

INFORME/MEMORIA DE PRÁCTICAS

Reyes Fornas Sáez

1. Descripción concreta y detallada de las tareas, trabajos desarrollados y departamentos de la entidad a los que ha estado asignado.

En la Cátedra ENIA junto con el Laboratorio de Puertos y Costas de la Universidad Politécnica de Valencia se me encomendó la tarea de comprender y mejorar el método para conocer la progresión del daño en HLCS de Cubípodos a través del escaneo láser 3D desarrollado por Muñoz (2025).

Durante mis prácticas, he realizado dos cambios principalmente respecto al Método de Muñoz: la optimización de la red neuronal y la implementación del proceso en un solo programa, en este caso, Python. Es decir, se emplea un script constituido por un único módulo, es decir, un fichero de texto con extensión .py con un punto de ejecución al final de este, donde se utilizan librerías del sistema, se lanza por consola y en él se definen distintas funciones simples.

Cabe destacar que previamente a la mejora se ha hecho un estudio riguroso del método propuesto por Muñoz (2025) desde la toma de datos hasta la obtención de resultados.

1.1 Algunos problemas previos

Lo primero que se ha llevado a cabo en el desarrollo de este método mejorado ha sido conocer el funcionamiento del escáner Kinect 3D. Una vez toma los datos en una posición perpendicular al canal y por tanto a la estructura, devuelve una nube de puntos en “espejo”, es decir, completamente invertida tal y como él la ve, es por esto por lo que al final de la corrección de la refracción llevada a cabo por la red neuronal, es preciso hacer una simetría y la rotación correspondiente a la pendiente del canal para que los resultados sean fieles a los ensayos.




Figura 1. Vista de una estructura HLCS de Cubípodos captada por el escáner Kinect3D

Fuente: Elaboración propia

Otro de los problemas que se debía arreglar era la lectura de archivos desde Python. Muñoz (2025) renombró todos los ensayos para el funcionamiento de su método. Este hecho se ha eliminado para evitar ese preproceso de modificación de nombres y así lograr una mayor rapidez a la hora de implementar el código. Por lo tanto, en la versión mejorada se pueden emplear los ensayos con el nombre que reciben al ser tomados, sin modificaciones.

1.2 Optimización de la Red Neuronal

La red neuronal empleada por Muñoz (2025) es de tipo *feedforward* multicapa generada automáticamente por Matlab.

En la versión mejorada, se elabora en Python una configuración similar con algunas matizaciones descritas a continuación:

La arquitectura de la red está formada por tres partes principales: una capa de entrada, una capa oculta y una capa de salida. Antes de entrar a la red, la entrada, constituida por tres

variables, es normalizada transformando los datos originales a un rango entre $[-1,1]$, lo cual mejora la estabilidad numérica y facilita el entrenamiento de la red neuronal.

La capa oculta constituye el núcleo principal de la red. Está formada por 100 neuronas completamente conectadas con las tres entradas. Cada neurona calcula una combinación lineal de las entradas mediante una matriz de pesos y un término de sesgo. Posteriormente, el resultado pasa por una función de activación no lineal que en este caso es equivalente a la tangente hiperbólica. Así, la red puede modelar relaciones no lineales complejas entre las variables de entrada y salida.

En la última capa, la de salida, existe una única neurona conectada a las 100 neuronas ocultas mediante otra matriz de pesos. A diferencia de la capa oculta, aquí no se aplica ninguna función de activación no lineal; la salida es puramente lineal.

Finalmente, la salida calculada se desnormaliza, recuperando así la escala original de la variable objetivo. Esto permite que el valor final entregado por la red esté expresado en las mismas unidades que los datos reales utilizados durante el entrenamiento.

Para programar este proceso se emplea la librería de Scikit-Learn de Python. La red neuronal es de tipo MLP (Perceptrón Multicapa) con la función de activación “tanh” mencionada antes, que ayuda a la red a aprender relaciones complejas y no lineales. Por otro lado, como algoritmo optimizador se emplea el de tipo Adam, que es el estándar en la industria, ya que ajusta de manera inteligente la tasa de aprendizaje para cada parámetro de manera individual. Además, se establece una velocidad de aprendizaje estable de manera que la red entrena a un nivel no muy rápido para que pueda hacer bien su labor, ni muy lento para que el método sea eficiente. Por otro lado, se introducen: un número máximo de iteraciones, un criterio de parada (en este caso el *early stopping*) para evitar que la red se sobreentrene y un término de regularización para evitar el *overfitting* (que la red se memorice los datos de entrenamiento en lugar de aprender el patrón real).

