

# Deteção e Delimitação de Corpos de Água em Imagens de Satélite de Alta Resolução com Aprendizagem Profunda: Um Estudo Preliminar com o Detectron2

**Samuel Fernandes, PhD**

Agência Portuguesa do Ambiente

ARH Alentejo - DPI

Técnico Superior

**Alice Fialho, MSc**

Agência Portuguesa do Ambiente

ARH Alentejo - DPI

Chefe Divisão

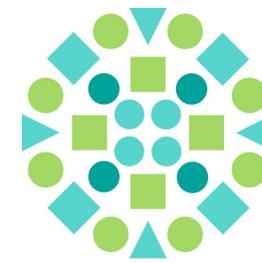
**Isabel Patriarca, MSc**

Agência Portuguesa do Ambiente

ARH Tejo e Oeste - DPI

Técnico Superior

# Plano de Apresentação



1. Introdução
2. Descrição do Fluxo de Trabalho
3. Local de estudo
4. Dados de base e armazenamento de informação
5. Segmentação, anotação de corpos de água e treino
6. Arquitetura do Modelo
7. Conversão de coordenadas DATUM WGS84
8. Resultados
9. Conclusões

# 1. Introdução



Ecosistemas



Biodiversidade



Sociedade Humana



Agricultura



Pecuária



Indústria



Ambiente  
Domestico

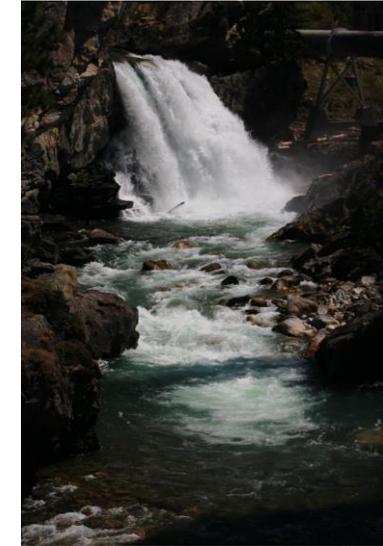


Turismo

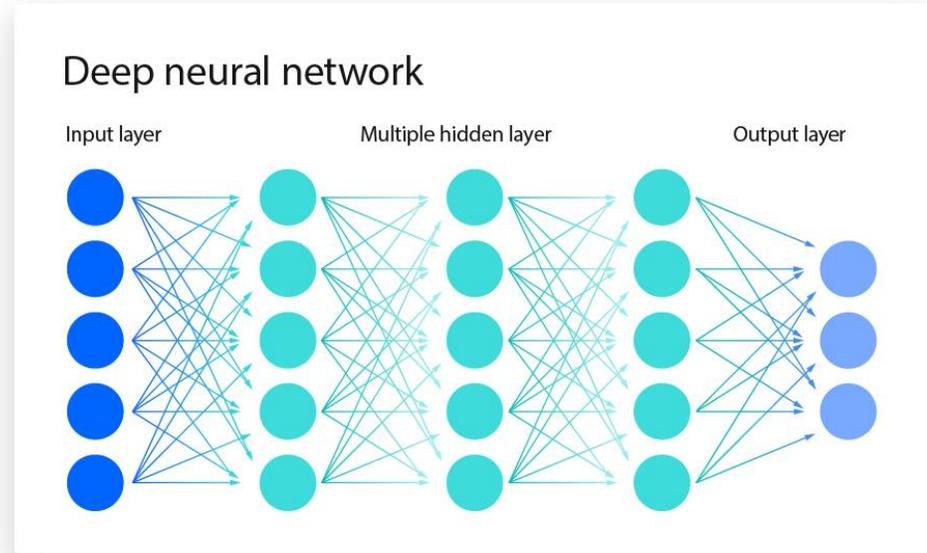
# 1. Introdução

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.

- Avaliação das disponibilidades hídricas do território;
- Melhor compreensão dos impactes das alterações climáticas;
- Preservação dos serviços de ecossistema relacionados com os recursos hídricos e;
- Implementação de atividades e programas voltados para a gestão da água, abrangendo desde estratégias de captação até ao tratamento de efluentes líquidos.



# 1. Introdução



# 1. Introdução

Neste trabalho, propomos uma metodologia de extração de corpos de água utilizando a framework estado-de-arte Detectron2 baseada em Pythorch.



## Detectron2

Esta plataforma de visão computacional permite desenvolver métodos de **segmentação de instancias, semântica, panótica, Densee pose, Cascade R-CNN, caixas delimitadoras rotacionadas, PointRend, DeepLab, ViTDet, MViTv2.**

Tem sido amplamente utilizada na:

