de estratégias adequadas

e sustentáveis para a gestão dos recursos hídricos[8–10]. Estes fatores adquirem uma importância crucial na região do Alentejo, onde a escassez hídrica terá repercussões nos ecossistemas e nas atividades económicas[11,12].

A precisa deteção e delimitação de corpos de água pode contribuir para alcançar as metas 6.4, 6.5, 6.6 e 6.A estabelecidas no Objetivo 6 das Nações Unidas para o Desenvolvimento Sustentável (SDGs) até 2030. O mapeamento de corpos de água superficiais ajudar-nos-á na avaliação das disponibilidades hídricas do território, na melhor compreensão dos impactos das alterações climáticas, na preservação dos serviços de ecossistema relacionados com os recursos hídricos e na implementação de atividades e programas voltados para a gestão da água, abrangendo desde estratégias de captação até o tratamento de efluentes líquidos. Os arquivos históricos de dados provenientes de satélites de observação terres-



Figura 1. Corpos de água delimitados em imagens de satélite de alta resolução com recurso ao modelo de deteção e segmentação de imagem Mask R-CNN com o Framework Detectron2.

tre são um dos únicos meios viáveis para quantificar essas dinâmicas em escala global e ao longo do tempo, uma vez que conseguem capturar informações em larga escala espacial e temporal da superfície terrestre em pouco tempo e com baixos custos.

A tradicional delimitação de corpos de água sobre ortofotomapas é dispendiosa, morosa e não tão eficaz quanto um modelo de detecção. Os métodos clássicos baseados nos índices da água [13–15] levam ao problema de classificar erroneamente pixels de água como pixels não pertencentes à água, identificar de forma imprecisa os pixels de fronteira devido à tarefa tediosa de seleção de limiares ótimos e os satélites de dados abertos apresentam uma baixa resolução de imagens impossibilitando a detecção de pequenos corpos de água. A aprendizagem profunda (deep learning) emergiu como um propulsor fundamental para a rápida evolução de uma ampla gama de tarefas voltadas à análise de imagens. Esse cenário tem proporcionado notáveis benefícios aos investigadores interessados na análise de vastos conjuntos de dados visuais. Neste campo dinâmico, denominado visão computacional, revelam-se desenvolvimentos científicos de alta relevância com aplicações em variados setores como os sistemas de condução autónoma [16,17], medicina [18], planeamento urbano [19], agricultura [20], levantamentos geológicos [21], controlo de qualidade industrial [22], biotecnologia [23] e astronomia [24]. A delimitação de corpos de água superficiais, constitui uma tarefa clássica e desafiante no campo da detecção remota e interpretação de imagens, disciplina que tem sido estudada há décadas. Kadhim, Inas et al. [25] desenvolveu em 2023 uma plataforma para segmentação de corpos de água a partir de imagens da base de dados publica Sentinel-2. Os resultados alcançados evidenciaram um desempenho bem-sucedido e uma melhoria na performance em relação a outras metodologias consideradas de estado-da-arte à época. Ma, Zhanming et al. [26] no ano de 2023 desenvolveu uma rede de pesquisa de características locais para segmentação de edifícios e água sobre imagens de detecção remota. Yuan, Kunhao et al. [27] em 2021 desenvolveu uma metodologia baseada numa rede neural convolucional profunda para segmentação de corpos de água em imagens multiespectrais provenientes de satélites. Marc Wieland et al. [28] em 2023 desenvolveu um método que permitiu delimitar corpos de água em imagens de alta resolução através de segmentação semântica, combinado diferentes arquiteturas de modelos U-Net e DeepLab-V3+MobileNet-V3, ResNet-50 e EfficientNet-B4. Também, Rishikesh et al. implementou em 2021 uma arquitetura avançada de aprendizagem profunda de múltiplos atributos para segmentação de corpos de água a partir de imagens de satélite [29].

Neste artigo, propomos uma metodologia de extração de corpos de água utilizando a framework estado-de-arte Detectron2 baseada em Pythorch. Esta plataforma de visão computacional permite desenvolver métodos de segmentação de instancias, semântica, panótica, Densepose, Cascade R-CNN, caixas delimitadoras rotacionadas, PointRend, DeepLab, ViTDet, MVITv2, entre outros [30]. Tem sido amplamente utilizada na detecção de fogos florestais [31], detecção e classificação de danos em estradas [32], cuidados de saúde [33,34], astronomia [35], agricultura [36], entre outros campos da investigação.

O principal avanço deste artigo reside na sua capacidade de detetar e delimitar com alta precisão corpos de água superficiais a partir de imagens capturadas por satélites de alta resolução. As imagens processadas pelo modelo podem conter um ou múltiplos corpos de água com diferentes dimensões e tonalidade, demonstrando assim sua eficácia na identificação de espelhos de água.

Foi desenvolvido um método automatizado de detecção e delimitação de corpos de água superficiais capturados através de satélites de alta resolução.

Para treinar o modelo proposto, recolheu-se um vasto conjunto de dados personalizados contendo vários cenários, florestais, montanhosos, agrícola, urbana, baixo índice de vegetação. Utilizou-se a ferramenta de anotação de imagem VGG Image Annotator (VIA), para delimitar os corpos de água utilizando polígonos em vez de retângulos. Foram comparados os resultados da detecção de corpos de água automatizada com o levantamento manual a ponto realizado no ano de 2017.

O restante estudo encontra-se estruturado do seguinte modo. Na Secção 2 é apresentada a área de estudo e descrito em detalhe o modelo de detecção e segmentação de corpos de água proposto. Discutiram-se os resultados experimentais obtidos a partir da análise quantitativa e qualitativa, bem como do conjunto de dados na Secção 3. O artigo conclui com um resumo dos resultados obtidos e propostas de trabalho futuras na Secção 4.

## 2. MATERIAIS E MÉTODOS

Os modelos de segmentação de instâncias têm como objetivo atribuir rótulos a cada pixel dentro de uma Região da imagem por meio de uma estrutura codificador-descodificador [37]. Essa tarefa é particularmente desafiadora, pois exige não apenas a segmentação de objetos, mas também a habilidade de diferenciar entre instâncias distintas pertencentes à mesma classe. Nesta seção, apresentaremos uma descrição detalhada dos materiais e métodos adotados na criação de uma metodolo-




Figura 2. Diagrama de fluxo passo-a-passo da metodologia implementada. Aquisição de imagens, anotação manual de corpos de água, treino do modelo Mask R-CNN, deteção e segmentação automáticas de corpos de água sobre imagens, conversão das coordenadas dos pixels no Datum WGS84 (EPSG:4326), obtenção de shapefile final com a combinação dos corpos de água na RH6 e RH7. Apresentam-se ainda os dados de entrada e saída ao longo do procedimento.

gia para detetar e segmentar corpos de água superficiais em imagens de alta resolução.

### 2.1 Descrição do Fluxo de Trabalho

A implementação desta metodologia, cujo core assenta na Framework Detectron2, requereu a subdivisão do procedimento em 10 componentes, detalhadamente descritas nas subsecções seguintes. Uma representação visual dos diferentes subprocessos e dos dados de entrada e saída no formato raster e vetorial destinados à deteção e segmentação de corpos de água pode ser observada na (Figura-2).

