

EMPLEO DE REDES NEURONALES INFORMADAS POR FÍSICA (PINNS) EN LA RESOLUCIÓN DE FLUJO DE FLUIDOS

USE OF PHYSICS INFORMED NEURAL NETWORKS (PINNS) FOR SOLVING FLUID FLOWS

Hugo G. Castro, Javier L. Mroginski y Juan M. Podestá

Laboratorio de Mecánica Computacional (UNNE-IMIT / CONICET) Universidad Nacional del Nordeste (UNNE), Facultad de Ingeniería, Resistencia, Chaco, Argentina,
guillermo.castro@conicet.gov.ar, <https://imit.conicet.gov.ar/laboratorio-de-mecanica-computacional>

Palabras clave: redes neuronales, aprendizaje de máquina, mediciones experimentales, fluidodinámica computacional.

Resumen. Los datos obtenidos a partir de mediciones experimentales suelen contener una gran cantidad de ruido y/o ser de baja resolución, impidiendo muchas veces una buena calibración con las técnicas computacionales. Las técnicas de aprendizaje automático han demostrado que los enfoques del aprendizaje profundo son potencialmente adecuados para mejorar la resolución de imágenes, pero su eficacia suele estar limitada a la necesidad de grandes volúmenes de datos de alta resolución. Además, las predicciones generadas por estas redes neuronales pueden carecer de la coherencia física necesaria, violando principios fundamentales como la conservación de masa y cantidad de movimiento. En este sentido, la incorporación de Redes Neuronales Informadas por Física (PINNs) en el esquema típico de trabajo de la Fluidodinámica Computacional (CFD) parece ser útil. Dado que las PINNs permiten incorporar leyes físicas (ecuaciones de gobierno) en los datos disponibles, pueden aprender soluciones que son intrínsecamente coherentes con la física del problema analizado. En este trabajo, las PINNs se utilizan para mejorar la resolución de un campo de velocidades provenientes de un conjunto limitado de mediciones ruidosas y sin la incorporación de datos de alta resolución como referencia.

Keywords: neural networks, machine learning, measurements, computational fluid dynamics.

Abstract. Data obtained from experimental measurements often contain a large amount of noise and/or are of low resolution, so that the subsequent calibration of computational techniques can be complex. With the advent of machine learning techniques, deep learning approaches have been shown to be potentially suitable for improving images resolution, but their effectiveness is often limited by the need for large volumes of high-resolution reference data. In addition, the predictions generated by these networks may lack the necessary physical consistency, violating fundamental principles such as conservation of mass and momentum. In this sense, the incorporation of Physics Informed Neural Networks (PINNs) into the typical tasks scheme of Computational Fluid Dynamics (CFD) seems to be useful. Since PINNs allow physical laws (the governing equations) to be incorporated into the available data, it is possible to learn solutions that are intrinsically consistent with the physics of the problem being analyzed. In this work, PINNs are used to improve the resolution of fluid-flow data, using a limited set of noisy measurements and without the incorporation of high-resolution data as a reference.