1.3 Implementación del proceso en Python

Muñoz (2025) utilizó distintos programas para el procesado de datos y la corrección de la refracción. En este modelo, se emplea un único programa para mejorar el rendimiento.

El procedimiento es el siguiente:

1. El primer paso es generar líneas equiespaciadas centradas alrededor de los ejes X, Y.
2. Luego se define el mallado a partir del cual se asigna al centro de cada celda la $Z_{\max}$, eliminando las Z del resto de puntos que caigan en esa casilla.




Figura 2. Mallado en 2D.

Fuente: Elaboración propia.

3. Se hace la limpieza de *Outliers* y el suavizado de la superficie y se representan algunos perfiles para verificar que el proceso avanza adecuadamente.




Ilustración 3. Representación del perfil $X=0$ tras el preproceso.

Fuente: Elaboración propia.

4. Se toma el primer ensayo en seco y en mojado y se alinean los perfiles en ambos estados ya preprocesados y se lleva a cabo el mismo proceso para el último ensayo. Esto sirve para poder entrenar la red neuronal en el paso siguiente.
5. Se entrena la red neuronal para que esta corrija la distorsión generada por la presencia de agua. Por otro lado, se ejecuta una prueba de validación cruzada para evaluar la bondad del entrenamiento además de los parámetros estadísticos que se representan junto a sus respectivas bandas de ajuste.




Figura 4. Regresión del entrenamiento de la red neuronal.

Fuente: Elaboración propia.

6. Dado que los puntos tomados con el láser 3D están tomados en espejo, la nube de puntos está del revés. Por ello, se hace una transformación lineal (una simetría) para que la vista del dique sea la misma que en el canal.




Figura 5. Representación original de los perfiles.

Fuente: Elaboración propia.




Figura 6. Representación de los perfiles sin pendiente y tras aplicarles la simetría.

Fuente: Elaboración propia.

7. De los 25 perfiles que había originalmente, nos quedamos con 17. Es decir, se excluyen del estudio los más externos por las posibles interacciones de las paredes laterales con las ondas.




Figura 7. Representación de los 17 perfiles que constituyen un ensayo.

Fuente: Elaboración propia.

8. Se calculan los daños y el área acumulada. Los principales parámetros hidráulicos que explican el rendimiento de los HLCS son la erosión del revestimiento y la altura de la cresta. Estos también afectan a su respuesta hidráulica. Por lo tanto, cuanto mayor es el daño causado, es más probable que se vea afectada la altura de su cresta. Es importante remarcar que los HLCS son estructuras sin núcleo. Como consecuencia, la extracción o el movimiento de las unidades de revestimiento pueden alterar su forma y su comportamiento hidráulico.

El parámetro de daño empleado en este Trabajo de Fin de Grado es el daño adimensional (Broderick y Ahrens, 1982). Es el siguiente:

$$S_e^k = A_e^k / D_n^2$$

Donde A_e^k es el área erosionada de la k-ésima prueba y D_n es el diámetro nominal de la unidad de revestimiento. Para cada una de las pruebas, indicada con el superíndice

k, tanto la erosión como la acreción pueden distinguirse fácilmente comparando las coordenadas Z entre los perfiles de la k-ésima prueba $z^k(x, y)$ y su estado inicial $z^0(x, y)$. La erosión aparece cuando z^k es menor que el estado inicial, $z^k < z^0$. Por el contrario, la acreción se mide cuando $z^k > z^0$. Matemáticamente esto se expresa de la siguiente manera:

$$z_e^k(x_i, y_j) = \left[[z^0(x_i, y_j) - z^k(x_i, y_j)]_{i=1}^{N_{\text{puntos}}}, \text{ si } z^0 > z^k, \text{ sino } 0 \right]_{j=1}^{N_{\text{perfiles}}}$$

Donde $z^0(x, y)$ y $z^k(x, y)$ corresponden a las nubes de puntos del estado inicial o y de la k-ésima prueba. Cada punto de la cuadrícula $z(x_i, y_j)$ está indexado. Las coordenadas X, son múltiplos de $x_i = x_{\text{mín}} + i \cdot \Delta_x/2$ donde i es el subíndice de indexación dentro de los perfiles, $1 \leq i \leq N_{\text{puntos}}$, mientras que las coordenadas Y son múltiplos de $y_j = y_{\text{mín}} + j \cdot \Delta_y/2$, donde j es el subíndice utilizado para recorrer cada perfil j-ésimo, $1 \leq j \leq N_{\text{perfiles}}$.