Uma amostra aleatória de imagens das duas Regiões Hidrográficas (RH) foi cuidadosamente examinada. Durante essa análise, todos os corpos de água superficiais

identificados nessas imagens foram segmentados e anotados manualmente. Esse conjunto de imagens, juntamente com os polígonos e anotações no padrão COCO, desempenharam um papel fundamental como dados de entrada para o treino dos modelos de computação visual. Os modelos finais aplicaram-se às duas RH para segmentação de polígonos que delimitam os corpos de água. As coordenadas dos pixels associados aos polígonos foram convertidas nos sistemas de coordenadas geográfico. A shapefile intermédia contendo todas os polígonos gerados foi avaliada no sentido de eliminação de polígonos aberrantes e falsos positivos correspondentes a estruturas com tonalidade de cor e formato próximas dos corpos de água. Finalmente obteve-se a shapefile final com todos os corpos de água encontrados nas duas RH.

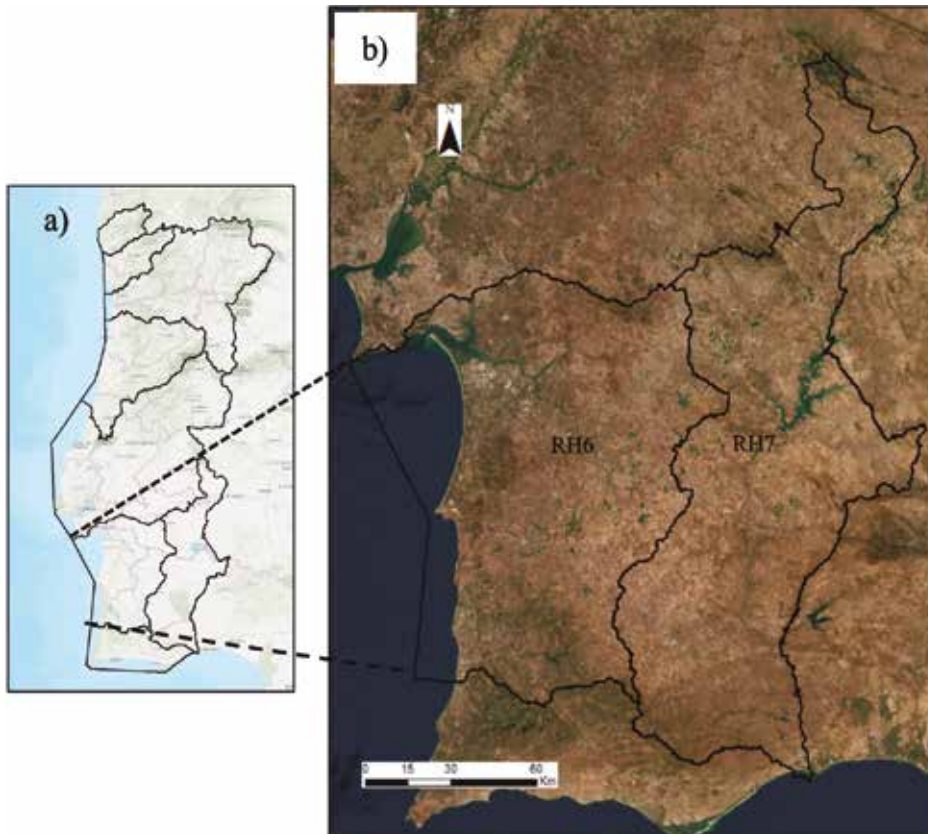


Figura 3. Delimitação das Regiões Hidrográficas da ARH do Alentejo, RH6 - Sado e Mira e RH7 - Guadiana, como indicado no mapa maior, a) mapa geral de Portugal com a delimitação das 8 Regiões Hidrográficas, b) mapa de pormenor com a identificação da Região Hidrográfica 6 e 7.




Figura 4. Abordagem utilizada para a aquisição de imagens em múltiplas seções. Uma vez que foram definidos blocos retangulares, na zona de fronteira adjacente às duas RH verificou-se a sobreposição das duas camadas.

## 2.2 Local de estudo

O estudo realizado centra-se nas duas Regiões Hidrográficas do Alentejo, RH6 e RH7. A RH6 - Sado e Mira com uma área total de 12 149 km<sup>2</sup>, integra as bacias hidrográficas dos rios Sado e Mira e as bacias hidrográficas das ribeiras de costa. A RH7 - Guadiana, é uma região hidrográfica internacional com uma área total em Portugal de 11 611 km<sup>2</sup>, integra a bacia hidrográfica do rio Guadiana e as bacias hidrográficas das ribeiras de costa. As áreas de estudo e os detalhes associados são apresentados na (Figura-3).

O clima nas duas Regiões Hidrográficas é tipicamente mediterrânico, bioclima mediterrâneo pluvisazonal oceânico, sub-árido seco, e mesotérmico [38,39], com dias quentes e secos no verão, temperaturas que podem ir até aos 45°C. No inverno os dias são frios e chuvosos com temperaturas mínimas que podem ir até aos -4°C [40,41]. A precipitação anual nas duas regiões apresenta variações entre os 266 e os 610 mm na última década [42]. A altitude varia entre os 0 m ao nível do oceano e os 1027 m na Serra de São Mamede. Estas duas regiões são altamente vulneráveis às alterações climáticas no futuro, como evidenciado pela previsão de expansão da área de clima árido [43].

## 2.3 Preparação dos dados de base e armazenamento de informação

A resolução espacial mede a riqueza de características contidas em imagens de deteção remota, o que é fundamental para distinguir corpos de água do resto dos objetos. As resoluções baixas geralmente resultam em menor precisão de segmentação e contornos mais grosseiros. Além




Figura 5. Amostra do conjunto de imagens utilizadas para treino do modelo. Foi utilizado um conjunto de 200 imagens na RH6 e um conjunto de 100 imagens na RH7. As imagens utilizadas poderiam conter um ou mais corpos de água com diferentes tonalidades, dimensões, estruturas físicas diversas e uma variedade de usos do solo na envolvente.

disso, modelos de aprendizagem profunda treinados em imagens de baixa resolução são desafiantes de aplicar a imagens com resoluções mais elevadas. O método proposto faz uso dos mapas de satélite de alta resolução disponíveis na plataforma Google Maps. As imagens foram recolhidas em blocos retangulares que cobrem as duas Regiões Hidrográficas, na (Figura-4) é ilustrada a metodologia de aquisição da informação. Tendo sido a

RH6 e RH7 repartidas em 7 e 9 blocos respetivamente. Por sua vez cada um dos blocos foi subdividido em pequenas quadrículas com 1.8 km de comprimento e 0.8 km de largura, com o zoom ao nível 17. As imagens recolhidas têm uma dimensão espacial de 1942 x 860 pixels. A obtenção destes dados foi realizada com recurso ao módulo satellite imagery downloader (SDI), o qual permite descarregar imagens retangulares da região pretendida, tendo como



Figura 6. Anotação de corpos de água em imagens de satélite com recurso ao software VGG Image Annotator. Na figura encontram-se anotados dois corpos de água (polígono amarelo).

variáveis de entrada as coordenadas geográficas e nível zoom, por sua vez a imagem é guardada na extensão PNG no formato de cores vermelho, verde e azul (RGB).