**Deteção de Fogos Florestais**

**Cuidados de Saúde**

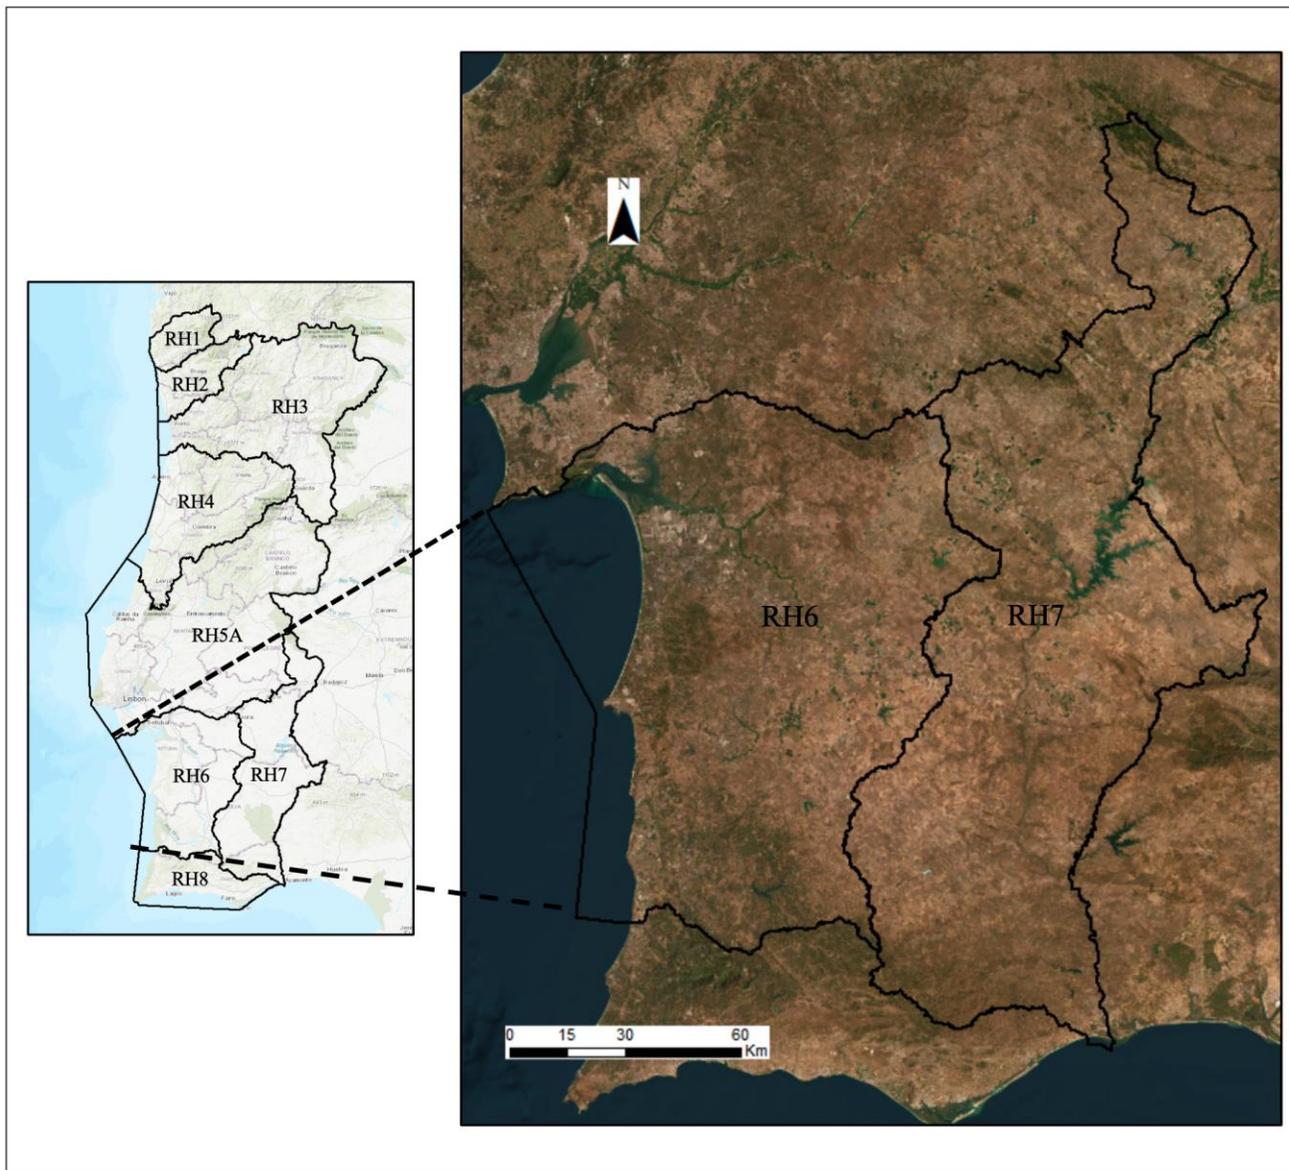
**Agronomia**

**Deteção e classificação de danos em estradas**

## 2. Descrição do Fluxo de Trabalho



# 3. Local de estudo

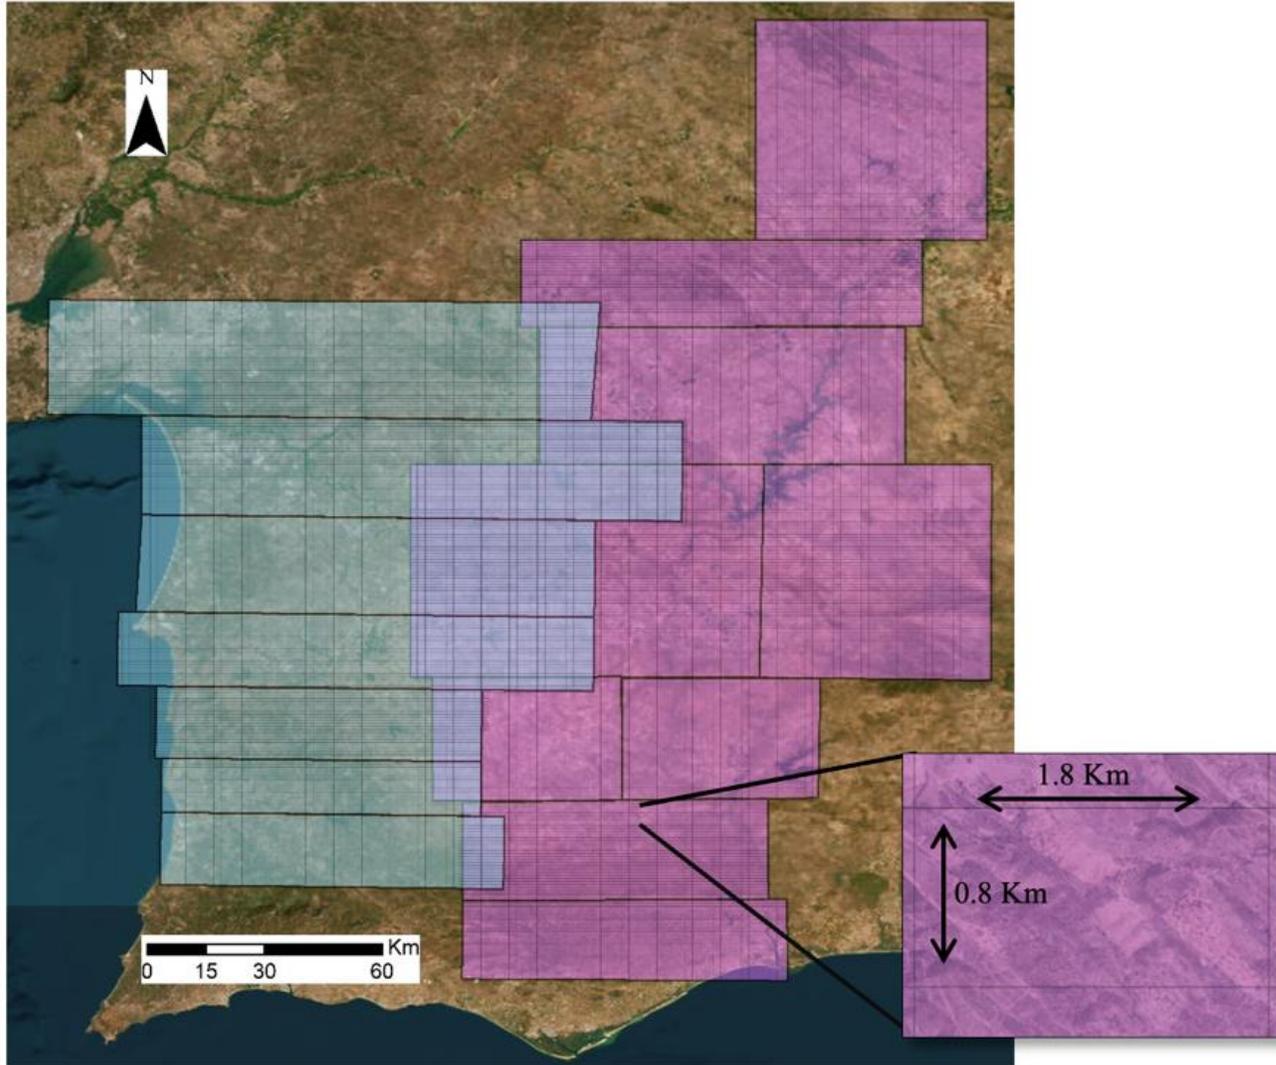
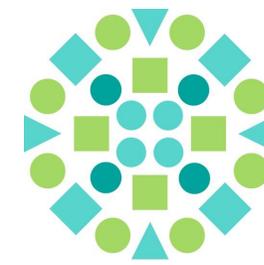


O estudo realizado centra-se nas duas Regiões Hidrográficas do Alentejo, RH6 e RH7.

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 Guadiana e as bacias hidrográficas das ribeiras de costa.

## 4. Dados de base e armazenamento de informação



As imagens foram recolhidas em blocos retangulares que cobrem as duas Regiões Hidrográficas.

RH6 - 7 Blocos

RH7 - 9 blocos

Cada um dos blocos foi subdividido em quadrículas com 1.8 km de comprimento e 0.8 km de largura, com o zoom ao nível 17.