Por lo tanto, el área erosionada es la integral definida de la curva

$$A_{e,j}^k = \left[\sum_{i=1}^{N_{\text{puntos}}} \frac{z_{e,j}^k(x_i, y_j) + z_{e,j}^k(x_i, y_j)}{2} \cdot (x_i - x_{i-1}) \right]_{j=1}^{N_{\text{puntos}}}$$

Este cálculo es equivalente a la suma acumulativa de $z_{e,j}^k(x, y)$. Finalmente, el promedio entre todos los perfiles internos corresponde al valor representativo del daño, expresado como:

$$S_e^k = \frac{1}{N_{\text{perfiles}}} \sum_{j=1}^{N_{\text{perfiles}}} A_{e,j}^k / D_n^2$$

9. Se aplica la rotación del canal (del 2%) una vez obtenidos los datos de interés en el paso anterior.
10. De cada uno de los 17 perfiles, tras el preproceso y la corrección con la red neuronal, se obtiene el punto más alto y a partir de este, se hace un corte de un Dn hacia abajo. De la región comprendida entre dicho corte y el punto más alto, se sacan los percentiles del 90%, el 95%, el 98% y el 99%.
11. Los cortes de dichos percentiles con la superficie del dique determinan el ancho de la estructura para cada una de las alturas.
12. Se extrae una hoja Excel con una tabla donde se especifican los nombres de los ensayos evaluados, el daño producido de cada uno de los perfiles en comparación con el original, las alturas de los percentiles y los anchos asociados a cada una de ellas.

2. Valoración de las tareas desarrolladas con los conocimientos y competencias adquiridas en relación con los estudios universitarios

Comprender todo lo relativo a las obras marítimas me ha resultado sencillo porque la mayoría de conceptos los había visto en el Grado de Ingeniería Civil. Sin embargo, la parte de Redes Neuronales me resultó más complicada porque a pesar de haberlo visto en el Grado de Matemáticas, lo vimos en otro programa distinto a Python y de forma muy superficial. Además, lo vimos de manera matemática (la arquitectura de las redes), pero su programación no la vimos con detalle.

3. Relación de los problemas planteados y de los procedimientos seguidos para su resolución.

Tuve dos tipos de problemas:

1. Problemas de comprensión respecto a lo que ponía en la Tesis de Muñoz (2025).
2. Problemas de programar.

Para ambos recurrí a mis tutores Jorge Molines Llodrá y Josep Ramón Medina Folgado. Por otro lado, recurrí a mi otro tutor de TFG, Enrique Ripoll Domínguez que me ayudó a

comprender el funcionamiento del canal de ensayos del LPC-UPV y me proporcionó los instrumentos necesarios para que hiciera pruebas con el fin de comprender el funcionamiento de los escáneres y los ensayos.

Para los problemas de programar también recurrí a la IA sobre todo para la descarga de librerías y para la consulta de comandos de Python.

4. Identificación de las aportaciones que, en materia de aprendizaje han supuesto las prácticas.

- Las prácticas me han dado la oportunidad de aprender métodos para evaluar daños en diques reales a escala creados en el propio laboratorio.
- He aumentado de manera notable mis conocimientos en programación en Python y en aplicaciones de Redes Neuronales.
- He aprendido a aplicar conocimientos de la carrera a un problema real.
- He aprendido también a tomar decisiones respecto al problema planteado.
- Gracias a mis compañeros y tutores he conocido en parte cómo funciona el canal de olas del LPC-UPV y la toma de datos a partir de los ensayos.

5. Evaluación de las prácticas y sugerencias de mejora.

Mi experiencia en las prácticas ha sido muy satisfactoria y enriquecedora. No tengo ninguna sugerencia que añadir.