Como o módulo python SDI guarda as imagens sem a inclusão do sistema de coordenadas, os pontos de referência correspondentes ao vértice superior esquerdo e vértice inferior direito foram guardadas para serem utilizadas como pontos de referência no processo de conversão das coordenadas do pixel para o sistema de coordenadas WGS84. O processamento de dados foi realizado na versão gratuita do Google Colab em conjunto com o Google Drive para armazenamento de informação recolhida. Esta metodologia de armazenamento de imagens por bloco foi adotada ao invés de descartar cada imagem após o processamento, o que permitiu na ocorrência de falsos positivos e de polígonos aberrantes numa determinada área, maior rapidez na correção do modelo inicial.

#### 2.4 Segmentação, anotação de corpos de água e treino

A segmentação de instâncias desempenha um papel fundamental no desenvolvimento de modelos de deteção de objetos avançados, como o Mask R-CNN. Para treinar e validar esses modelos, é essencial contar com conjuntos de dados robustos e representativos. No contexto deste estudo, os dados utilizados para treinar o modelo foram adquiridos a partir dos blocos retangulares em duas Regiões Hidrográficas (RH). Uma amostra dessas imagens pode ser vista na (Figura-5). É importante notar que as RH6 e RH7 apresentam diferenças no que concerne à morfologia, culturas agrícolas e topografia do terreno. Portanto, optou-se por criar dois conjuntos de dados distintos para

melhorar a precisão e exatidão na deteção e segmentação de corpos de água. Na RH6, foram selecionadas aleatoriamente 200 imagens para compor o conjunto de treino do modelo. Essa decisão foi tomada devido à observação inicial de um alto número de falsos positivos, especialmente relacionados com as copas das árvores de grande porte e as sombras que elas projetam. Na RH7, escolheram-se aleatoriamente 100 imagens para o conjunto de treino, considerando as características específicas dessa região. Esta abordagem que passou por utilizar um maior número de imagens na RH6 e comparativamente com a RH7 permitiu ajustar o modelo de acordo com as particularidades de cada região, melhorando assim capacidade de segmentação e deteção de corpos de água.

A segmentação e anotação manual dos corpos de água desempenha um papel crítico no processo de treino de modelos de visão computacional, como o Detectron2, para a deteção e segmentação precisa dessas características geográficas. Para realizar essa tarefa, foi utilizado o software VGG Image Annotator (VIA), uma ferramenta amplamente reconhecida e utilizada em tarefas de anotação de dados visuais, incluindo deteção de objetos e segmentação de imagens (Figura-6). O processo de anotação permitiu a introdução de imagens específicas da área de jurisdição da ARH Alentejo no modelo, um fator que contribuiu significativamente para melhorar o desempenho na deteção de corpos de água.

Através do VIA, foi possível criar um conjunto de dados anotado com informações precisas sobre a localização dos corpos de água. O software gerou um arquivo JSON que continha as coordenadas dos polígonos que representam



Figura 7. Amostra do conjunto de imagens analisadas pelo modelo com os respectivos polígonos e anotações.

os corpos de água, juntamente com as suas respectivas anotações. Esses dados foram formatados de acordo com o padrão COCO. É importante destacar que, para garan-

tir a consistência no treino do modelo, todas as imagens utilizadas devem ter as mesmas dimensões em termos de altura e largura. Isso é fundamental para que o modelo



possa aprender com eficácia os padrões e características dos corpos de água nas imagens de treino.

## 2.5 Arquitetura do Modelo

A Framework Detectron2 possui diferentes modelos de referência, que são combinações de diferentes backbones e cronogramas de treino. O backbone do modelo apresentado é a arquitetura ResNet-50, uma rede neural convolucional profundamente elaborada com 50 camadas (48 camadas convolucionais, uma camada MaxPool e uma camada de Médio pool). A escolha do ResNet-50 como backbone é fundamental para a extração de características robustas a partir das imagens de entrada. Esta arquitetura destaca-se pela capacidade de capturar informações de diferentes níveis de abstração, o que é crucial para tarefas de detecção e segmentação de objetos em imagens complexas. A arquitetura Mask R-CNN estende o Faster R-CNN ao incorporar a capacidade de segmentação por pixel, permitindo a previsão de máscaras binárias para objetos em uma imagem por meio do uso de uma rede totalmente convolucional (FCN). A FCN gera uma máscara  $m \times m$  para cada região de interesse (ROI), preservando a correspondência pixel a pixel através de convoluções. Isto permite uma extração precisa da estrutura espacial do objeto. A camada RoIAlign na Mask R-CNN ajuda a manter a precisão das características das pequenas ROIs, alinhando-as com a entrada, resultando num melhor desempenho na previsão de máscaras. A camada RoIAlign é crucial para uma previsão de máscara precisa e assegura uma correspondência espacial por pixel. Para abordar objetos em diferentes escalas, a arquitetura incorpora a Feature Pyramid Network (FPN). A FPN é responsável por criar uma pirâmide de características a partir das saídas de diferentes camadas do backbone. Essa pirâmide permite que o modelo detete objetos em diferentes tamanhos. A etapa subsequente é a aplicação de uma Região de Proposta de Rede (Region Proposal Network - RPN). O RPN gera propostas de regiões candidatas que possam conter objetos. Essas propostas são uma etapa fundamental na seleção das Regiões de Interesse (Rois) que serão posteriormente refinadas para detecção e segmentação. Uma das características distintas deste modelo é o treino intensivo. O conjunto de dados foi treinado utilizando o padrão COCO numa taxa três vezes superior ao padrão.

Utilizou-se o modelo de detecção e segmentação de imagem selecionado a partir do repositório de modelos Detectron2, "mask\_rcnn\_R\_50\_FPN\_3x" e a configuração dos parâmetros do treino consistiram no seguinte:

**Imagens por Lote (Batch Size):** Definimos um tamanho de lote de 2 imagens por iteração. Isso permite que o modelo generalize melhor e evite o ajuste excessivo(o-

verfitting), especialmente considerando as variações nas imagens de satélite.

**Taxa de Aprendizagem Base (Learning Rate):** Configuramos a taxa de aprendizagem base em 0.00025. Essa taxa foi cuidadosamente ajustada para controlar a convergência do modelo durante o treino.

**Iterações de Treino:** O modelo foi treinado ao longo de 400 iterações.

**Tamanho de Lote por Imagem (Image Batch Size):** Foi utilizado um tamanho de imagem de 512, que permitiu acelerar o treino sem colocar em causa a qualidade da informação.