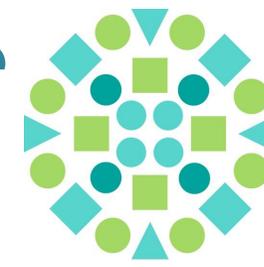
Dimensão espacial de 1942 x 860 pixels

Módulo python satellite imagery downloader (SDI)

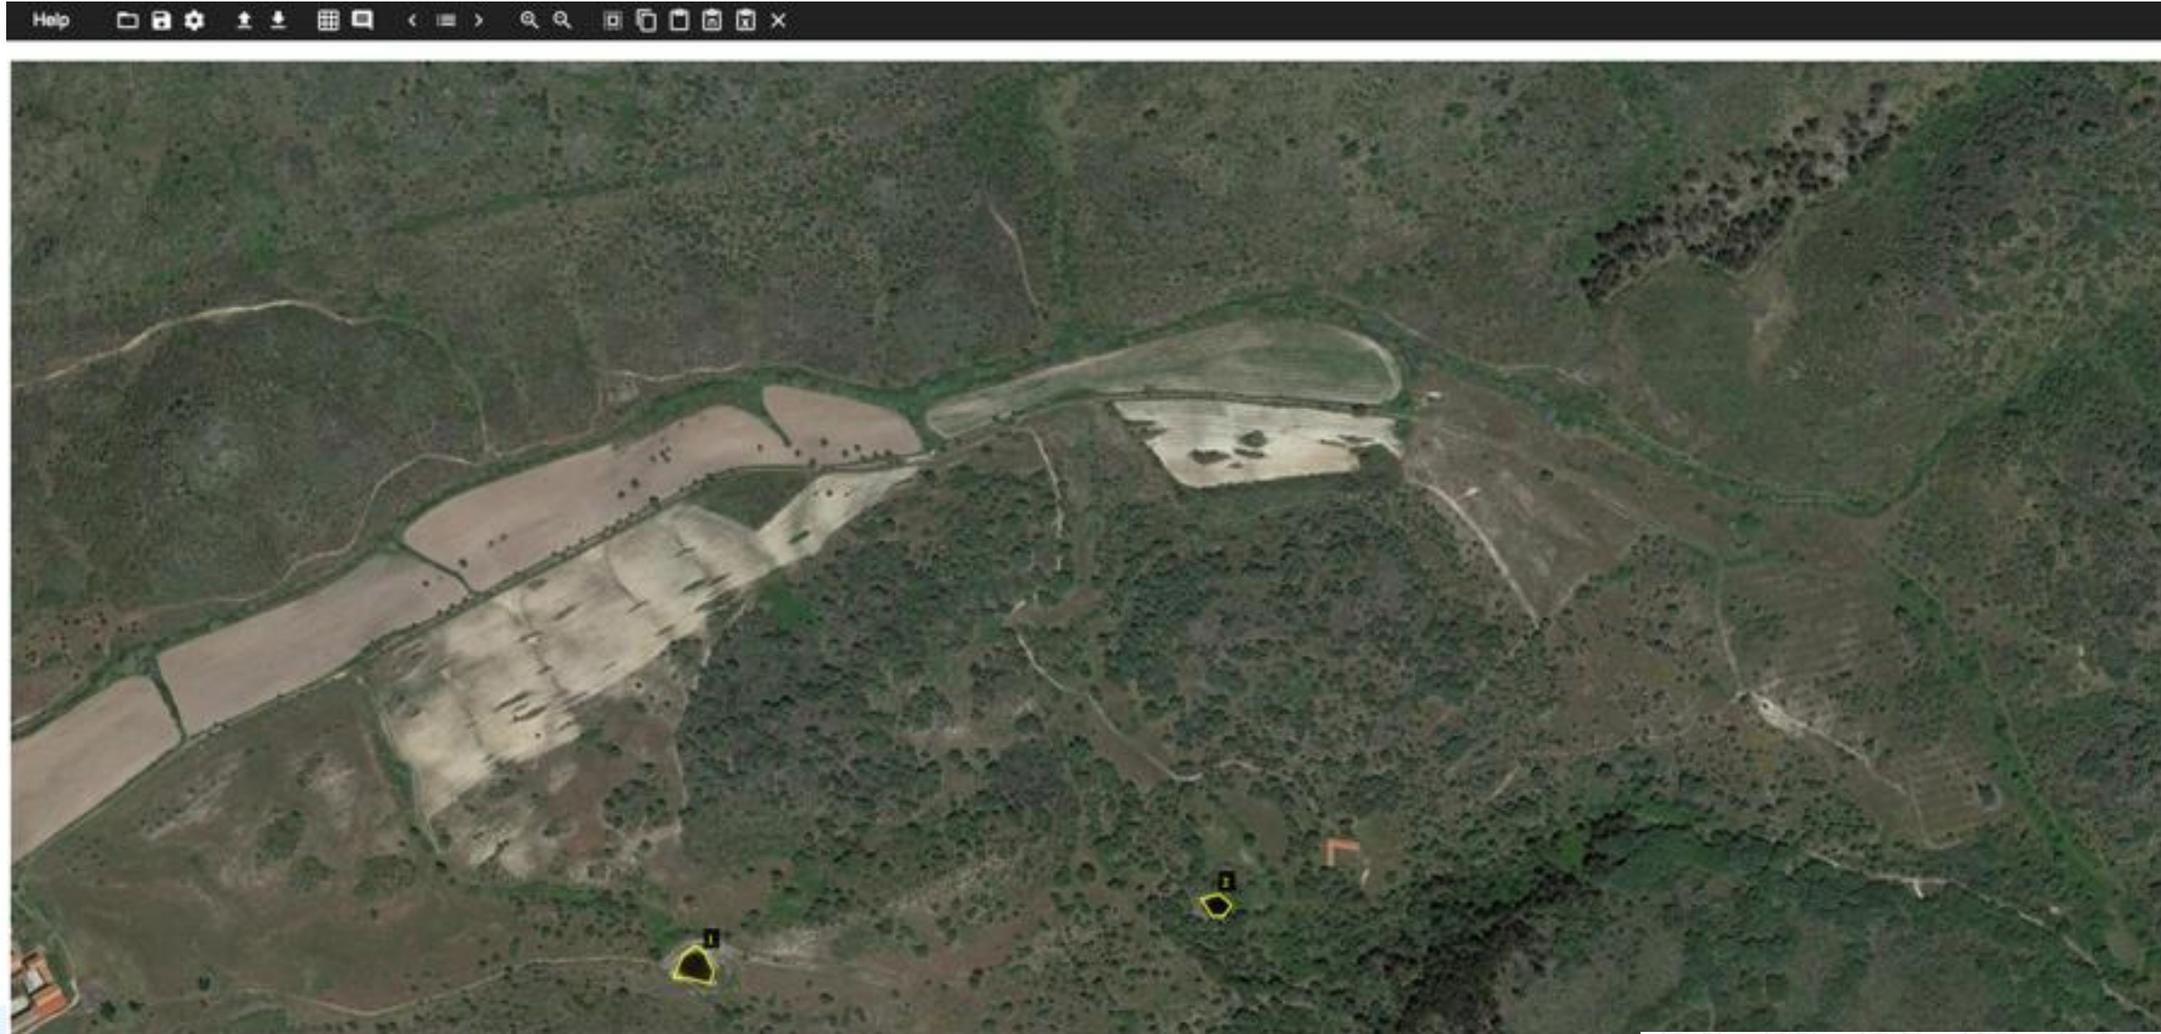
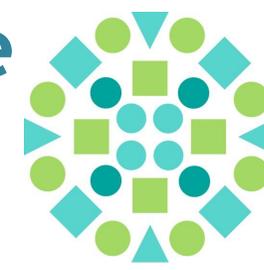
Google Drive

