



*1821 Universidad de Buenos Aires*

## **Resolución Consejo Directivo**

**Número:**

**Referencia:** EX-2024-02982672- -UBA-DMESA#FCEN - POSTGRADO - Sesión  
29/07/2024

---

**VISTO:**

La nota presentada por la Dirección del Departamento de Computación, mediante la cual eleva la información del curso de posgrado Curso Avanzado sobre NeuroIA: Modelando Circuitos Corticales mediante Herramientas de Machine Learning para el año 2024,

**CONSIDERANDO:**

lo actuado por la Comisión de Doctorado,

lo actuado por este Cuerpo en la sesión realizada el día 29 de julio de 2024,

en uso de las atribuciones que le confiere el Artículo 113° del Estatuto Universitario,

**EL CONSEJO DIRECTIVO DE LA FACULTAD**

## DE CIENCIAS EXACTAS Y NATURALES

### RESUELVE:

**ARTÍCULO 1°:** Aprobar el nuevo curso de posgrado **Curso Avanzado sobre NeuroIA: Modelando Circuitos Corticales mediante Herramientas de Machine Learning** de 15 horas de duración, que será dictado por el Dr. Rodrigo Echeveste, con la colaboración del Dr. Pablo Barenbaum.

**ARTÍCULO 2°:** Aprobar el programa del curso de posgrado **Curso Avanzado sobre NeuroIA: Modelando Circuitos Corticales mediante Herramientas de Machine Learning** que como anexo forma parte de la presente Resolución, para su dictado en invierno 2024.

**ARTÍCULO 3°:** Aprobar un puntaje máximo de medio (0,5) punto para la Carrera del Doctorado.

**ARTÍCULO 4°:** Establecer un arancel de **CATEGORÍA NULA**, estableciendo que dicho arancel estará sujeto a los descuentos y exenciones estipulados mediante la Resolución CD N.º 1072/19. Disponer que los fondos recaudados ingresen en la cuenta presupuestaria habilitada para tal fin, y sean utilizados de acuerdo a la Resolución 072/03

**ARTÍCULO 5°:** Disponer que, de no mediar modificaciones en el programa, la carga horaria y el arancel, el presente Curso de Posgrado tendrá una vigencia de cinco (5) años a partir de la fecha de la presente Resolución.

**ARTÍCULO 6°:** Comuníquese a todos los Departamentos Docentes, a la Dirección de Estudiantes y Graduados, a la Biblioteca de la FCEyN y a la Secretaría de Posgrado con copia del programa incluida. Cumplido, pase COMPUTACION #FCEN y resérvese.

## **ANEXO**

### **PROGRAMA**

El objetivo central del curso es salir del uso más habitual de ML como herramienta de análisis de datos, en el que la estructura del modelo puede o no tener relación con la estructura del sistema de estudio, para centrarnos en técnicas de ML aplicadas al modelado de un sistema complejo y dinámico como es el cerebro.

Muchas de estas ideas son sin embargo generalizables a otros sistemas complejos y dinámicos. Cubriremos elementos básicos tanto de las redes neuronales sintéticas como de los sistemas biológicos que las inspiraron.

Además, estudiaremos una serie de trabajos de los últimos años que ilustran cómo podemos usar redes sintéticas construidas siguiendo el principio de la optimalidad para avanzar en la comprensión del funcionamiento de distintas áreas del cerebro.

Si bien el curso hará foco en el modelado de la percepción visual, también se incluirán ejemplos de percepción auditiva, y tareas de memoria. Se irá de redes feed-forward a redes recurrentes, y se presentarán distintos niveles de comparación y modelado, desde registros de neuronas individuales, a patrones poblacionales y activaciones regionales provenientes de neuroimágenes.

Las clases incluirán tanto filmas como Colabs con demostraciones sencillas en Pytorch.