**Número de Classes:** O número de classes considerado foi de 1 (Corpos de Água).

**Valor crítico:** Foi definindo 0.85 o limiar para o qual um objeto é identificado como corpo de água superficial.

## 2.6 Conversão de coordenadas DATUM WGS84

Na ausência de uma integração nativa da funcionalidade de processamento de imagens georreferenciadas no framework Detectron2 e no módulo satellite imagery downloader, foram imperativos no desenvolvimento e implementação de uma metodologia robusta para a conversão das coordenadas dos polígonos produzidos pelo modelo de computação visual para o sistema de coordenadas DATUM WGS84. Este procedimento permitiu garantir a exatidão espacial e a coerência geográfica da informação extraída.

A transformação de coordenadas é efetuada através de um modelo de regressão linear como descrito na equação 1:

$$Y = \beta X + \epsilon \quad \text{Eq.1}$$

onde Y denota as coordenadas transformadas no DATUM WGS84, X denota as coordenadas originais geradas pelo modelo de visão computacional,  $\beta$  e  $\epsilon$  são os parâmetros do modelo linear.

Para realizar essa transformação, é necessário o conhecimento prévio de dois pontos de referência georreferenciados, que correspondem ao vértice superior direito e ao vértice inferior esquerdo da imagem ou da área de interesse em questão. Esses pontos fornecem os dados necessários para estimar os coeficientes,  $\beta$  e  $\epsilon$  na equação da regressão linear. Uma vez calculados os coeficientes, torna-se possível aplicar a transformação linear a todas as coordenadas dos polígonos gerados pelo modelo de visão computacional, alinhando-os com o DATUM WGS84.

Após a conversão das coordenadas, os polígonos resultantes passaram por um processo de validação.

Este passo garantiu a integridade e a precisão dos dados geoespaciais, uma vez que nem todos os polígonos gerados pelo modelo de visão computacional eram necessariamente representativos de corpos de água reais.

### 3. RESULTADOS

O modelo de computação visual desenvolvido revelou-se capaz de detetar e segmentar corpos de água superficiais nas duas RH. Uma amostra aleatória do conjunto de dados onde o modelo conseguiu identificar corretamente os corpos de água e traçar os respetivos contornos de forma coerente com a geografia real é apresentada na (Figura 7). Junta-mente com a delimitação do polígono, o output do modelo inclui o nome da classe observada e o limiar de classificação do objeto. Os modelos desenvolvidos passaram por um processo de validação tendo por base a comparação com o levantamento manual de corpos de água no formato ponto realizado no ano de 2017, para as duas regiões. A validação permitiu-nos aferir o nível de performance que o modelo pode alcançar em condições do mundo real e confirmar a sua eficácia na tarefa específica para a qual foi desenvolvido. As métricas utilizadas para a aferição dos modelos, incluíram a determinação dos polígonos positivos que efetivamente representam corpos de água, falsos positivos, polígonos que erroneamente indicam a presença dos objetos de interesse, falsos negativos e ausência de polígono quando na verdade existe um corpo de água. Foi ainda calculada a precisão, a taxa de verdadeiros positivos, o recall, parâmetro que mede a capacidade de o modelo identificar corretamente todos os exemplos positivos em um conjunto de dados e o f1-score uma única medida do desempenho de um modelo de classificação, levando em consideração tanto a precisão quanto a sensibilidade.

A precisão do modelo em determinar corpos de água foi determinada segundo a Equação-2:

$$P = \frac{TP}{TP + FP} \quad \text{Eq.2}$$

onde P denota a precisão, TP os polígonos positivos, FP falsos positivos.

A taxa de verdadeiros positivos também conhecida como a sensibilidade do modelo foi calculada através da Equação-3:

$$TPR = \frac{TP}{P} \quad \text{Eq.3}$$

O coeficiente f1-score foi determinado segundo a Equação-4:

$$F1 = 2 \times \frac{PPV \times TPR}{PPV + TPR} \quad \text{Eq.4}$$

onde PPV denota o valor preditivo positivo

O parâmetro recall foi calculado segundo a Equação-5:

$$R = \frac{TP}{TP + FN} \quad \text{Eq.5}$$

onde FN denota o número de polígonos falsos positivos.

Após a análise dos resultados obtidos (Tabela-1), verificamos que o número de polígonos positivos representativos de corpos de água foi mais elevado na RH7 em comparação com RH6, o que é expectável considerando o levantamento realizado no ano de 2017.

Como a RH6 apresenta um conjunto de características orográficas e culturas agrícolas próprias, a deteção de corpos de águas nesta região foi mais desafiadora. Observou-se num estágio preliminar que a utilização do modelo calibrado com informação da RH7 na RH6 apresentava resultados pobres e ainda que se tenha incrementado o número de dados de entrada com imagens da Região, verificou-se que as métricas como a precisão e o f1-score foram inferiores às métricas obtidas para a RH7. Uma das causas que levou ao aumento de falsos positivos foi a classificação de copas de árvores cuja tonalidade se aproximou da água. As sombras das árvores pela sua tonalidade e forma foram algumas vezes classificadas como corpos de água. Verificou-se também nas zonas urbanas uma tendência para a classificação de campos desportivos ou zonas de recreio como corpos de água. Segundo a análise efetuada verificou-se que o modelo apresentou uma maior precisão na RH7, 0.06 pontos superior à RH6 e o recall foi exatamente o mesmo nas duas RH. Consequentemente verificou-se uma melhoria qualitativa nos resultados da RH7 comparativamente à RH6. Numa perspetiva global, o modelo desenvolvido permitiu identificar e delimitar 9236 corpos de água em contraste com os 13902 identificados em 2017, obteve uma precisão de 0.71, uma taxa de verdadeiros positivos de 0.67, o recall de 0.60 e o f1-score de 0.68. Estima-se ainda que devido à dinâmica do território existam atualmente mais 1450 corpos de água presentes nas duas RH quando comparado com o ano de referência.

	RH6	RH7	Global
<u>Positivos</u>	3577	5659	9236
<u>Falsos Positivos</u>	1660	1891	3551
<u>Falsos Negativos</u>	2376	3740	6116
<u>Total</u>	5237	7570	12807
<u>Corpos água 2017</u>	5291	8611	13902
<u>Precisão</u>	0.68	0.74	0.71
<u>Taxa de Verdadeiros Positivos</u>	0.67	0.65	0.67
<u>Recall</u>	0.60	0.60	0.60
<u>F1-score</u>	0.67	0.69	0.68

Tabela 1. Resultados do modelo de computação visual Mask R-CNN após implementação na RH6 e RH7 e a performance global conjugando as duas RH. Os corpos de água de 2017 dizem respeito ao levantamento a ponto efetuado nesse ano e que serviu de referência ao nosso estudo.

de água pode ser observada na (Figura-8). Através desta abordagem foi possível não apenas a detecção dos corpos de água, mas também a delimitação das suas extensões, oferecendo um mapeamento altamente informativo e visualmente esclarecedor. Ainda que a figura apresentada seja estática numa grande escala, a camada geospacial no formato shapefile, permite uma visualização clara dos açudes, pequenas albufeiras, charcos, lagos, lagoas e represas, ajudando na tomada de decisão relacionadas com o uso sustentável da água, proteção de ecossistemas aquáticos, monitorização das alterações climáticas, gestão de recursos hídricos para a agricultura e ainda na defesa contra incêndios.