Google Colab

# 5. Segmentação, anotação de corpos de água e treino

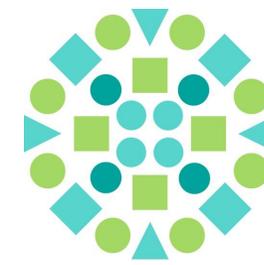


# 5. Segmentação, anotação de corpos de água e treino



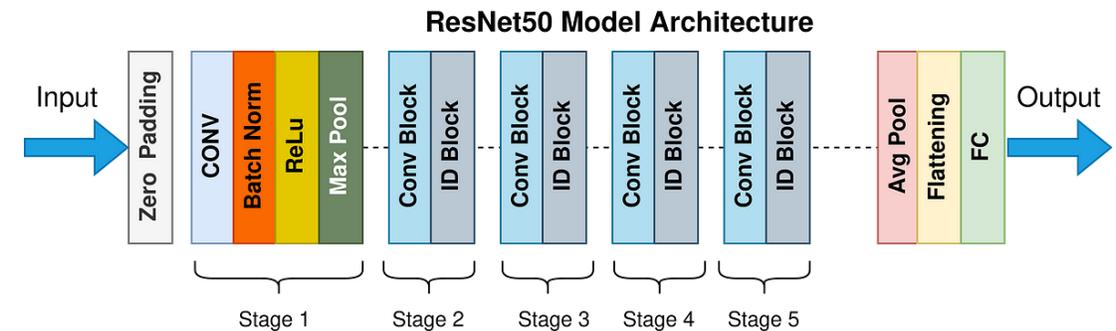
VGG Image Annotator (VIA)

# 6. Arquitetura do Modelo

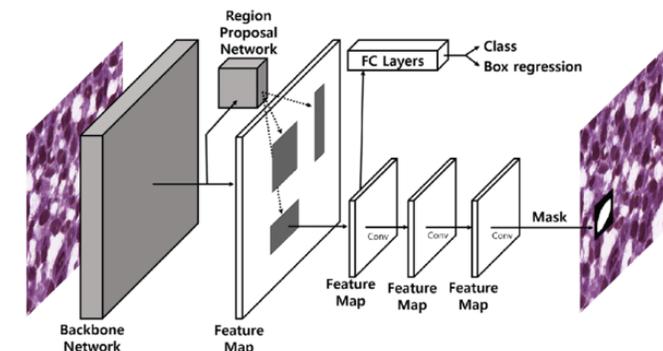


A Framework Detectron2 possui diferentes modelos de referência

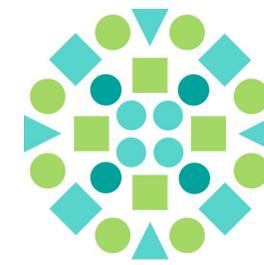
O *backbone* do modelo apresentado é a arquitetura ResNet-50, uma rede neural convolucional profundamente elaborada com 50 camadas



