

Detección de línea de costa a partir de imágenes satelitales y algoritmos de aprendizaje profundo



Contexto y objetivos

El seguimiento y monitorización de la **línea de costa** es crucial para el desarrollo económico y social de las zonas costeras, acentuándose en los últimos años por las consecuencias del cambio climático.

La inteligencia artificial, más concretamente el **deep learning**, tiene un enorme potencial en el procesamiento de imágenes espaciales, permitiendo una **detección automática, instantánea y precisa**.

En este trabajo fin de grado se pretende diseñar un **modelo de red neuronal** capaz de detectar la línea de costa a nivel de píxel a partir de imágenes satelitales.

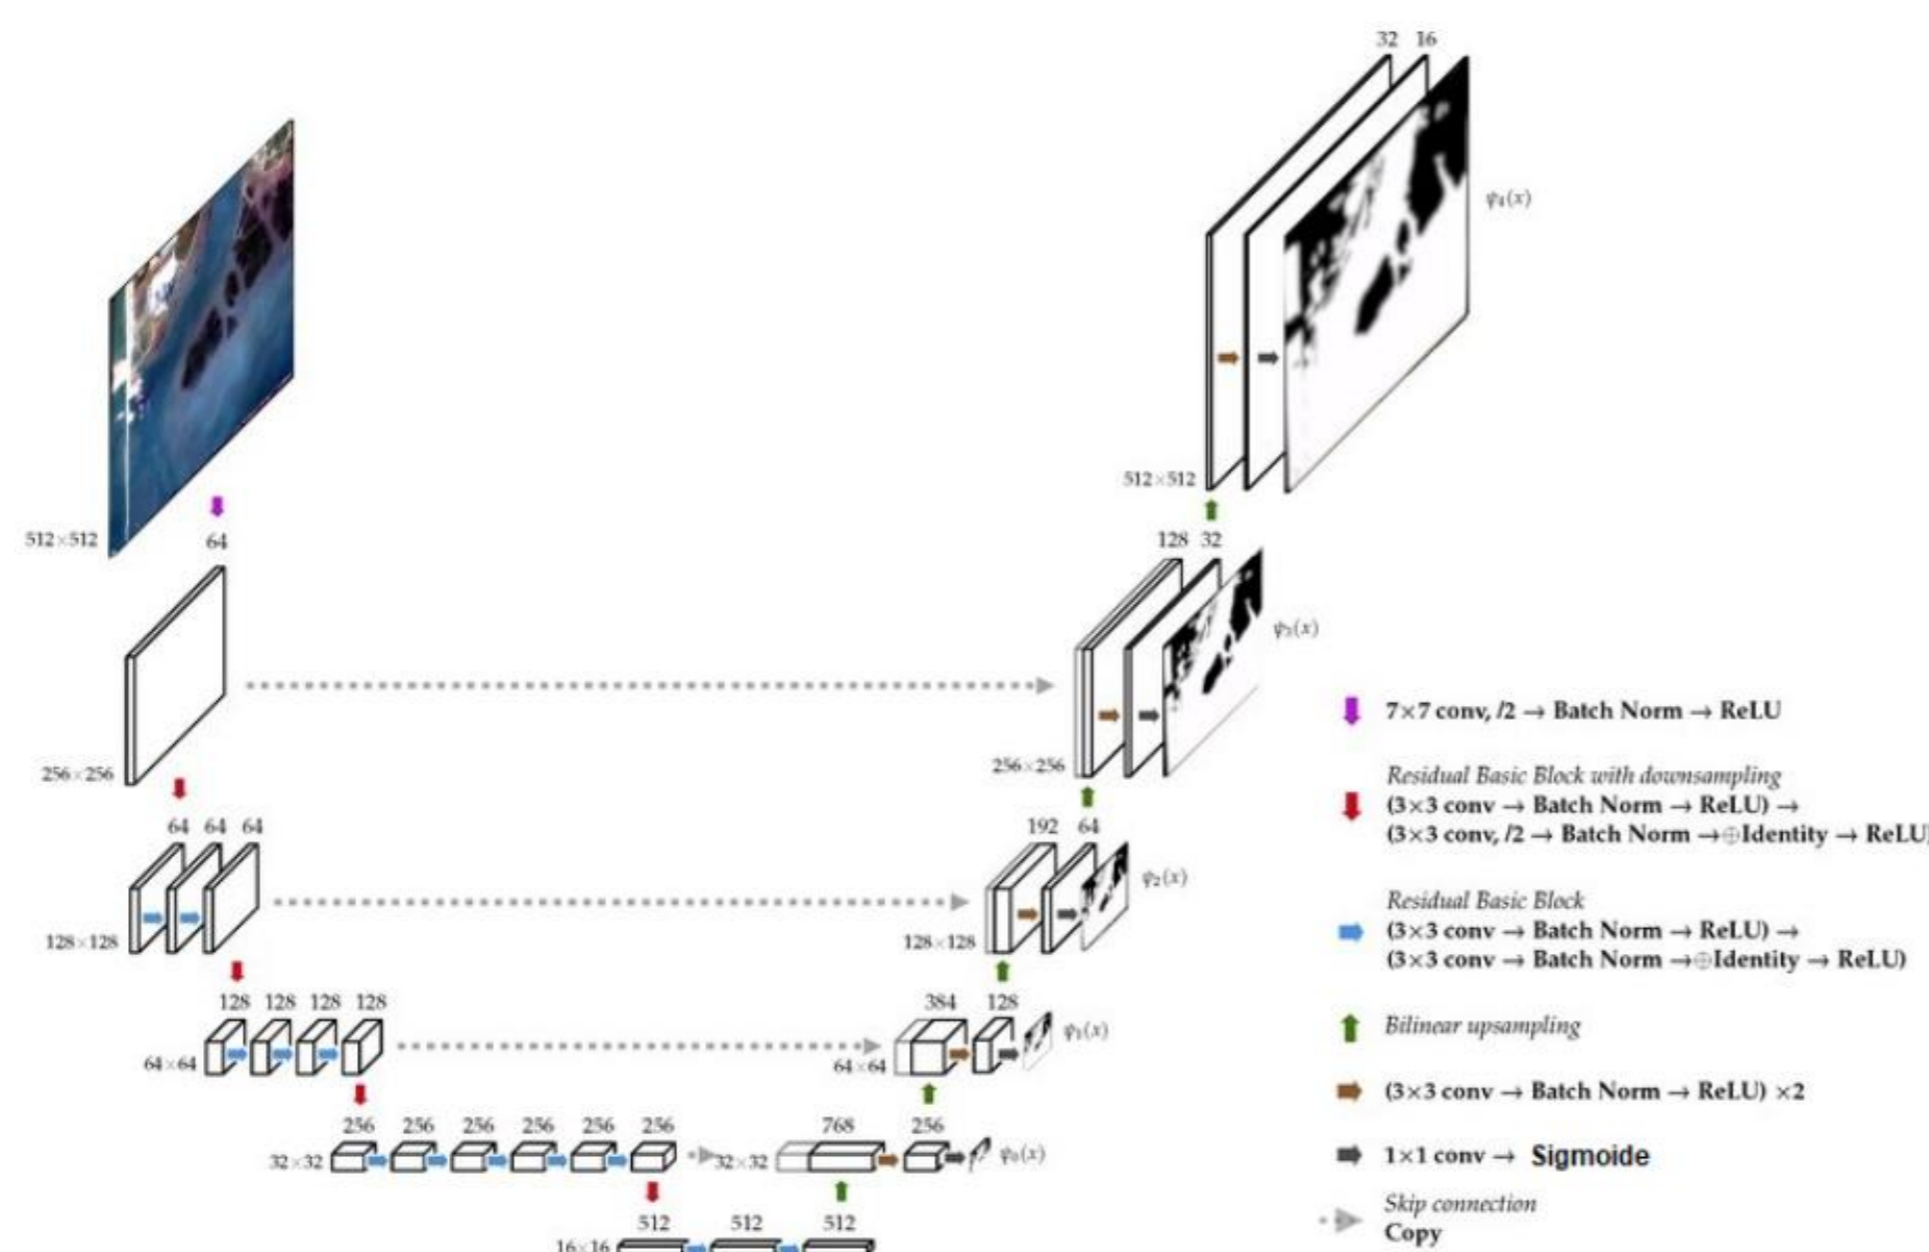
Bases de datos

Para el desarrollo del proyecto se han utilizado tres bases de datos:

- **SWED** para la implementación y entrenamiento del modelo.
- Una de elaboración propia, creada a partir de imágenes descargadas de **GEE** con sus correspondientes máscaras.
- Y una base de datos proporcionada por el grupo de **Cartografía GeoAmbiental y Teledetección** para su validación en diferentes entornos de la costa europea.

Modelo de red neuronal propuesto

El modelo propuesto, **U-Net**, es una arquitectura ampliamente utilizada en la segmentación de imágenes. Se caracteriza por su estructura de **encoder-decoder** que permite una segmentación precisa y detallada. Se caracteriza por tener una alta capacidad de aprendizaje gracias a su **arquitectura simétrica**, por su capacidad de manejar conjuntos de datos pequeños y la capacidad de preservar detalles sutiles mediante el uso de **skip-connections** que, en esencia, indican a la red de qué parte de la imagen proceden las características.



Conclusiones

El proyecto presenta el desarrollo y evaluación de un modelo de red neuronal para la detección de la línea de costa en imágenes de Sentinel-2.

Evaluación

La evaluación del modelo se ha llevado a cabo con las métricas de **Accuracy, Precision, Recall, Cohen's kappa coefficient, F1-Score, Dice coefficient** y **Matthew's correlation coefficient**.

| Descripción | Accuracy | Precision | Recall | Kappa | F1 score | Dice score | MCC |
|-------------|----------|-----------|--------|--------|----------|------------|--------|
| U-NET | 0.9296 | 0.9060 | 0.9574 | 0.8353 | 0.9139 | 0.9139 | 0.8426 |
| NDWI | 0.9403 | 0.9469 | 0.9345 | 0.8478 | 0.9327 | 0.9327 | 0.8519 |
| AWEINSH | 0.9215 | 0.9007 | 0.9544 | 0.8007 | 0.9177 | 0.9177 | 0.8079 |
| MNDWI | 0.8846 | 0.8563 | 0.9350 | 0.7166 | 0.8745 | 0.8745 | 0.7333 |
| AWEISH | 0.8686 | 0.9153 | 0.8374 | 0.7239 | 0.8385 | 0.8385 | 0.7357 |

Resultados sobre el conjunto de evaluación 1

| Descripción | Accuracy | Precision | Recall | Kappa | F1 score | Dice score | MCC |
|-------------|----------|-----------|--------|--------|----------|------------|--------|
| U-NET | 0.9965 | 0.9185 | 0.9097 | 0.9071 | 0.9089 | 0.9089 | 0.9097 |
| NDWI | 0.9957 | 0.9036 | 0.9092 | 0.8939 | 0.8961 | 0.8961 | 0.8990 |
| AWEINSH | 0.9953 | 0.9107 | 0.8749 | 0.8741 | 0.8763 | 0.8763 | 0.8819 |
| MNDWI | 0.9921 | 0.7522 | 0.9811 | 0.8392 | 0.8431 | 0.8431 | 0.8513 |
| AWEISH | 0.9917 | 0.7460 | 0.9887 | 0.8382 | 0.8423 | 0.8423 | 0.8511 |

Resultados sobre el conjunto de evaluación 2

Siendo el *conjunto de evaluación 1* el correspondiente a la partición de *test* reservada del conjunto de datos SWED y el *conjunto de evaluación 2* el proporcionado por el CGAT.



Los resultados son prometedores en términos de precisión y consistencia a nivel de píxel.