A camada resultante da metodologia desenvolvida e que contém todos os polígonos representativos de corpos

de água

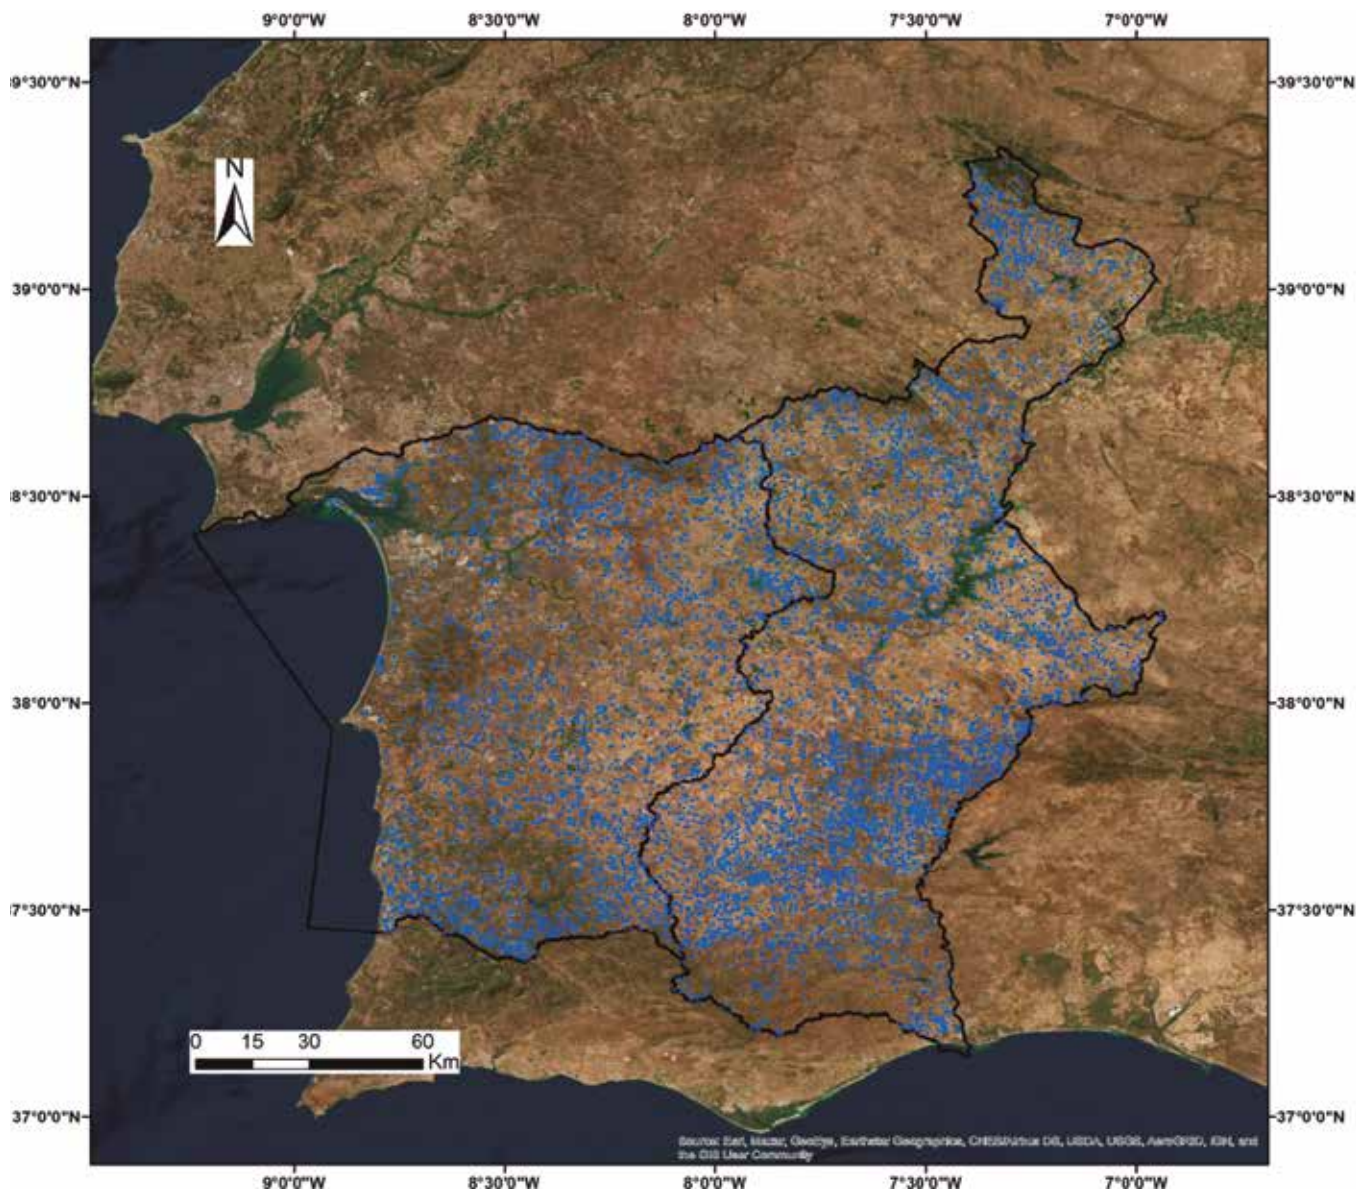


Figura 8. Mapa final com a representação de todos os corpos de água (polígono azul) detetados e segmentados na RH6 e RH7.

Observa-se uma maior densidade de corpos de água sobretudo no Norte e Centro-Sul da RH7 e a menor densidade de corpos de água ocorre na zona Centro-Norte da RH6 e Sul da RH7. O menor corpo de água identificado, com uma área de 121 m<sup>2</sup> foi detetado na RH7 é um exemplo da capacidade do modelo Mask R-CNN implementado por meio da Framework Detectron2. Essa precisão notável é essencial para identificar corpos de água em todas as escalas, desde pequenos charcos até grandes represas. O impacto na gestão da água é significativo, pois cada corpo de água, independentemente do tamanho, desempenha um papel vital nos ecossistemas aquáticos e na segurança hídrica.