Mask R-CNN extensão ao Faster R-CNN - capacidade de segmentação por pixel



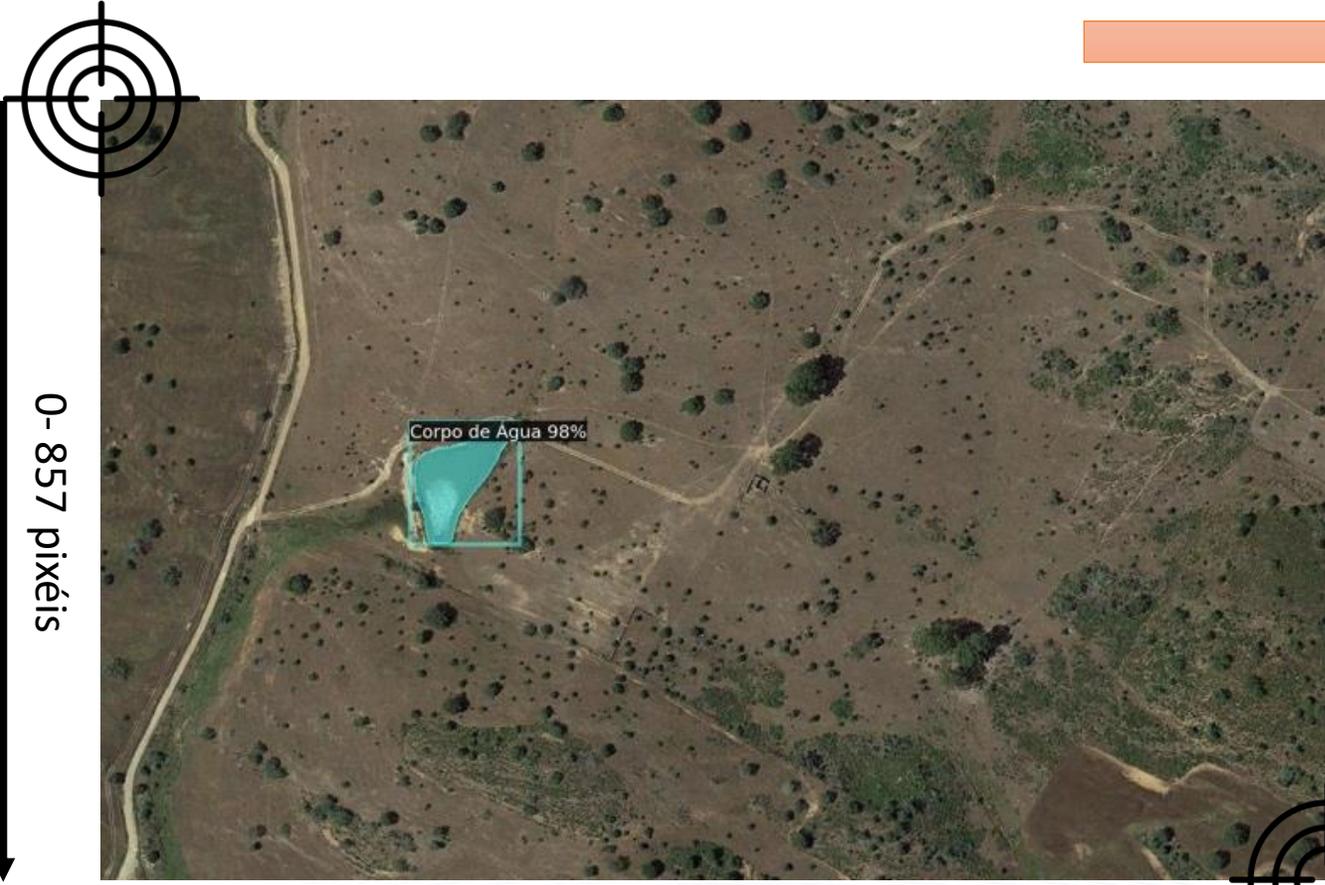
# 6. Arquitetura do Modelo



- **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 (overfitting), 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 pixels, 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.