#### Temario:

- Elementos de neurociencia: el cerebro y qué podemos medir.
- Elementos de redes sintéticas: arquitecturas feed-forward y arquitecturas recurrentes.
- Principio de Optimalidad y nociones básicas de entrenamiento: diferenciación automática y retropropagación.
- Redes sintéticas entrenadas funcionalmente para entender redes biológicas.
- Predicción de nuevas propiedades biológicas a partir de los modelos aprendidos, y modelos como banco de pruebas de hipótesis.

## BIBLIOGRAFÍA

- Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep learning. MIT press.
- Dayan, P., Abbott, L. F., & Abbott, L. (2001). Theoretical neuroscience: computational and mathematical modeling of neural systems.
- Yamins, D. L., & DiCarlo, J. J. (2016). Using goal-driven deep learning models to understand sensory cortex. *Nature neuroscience*, 19(3), 356.
- Kriegeskorte, N. (2015). Deep neural networks: a new framework for modeling biological vision and brain information processing. *Annual review of vision science*, 1, 417-446.
- Yamins, D. L., Hong, H., Cadieu, C. F., Solomon, E. A., Seibert, D., & DiCarlo, J. J. (2014). Performance-optimized hierarchical models predict neural responses in higher visual cortex. *Proceedings of the National Academy of Sciences*, 111(23), 8619-8624.
- Güçlü, U., & van Gerven, M. A. (2015). Deep neural networks reveal a gradient in the complexity of neural representations across the ventral stream. *Journal of Neuroscience*, 35(27), 10005-10014.
- Khaligh-Razavi, S. M., & Kriegeskorte, N. (2014). Deep supervised, but not unsupervised, models may explain IT cortical representation. *PLoS computational biology*, 10(11), e1003915.
- Cadena, S. A., Denfield, G. H., Walker, E. Y., Gatys, L. A., Tolias, A. S., Bethge, M., & Ecker, A. S. (2019). Deep convolutional models improve predictions of macaque V1 responses to natural images. *PLoS computational biology*, 15(4), e1006897.
- Higgins, I., Chang, L., Langston, V., Hassabis, D., Summerfield, C., Tsao, D., & Botvinick, M. (2021). Unsupervised deep learning identifies semantic disentanglement in single inferotemporal face patch neurons. *Nature communications*, 12(1), 6456.
- Echeveste, R., Aitchison, L., Hennequin, G., & Lengyel, M. (2020). Cortical-like dynamics in recurrent circuits optimized for sampling-based

probabilistic inference. *Nature neuroscience*, 23(9), 1138-1149.

- Echeveste, R., Ferrante, E., Milone, D. H., & Samengo, I. (2022). Bridging physiological and perceptual views of autism by means of sampling-based Bayesian inference. *Network Neuroscience*, 6(1), 196-212.
- Zhuang, C., Yan, S., Nayebi, A., Schrimpf, M., Frank, M. C., DiCarlo, J. J., & Yamins, D. L. (2021). Unsupervised neural network models of the ventral visual stream. *Proceedings of the National Academy of Sciences*, 118(3), e2014196118.
- Bashivan, P., Kar, K., & DiCarlo, J. J. (2019). Neural population control via deep image synthesis. *Science*, 364(6439), eaav9436.
- Kell, A. J., Yamins, D. L., Shook, E. N., Norman-Haignere, S. V., & McDermott, J. H. (2018). A task-optimized neural network replicates human auditory behavior, predicts brain responses, and reveals a cortical processing hierarchy. *Neuron*, 98(3), 630-644.
- Ponce, C. R., Xiao, W., Schade, P., Hartmann, T. S., Kreiman, G., & Livingstone, M. S. (2019). Evolving super stimuli for real neurons using deep generative networks. *Biorxiv*, 516484. Orhan, A. E., & Ma, W. J. (2019). A diverse range of factors affect the nature of neural representations underlying short-term memory. *Nature neuroscience*, 22(2), 275-283.
- Neftci, E. O., Mostafa, H., & Zenke, F. (2019). Surrogate gradient learning in spiking neural networks: Bringing the power of gradient-based optimization to spiking neural networks. *IEEE Signal Processing Magazine*, 36(6), 51-63.