## 4. CONCLUSÕES

Neste trabalho foi desenvolvida uma nova metodologia para análise de imagens de alta resolução com o objetivo de extrair informações sobre corpos de água superficiais em grande escala. O levantamento foi realizado nas Regiões Hidrográficas da ARH do Alentejo, RH6 e RH7, e os resultados obtidos comparados com a informação de referência do ano de 2017, recolhidos pela metodologia clássica a ponto. A metodologia utiliza a Framework Detectron2 para a implementação de um algoritmo de segmentação de instâncias que classifica os pixels em categorias, distingue objetos individuais da mesma categoria e atribui uma identificação única a cada um deles. O algoritmo utilizou as vantagens das redes neurais convolucionais, usando a arquitetura ResNet-50 conjugada com a arquitetura Mask R-CNN para obter características em diferentes níveis. Os resultados demonstraram que o modelo conseguiu identificar e delimitar corretamente 9236 corpos de água dos 13902 identificados no ano de referência, evidenciando uma taxa de acerto na ordem dos 67%. Tipicamente os modelos computacionais utilizam dados de treino na ordem dos milhares de objetos, o que neste estudo preliminar não ocorreu, tendo sido utilizadas 300 imagens na combinação das duas RH. Pretende-se numa próxima abordagem utilizar os polígonos obtidos atualmente para treinar um modelo com uma maior taxa de acerto, exatidão e precisão. Ainda que não se disponha de polígonos históricos que nos sirvam de referência para avaliar a precisão na definição dos polígonos, pode-se afirmar que na sua vasta maioria, os segmentos gerados encontram-se enquadrados com os corpos de água. Em virtude da versatilidade da Framework Detectron2, a metodologia aqui proposta pode ser utilizada em outros contextos da deteção remota como a ecologia aquática, levantamento de estruturas urbanas, florestas, agricultura, caracterização de elementos urbanos, deteção de desastres naturais, segurança e defesa.

## AGRADECIMENTOS

Os meus mais sinceros agradecimentos ao Dr. André Matoso (Diretor ARH Alentejo), Eng. Alice Fialho (Chefe Divisão Planeamento e Informação da ARH Alentejo) e José Mendes (Técnico Superior na Divisão de Planeamento e Informação). Quero também expressar a minha gratidão para com a toda a equipa da ARH Alentejo que acreditaram neste trabalho, cujo conhecimento profundo e dedicação à excelência foram fundamentais para o êxito deste projeto inovador. Agradecemos profundamente pelo seu empenho e colaboração exemplares, que enriquecem o campo da tecnologia e da ciência e esperamos ansiosamente continuar a trilhar este caminho emocionante.

## BIBLIOGRAFIA

- H. Xia, J. Zhao, Y. Qin, J. Yang, Y. Cui, H. Song, L. Ma, N. Jin, Q. Meng, Changes in Water Surface Area during 1989–2017 in the Huai River Basin using Landsat Data and Google Earth Engine, *Remote Sens.* 2019, Vol. 11, Page 1824. 11 (2019) 1824. <https://doi.org/10.3390/RS11151824>.
- D. Yang, Y. Yang, J. Xia, Hydrological cycle and water resources in a changing world: A review, *Geogr. Sustain.* 2 (2021) 115–122. <https://doi.org/10.1016/J.GEO-SUS.2021.05.003>.
- A. El Moll, Water resources and climate change: regional, national and international perspective, *Sustain. Circ. Manag. Resour. Waste Towar. a Green Deal.* (2023) 309–336. <https://doi.org/10.1016/B978-0-323-95278-1.00010-3>.
- M. Yadav, H.G. Gosai, G. Singh, A. Singh, A.K. Singh, R.P. Singh, R.N. Jadeja, Major impact of global climate change in atmospheric, hydrospheric and lithospheric context, *Glob. Clim. Chang. Environ. Refug. Nature, Framew. Leg.* (2023) 35–55. [https://doi.org/10.1007/978-3-031-24833-7\\_3/COVER](https://doi.org/10.1007/978-3-031-24833-7_3/COVER).
- J.J. Bogardi, B.M. Fekete, Water: A unique phenomenon and resource, *Handb. Water Resour. Manag. Discourses, Concepts Examples.* (2021) 9–40. [https://doi.org/10.1007/978-3-030-60147-8\\_2/COVER](https://doi.org/10.1007/978-3-030-60147-8_2/COVER).
- F. Papa, F. Frappart, Surface Water Storage in Rivers and Wetlands Derived from Satellite Observations: A Review of Current Advances and Future Opportunities for Hydrological Sciences, *Remote Sens.* 2021, Vol. 13, Page 4162. 13 (2021) 4162. <https://doi.org/10.3390/RS13204162>.
- W. Dorigo, S. Dietrich, F. Aires, L. Brocca, S. Carter, J.F. Cretaux, D. Dunkerley, H. Enomoto, R. Forsberg, A. Güntner, M.I. Hegglin, R. Hollmann, D.F. Hurst, J.A.