# 7. Conversão de coordenadas DATUM WGS84

$$Y = \beta X + \epsilon$$



0- 1982 pixéis



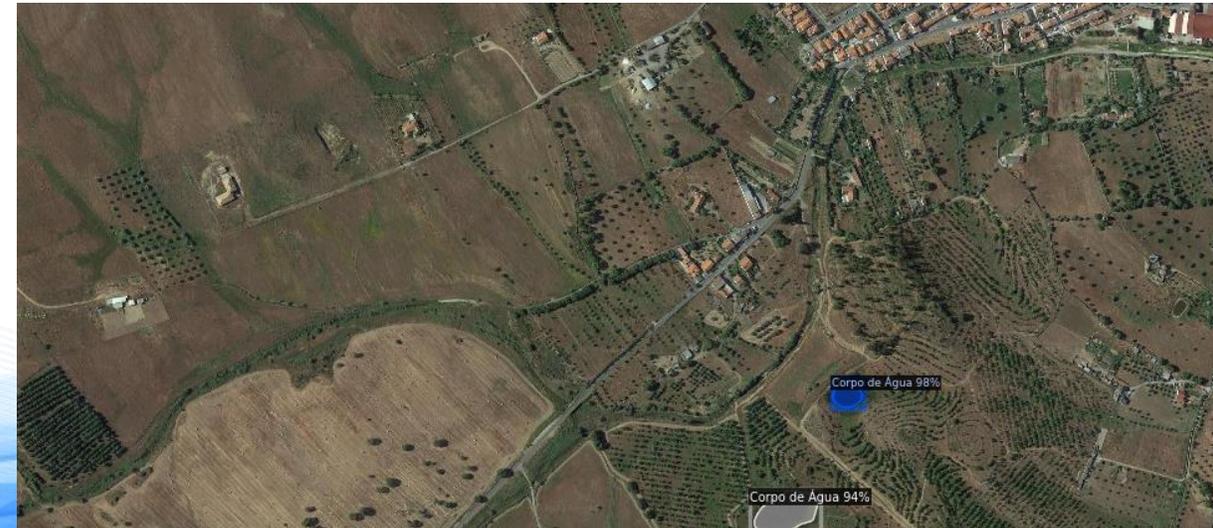
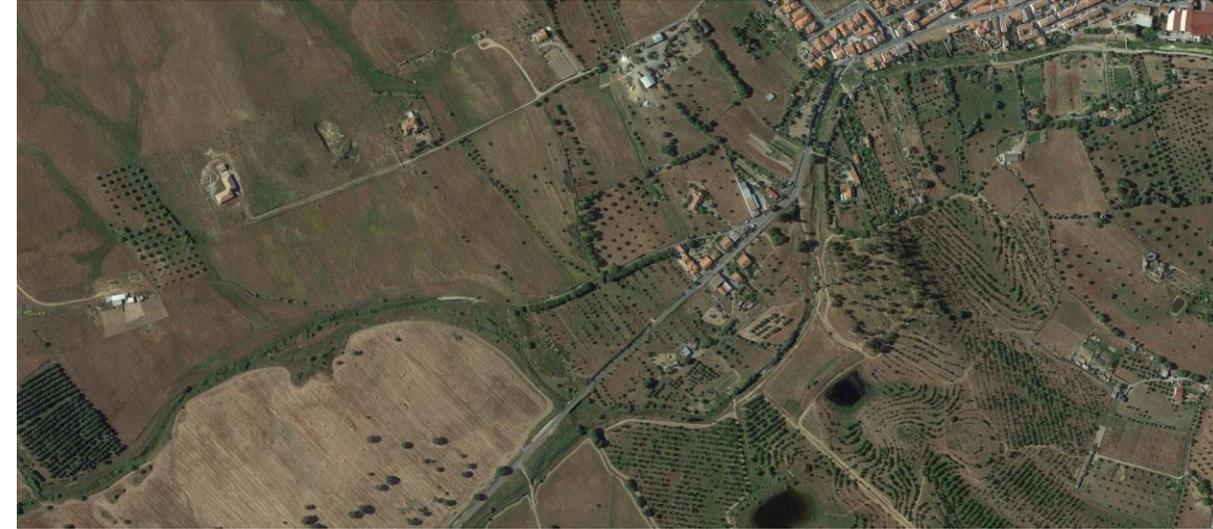
ArcGIS



# 8. Resultados



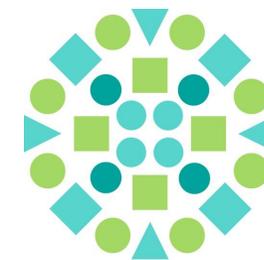
# 8. Resultados



# 8. Resultados

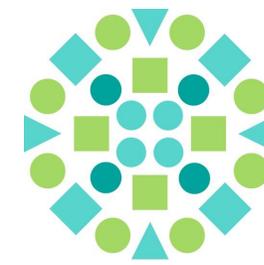


# 8. Resultados



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

## 8. Resultados (Dificuldades)



Como a RH6 apresenta um conjunto de características orográficas e culturas agrícolas próprias

