

Propuesta de lectura dirigida para estudiantes de posgrado en Ingeniería Eléctrica

Título

Seminario en redes neuronales basadas en la Física (Physics Informed Neural Networks, PINN)

Fecha de comienzo y horarios

Las sesiones serán semanales, los viernes de 08:00 a 09:00 comenzando el 16 de agosto de 2024 (a confirmar). Serán sesiones remotas en enlace a confirmar.

Descripción

Se propone realizar una lectura dirigida de seis semanas de duración, que incluye una reunión de discusión semanal con docentes.

Se asignará material de lectura semanal basado en artículos de interés de los estudiantes expositores. Se definirá un conjunto de artículos base de donde seleccionar, aunque se acepta que los participantes propongan nuevos contenidos. Sugerimos cinco créditos en total, teniendo en cuenta las horas dedicadas a la lectura, preparación de la presentación, reuniones con los docentes, y asistencia al seminario.

Los artículos base son los que se encuentran en las [referencias](#).

Metodología y evaluación

Las lecturas seguirán el formato de un seminario donde los estudiantes interesados preparan y presentan artículos previamente acordados. Para la aprobación se tendrá en cuenta la presentación de los temas, las diapositivas preparadas y utilizadas que deberán ser entregadas, y la participación en las charlas.

Conocimientos recomendados

Aprendizaje automático.

Referencias

Antonelo, E.A., Camponogara, E., Seman, L.O., de Souza, E.R., Jordanou, J.P., J.F. Hübner (2024), Physics-informed neural nets for control of dynamical systems, *Neurocomputing* 579.

Brunton, S. L., & Kutz, J. N. (2022). *Data-Driven Science and Engineering: Machine Learning, Dynamical Systems, and Control* (2nd ed.). Cambridge University Press.
<https://www.cambridge.org/highereducation/product/9781009089517/book>

Burns, Z., & Liu, Z. (2023). Untrained, physics-informed neural networks for structured illumination microscopy. *Optics Express*, 31(5), 8714.
<https://doi.org/10.1364/OE.476781>

Gupta, H., McCann, M. T., Donati, L., & Unser, M. (2021). CryoGAN: A New Reconstruction Paradigm for Single-Particle Cryo-EM Via Deep Adversarial Learning. *IEEE Transactions on Computational Imaging*, 7, 759–774.
<https://doi.org/10.1109/TCI.2021.3096491>

Raissi, M., Perdikaris, P., & Karniadakis, G. E. (2019). Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations. *Journal of Computational Physics*, 378, 686–707. <https://doi.org/10.1016/j.jcp.2018.10.045>

Thuerey, N., Holl, P., Mueller, M., Schnell, P., Trost, F., & Um, K. (2021). Physics-based Deep Learning. WWW. <https://physicsbaseddeeplearning.org>

Xypakis, E., De Turrís, V., Gala, F., Ruocco, G., & Leonetti, M. (2023). Physics-informed deep neural network for image denoising. *Optics Express*, 31(26), 43838. <https://doi.org/10.1364/OE.504606>

Ye, Z., Huang, Y., Zhang, J., Chen, Y., Ye, H., Ji, C., Jin, L., Gan, Y., Sun, Y., Tao, W., Han, Y., Liu, X., Chen, Y., Kuang, C., & Liu, W. (2024). Universal and High-Fidelity Resolution Extending for Fluorescence Microscopy Using a Single-Training Physics-Informed Sparse Neural Network. *Intelligent Computing*, 3, 0082. <https://doi.org/10.34133/icomputing.0082>

Contacto

Federico Lecumberry, fefo@fing.edu.uy; Pablo Monzón, monzon@fing.edu.uy