- Johannessen, C. Kummerow, T. Lee, K. Luoju, U. Looser, D.G. Miralles, V. Pellet, T. Recknagel, C.R. Vargas, U. Schneider, P. Schoeneich, M. Schröder, N. Tapper, V. Vuglinsky, W. Wagner, L. Yu, L. Zappa, M. Zemp, V. Aich, Closing the Water Cycle from Observations across Scales: Where Do We Stand?, *Bull. Am. Meteorol. Soc.* 102 (2021) E1897–E1935. <https://doi.org/10.1175/BAMS-D-19-0316.1>.
- G.L. Kyriakopoulos, Circular economy and sustainable strategies: Theoretical framework, policies and regulation challenges, barriers, and enablers for water management, *Water Manag. Circ. Econ.* (2023) 197–230. <https://doi.org/10.1016/B978-0-323-95280-4.00014-X>.
- C. Faye, A.A. Sow, S. Dieye, Water management policy for freshwater security in the context of climate change in Senegal, *Clim. Chang. Water Resour. Africa Perspect. Solut. Towar. an Imminent Water Cris.* (2021) 255–276. [https://doi.org/10.1007/978-3-030-61225-2\\_12/COVER](https://doi.org/10.1007/978-3-030-61225-2_12/COVER).
- P.H. Gleick, H. Cooley, Freshwater Scarcity, <https://doi.org/10.1146/Annurev-Environ-012220-101319>. 46 (2021) 319–348. <https://doi.org/10.1146/ANNUREV-ENVIRON-012220-101319>.
- J. Rocha, C. Carvalho-Santos, P. Diogo, P. Beça, J.J. Keizer, J.P. Nunes, Impacts of climate change on reservoir water availability, quality and irrigation needs in a water scarce Mediterranean region (southern Portugal), *Sci. Total Environ.* 736 (2020) 139477. <https://doi.org/10.1016/J.SCITOTENV.2020.139477>.
- P.M.M. Soares, D.C.A. Lima, Water scarcity down to earth surface in a Mediterranean climate: The extreme future of soil moisture in Portugal, *J. Hydrol.* 615 (2022) 128731. <https://doi.org/10.1016/J.JHYDROL.2022.128731>.
- [13] S. Lu, B. Wu, N. Yan, H. Wang, Water body mapping method with HJ-1A/B satellite imagery, *Int. J. Appl. Earth Obs. Geoinf.* 13 (2011) 428–434. <https://doi.org/10.1016/J.JAG.2010.09.006>.
- W. Jiang, Y. Ni, Z. Pang, X. Li, H. Ju, G. He, J. Lv, K. Yang, J. Fu, X. Qin, An Effective Water Body Extraction Method with New Water Index for Sentinel-2 Imagery, *Water* 2021, Vol. 13, Page 1647. 13 (2021) 1647. <https://doi.org/10.3390/W13121647>.
- X. Yang, Q. Qin, P. Grussenmeyer, M. Koehl, Urban surface water body detection with suppressed built-up noise based on water indices from Sentinel-2 MSI imagery, *Remote Sens. Environ.* 219 (2018) 259–270. <https://doi.org/10.1016/J.RSE.2018.09.016>.
- S. Ghosh, A. Pal, S. Jaiswal, K.C. Santosh, N. Das, M. Nasipuri, SegFast-V2: Semantic image segmentation with less parameters in deep learning for autonomous driving, *Int. J. Mach. Learn. Cybern.* 10 (2019) 3145–3154. <https://doi.org/10.1007/s13042-019-01005-5>.
- I. Papadeas, L. Tsochatzidis, A. Amanatiadis, I. Pratikakis, Real-Time Semantic Image Segmentation with Deep Learning for Autonomous Driving: A Survey, *Appl. Sci.* 2021, Vol. 11, Page 8802. 11 (2021) 8802. <https://doi.org/10.3390/APP11198802>.
- X. Liu, L. Song, S. Liu, Y. Zhang, A Review of Deep-Learning-Based Medical Image Segmentation Methods, *Sustain.* 2021, Vol. 13, Page 1224. 13 (2021) 1224. <https://doi.org/10.3390/SU13031224>.
- M.R. Ibrahim, J. Haworth, T. Cheng, Understanding cities with machine eyes: A review of deep computer vision in urban analytics, *Cities.* 96 (2020) 102481. <https://doi.org/10.1016/J.CITIES.2019.102481>.
- Y. Lu, D. Chen, E. Olaniyi, Y. Huang, Generative adversarial networks (GANs) for image augmentation in agriculture: A systematic review, *Comput. Electron. Agric.* 200 (2022) 107208. <https://doi.org/10.1016/J.COM-PAG.2022.107208>.
- X. Sang, L. Xue, X. Ran, X. Li, J. Liu, Z. Liu, Intelligent High-Resolution Geological Mapping Based on SLIC-CNN, *ISPRS Int. J. Geo-Information* 2020, Vol. 9, Page 99. 9 (2020) 99. <https://doi.org/10.3390/IJGI9020099>.
- M.E. El-sayed, A.W. Youssef, O.M. Shehata, L.A. Shihata, E. Azab, Computer vision for package tracking on omnidirectional wheeled conveyor: Case study, *Eng. Appl. Artif. Intell.* 116 (2022) 105438. <https://doi.org/10.1016/J.ENGAPPAI.2022.105438>.
- A. Vembadi, A. Menachery, M.A. Qasaimeh, Cell Cytometry: Review and Perspective on Biotechnological Advances, *Front. Bioeng. Biotechnol.* 7 (2019) 462391. <https://doi.org/10.3389/FBIOE.2019.00147/BIBTEX>.
- H. Farias, D. Ortiz, G. Damke, M. Jaque Arancibia, M. Solar, Mask galaxy: Morphological segmentation of galaxies, *Astron. Comput.* 33 (2020) 100420. <https://doi.org/10.1016/J.ASCOM.2020.100420>.
- I.J. Kadhim, P. Premaratne, A Novel Deep Learning Framework for Water Body Segmentation from Satellite Images, *Arab. J. Sci. Eng.* 48 (2023) 10429–10440. <https://doi.org/10.1007/S13369-023-07680-5/FIGURES/4>.
- Z. Ma, M. Xia, L. Weng, H. Lin, Local Feature Search Network for Building and Water Segmentation of Remote Sensing Image, *Sustain.* 2023, Vol. 15, Page 3034. 15 (2023) 3034. <https://doi.org/10.3390/SU15043034>.
- K. Yuan, X. Zhuang, G. Schaefer, J. Feng, L. Guan, H. Fang, Deep-Learning-Based Multispectral Satellite Image Segmentation for Water Body Detection, *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* 14 (2021) 7422–7434. <https://doi.org/10.1109/JSTARS.2021.3098678>.
- M. Wieland, S. Martinis, R. Kiefl, V. Gstaiger, Semantic segmentation of water bodies in very high-resolution satellite and aerial images, *Remote Sens. Envi-*

- ron. 287 (2023) 113452. <https://doi.org/10.1016/J.RSE.2023.113452>.
- R.G. Tambe, S.N. Talbar, S.S. Chavan, Deep multi-feature learning architecture for water body segmentation from satellite images, *J. Vis. Commun. Image Represent.* 77 (2021) 103141. <https://doi.org/10.1016/J.JVCIR.2021.103141>.
- GitHub - facebookresearch/detectron2: Detectron2 is a platform for object detection, segmentation and other visual recognition tasks., (n.d.). <https://github.com/facebookresearch/detectron2> (accessed August 31, 2023).
- A.B. Abdusalomov, B.M.S. Islam, R. Nasimov, M. Mukhiddinov, T.K. Whangbo, An Improved Forest Fire Detection Method Based on the Detectron2 Model and a Deep Learning Approach, *Sensors* 2023, Vol. 23, Page 1512. 23 (2023) 1512. <https://doi.org/10.3390/S23031512>.
- V. Pham, C. Pham, T. Dang, Road Damage Detection and Classification with Detectron2 and Faster R-CNN, *Proc. - 2020 IEEE Int. Conf. Big Data, Big Data 2020.* (2020) 5592–5601. <https://doi.org/10.1109/BIGDATA50022.2020.9378027>.
- R. Divya, J.D. Peter, Smart healthcare system-a brain-like computing approach for analyzing the performance of detectron2 and PoseNet models for anomalous action detection in aged people with movement impairments, *Complex Intell. Syst.* 8 (2022) 3021–3040. <https://doi.org/10.1007/S40747-021-00319-8/FIGURES/21>.
- B. Rai, S.A.S. Kumar, F. Chincholi, H. Koestler, Detectron2 for Lesion Detection in Diabetic Retinopathy, *Algorithms* 2023, Vol. 16, Page 147. 16 (2023) 147. <https://doi.org/10.3390/A16030147>.
- G. Merz, Y. Liu, C.J. Burke, P.D. Aleo, X. Liu, M. Carrasco, V. Kindratenko, Y. Liu, Detection, Instance Segmentation, and Classification for Astronomical Surveys with Deep Learning (DeepDISC): Detectron2 Implementation and Demonstration with Hyper Suprime-Cam Data, *MNRAS.* 000 (2023) 1–16. <https://arxiv.org/abs/2307.05826v1> (accessed September 1, 2023).
- .F. Restrepo-Arias, P. Arregocés-Guerra, J.W. Branch-Bedoya, Crops Classification in Small Areas Using Unmanned Aerial Vehicles (UAV) and Deep Learning Pre-trained Models from Detectron2, *Intell. Syst. Ref. Libr.* 226 (2023) 273–291. [https://doi.org/10.1007/978-3-031-08246-7\\_12/COVER](https://doi.org/10.1007/978-3-031-08246-7_12/COVER).
- Tian, Z. Chu, Q. Hu, L. Ma, Class-Wise Fully Convolutional Network for Semantic Segmentation of Remote Sensing Images, *Remote Sens.* 2021, Vol. 13, Page 3211. 13 (2021) 3211. <https://doi.org/10.3390/RS13163211>.
- O. Póvoa, V. Lopes, A.M. Barata, N. Farinha, Monitoring Genetic Erosion of Aromatic and Medicinal Plant Species in Alentejo (South Portugal), *Plants.* 12 (2023) 2588. <https://doi.org/10.3390/PLANTS12142588/S1>.
- C. Santos-Silva, R. Louro, Assessment of the diversity of epigeous Basidiomycota under different soil-management systems in a montado ecosystem: a case study conducted in Alentejo, *Agrofor. Syst.* 90 (2016) 117–126. <https://doi.org/10.1007/S10457-015-9800-3/FIGURES/2>.
- I. Pulido-Calvo, J.C. Gutiérrez-Estrada, V. Sanz-Fernández, Drought and Ecological Flows in the Lower Guadiana River Basin (Southwest Iberian Peninsula), *Water* 2020, Vol. 12, Page 677. 12 (2020) 677. <https://doi.org/10.3390/W12030677>.
- A.A. Rodríguez Sousa, C. Tribaldos-Anda, S.A. Prats, C. Brígido, J. Muñoz-Rojas, A.J. Rescia, Impacts of Fertilization on Environmental Quality across a Gradient of Olive Grove Management Systems in Alentejo (Portugal), *Land.* 11 (2022) 2194. <https://doi.org/10.3390/LAND11122194/S1>.
- SNIRH :: Sistema Nacional de Informação de Recursos Hídricos, (n.d.). <https://snirh.apambiente.pt/> (accessed September 29, 2023).
- C. Andrade, J. Contente, J.A. Santos, Climate change projections of dry and wet events in iberia based on the wasp-index, *Climate.* 9 (2021). <https://doi.org/10.3390/cli9060094>.