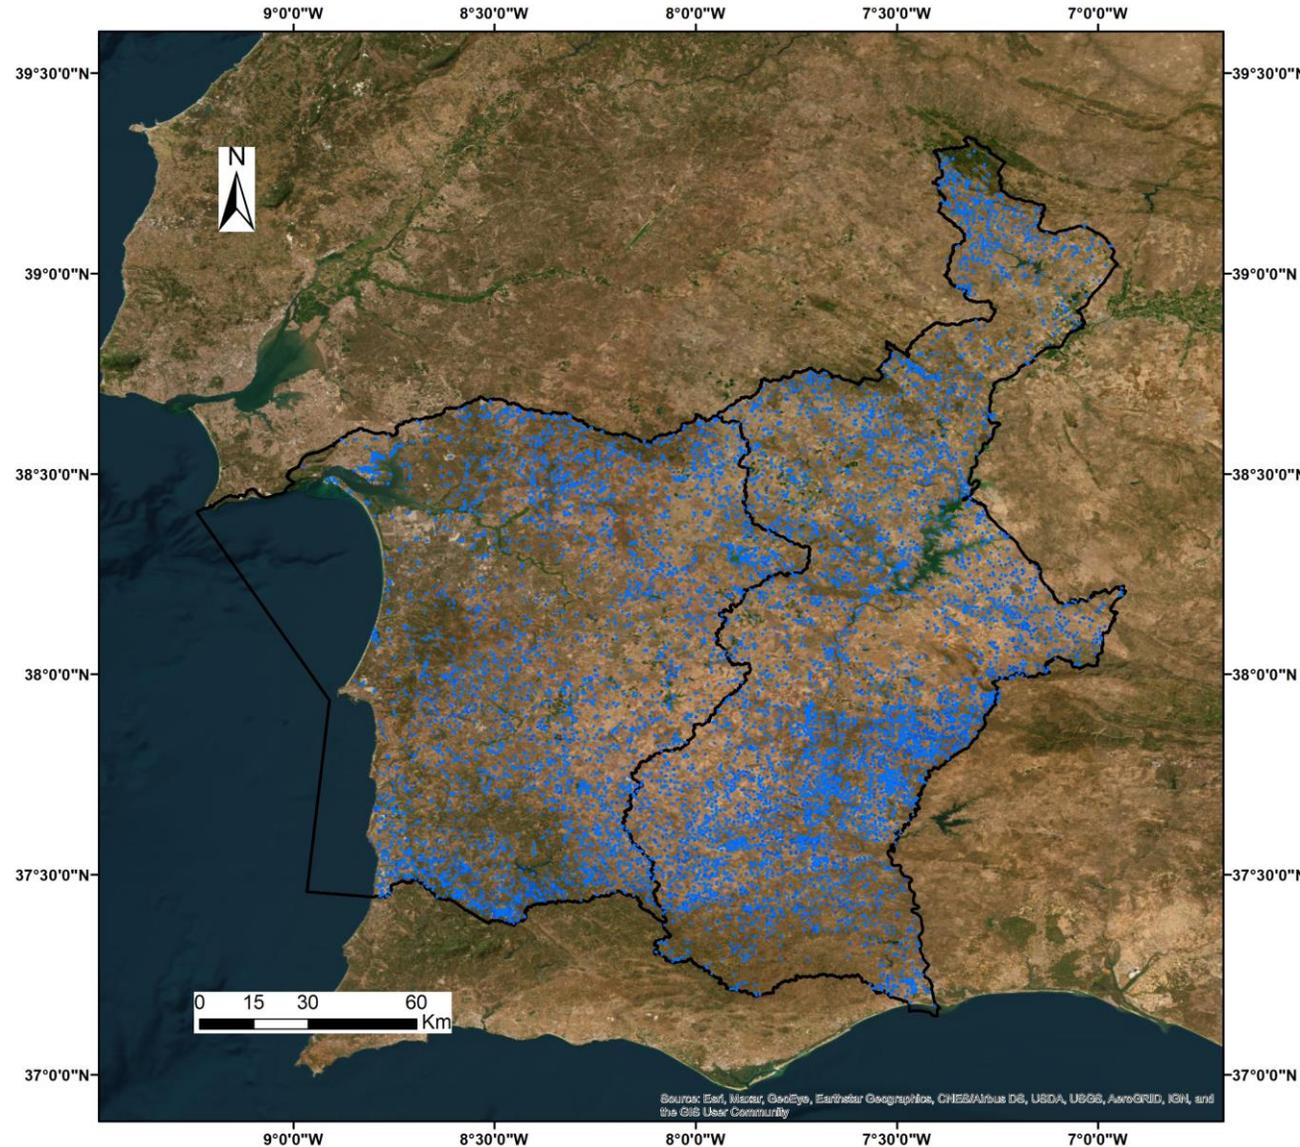
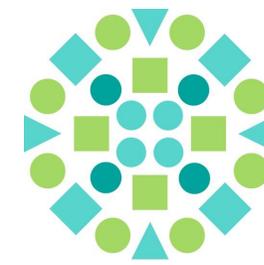
Num estágio preliminar que a utilização do modelo calibrado com informação da RH7 sobre a RH6 apresentava resultados pobres

Aumento de falsos positivos - classificação de copas de arvores tonalidade próxima da água

Sombras das arvores pela sua tonalidade e forma foram algumas vezes classificadas como corpos de água

Zonas urbanas - tendência para classificação de campos desportivos ou zonas de recreio como corpos de água

# 8. Resultados



# 9. Conclusões

Neste trabalho foi desenvolvido uma nova metodologia para análise de imagens de alta resolução com o objetivo de extrair informações sobre corpos de água superficiais em grande escala.

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%.

O algoritmo utilizou as vantagens das redes neurais convolucionais na extração de características, usando a arquitetura ResNet-50 conjugada com a arquitetura Mask R-CNN para obter características em diferentes níveis.

Pretende-se numa próxima abordagem utilizar os polígonos obtidos atualmente para treinar um modelo com uma maior taxa de acerto, exatidão e precisão.

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 aos:

- 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 gratitude 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.



**Muito Obrigado**

**Muchas Gracias**

**Samuel Fernandes**

samuel.fernandes@apambiente.pt

**Alice Fialho**

alice.fialho@apambiente.pt

**Isabel Patriarca**

isabel.patriarca@apambiente.pt