## Sobre los autores

### Samuel Fernandes:

Concluiu a Licenciatura em Engenharia do Ambiente no Instituto Politécnico de Bragança, Portugal, em 2014, onde foi distinguido como o melhor aluno do curso nesse ano. Obteve o grau de Mestre em Tecnologia Ambiental

no Instituto Politécnico de Bragança, em 2015, tendo desenvolvido um sistema de monitorização e controlo da qualidade do ar interior: construção, validação e aplicação como parte do seu projeto de mestrado. Em 2023, concluiu com sucesso o seu Programa Doutoral na Universidade de Évora, obtendo o grau de Doutor em Engenharia Mecatrónica e Energética, com

especialização em Mecatrónica. Durante o seu percurso de doutoramento, contribuiu significativamente para o desenvolvimento de instrumentação optoelectrónica de última geração especialmente concebida para a avaliação da qualidade da água. Recebeu um prestigioso convite da Universidade de Évora para integrar o corpo docente como professor no próximo ano letivo de 2023. A Universidade solicitou especificamente que lecionasse o curso "Energia Solar Fotovoltaica" como parte do programa de licenciatura em Engenharia de Energias Renováveis. Desde 2019, exerce a função de Técnico Sénior na Agência Portuguesa do Ambiente/Administração Regional de Recursos Hídricos do Alentejo, no departamento de Planeamento e Informação. Recebeu da Agência para a Modernização Administrativa uma menção honrosa pelo Sistema de Incentivo à Inovação Pública na categoria de Desenvolvimento de Modelos de Gestão. Na vanguarda dos seus interesses de pesquisa está o avanço das técnicas de deteção remota com vista à otimização dos processos de gestão e tomada de decisão. Em particular, dedica-se ao desenvolvimento de dispositivos optoelectrónicos que permitem a monitorização em tempo real da qualidade da água. Com experiência em espectroscopia UV/Vis, sistemas embarcados, modelos numéricos e análise de grandes volumes de dados, possui um conhecimento abrangente das várias áreas que contribuem para os seus objetivos de investigação.

#### **Alice Maria Guerreiro Fialho**

Licenciada em Engenharia dos Recursos Hídricos (1997) – Universidade de Évora

Mestre em Georrecursos (2008) – Instituto Superior Técnico  
Formação profissional: Curso de ArcGis (9.2) Avançado

Técnica Superior na Agência Portuguesa do Ambiente, I.P. Assume as funções de Chefe de Divisão de Planeamento e Informação da Administração da Região Hidrográfica do Alentejo, na Agência Portuguesa do Ambiente, I.P., desde abril de 2013 até ao presente.

Possui 26 anos de experiência profissional nas áreas de planeamento, gestão, monitorização e licenciamento de recursos hídricos, no âmbito da qual se destacam as seguintes tarefas:

- Conceção, implementação, gestão e exploração de redes de monitorização de recursos hídricos e produção de informação técnica;
- Coordenação regional de Planos de Gestão de Região Hidrográfica (PGRH) e de Planos de Gestão de Riscos de Inundações (PGRI);
- Acompanhamento técnico de projetos, direção e

coordenação de obras de execução de piezómetros de redes de monitorização; seleção de equipamentos de aquisição de dados automáticos com vista à instrumentação de redes de monitorização e elaboração de processos de concurso para implementação de estações de monitorização.

- Articulação entre atividades de monitorização e de licenciamento de utilizações de recursos hídricos, no contexto da análise de dados de autocontrolo e do estado das massas de água, bem como tarefas de apoio à definição de metodologias e procedimentos de trabalho, propostas de orientação técnica e modelos e atuação, no âmbito da análise e emissão de títulos de utilização de recursos hídricos.
- Elaboração de registo de zonas protegidas de captação de recursos hídricos superficiais e subterrâneos, e de propostas para regulamentação de zonas protegidas.
- Emissão de pareceres de afetação de recursos hídricos no âmbito de: ações com potenciais impactes de poluição difusa; avaliação de impacte ambiental; áreas estratégicas de proteção e recarga de aquíferos, entre outros.

#### **Isabel Silva Patriarca**

Licenciada em Engenharia Geográfica (Pré-Bolonha, 5 anos), fez parte do organismo pertencente ao Ministério da Defesa Português, o Instituto Hidrográfico desde meados dos anos 90 até 2018. Foi pioneira no lançamento da cartografia náutica digital eletrónica oficial (CEN) para navegação segura, produto baseado em Sistemas de Informação Geográfica, tendo integrado a equipa responsável de produção e validação em Portugal. Seguiu-se um período em que foi responsável no mesmo Instituto pela gestão dos Sistemas de Informação na produção de cartografia náutica oficial eletrónica e em papel e atualização destes produtos cartográficos. Atualmente encontra-se a exercer funções no âmbito dos Sistemas de Informação Geográfica e Observação da Terra, dando também apoio aos Sistemas de Informação na Agência Portuguesa do Ambiente I.P. / Administração da Região Hidrográfica do Tejo e Oeste, no departamento de Planeamento e Informação. Tem conhecimentos em linguagem de programação Phyton, Machine Learning e manipulação de imagens de satélite. Autora de artigos apresentados nas JiiDES de 2021 e 2022 e publicados na revista Mapping - Jornal Internacional de Geomática e Ciências da Terra. Autora de diversos outros artigos apresentados em conferências e jornadas e publicados nas respetivas revistas da especialidade. Membro da Ordem dos Engenheiros.