



*1821 Universidad de Buenos Aires*

## **Resolución Consejo Directivo**

**Número:**

**Referencia:** EX-2022-05734234- -UBA-DMESA#FCEN - POSTGRADO - Sesión  
14/11/2022

---

### **VISTO**

los errores involuntarios cometidos en el tipeo de la Res. CD N° 2300/22.

la nota de la Dirección del Departamento de Ciencias de la Atmósfera y los Océanos, mediante la cual eleva la información del curso de posgrado Introducción a Técnicas y Aplicaciones de Aprendizaje Automático en Geofluidos para el año 2023,

### **CONSIDERANDO**

lo actuado por la Comisión de Doctorado,

lo actuado por este Cuerpo en Sesión realizada el día 14 de noviembre de 2022

las atribuciones que le confiere el Art. 113 del Estatuto Universitario,

**EL CONSEJO DIRECTIVO**

## DE LA FACULTAD DE CIENCIAS EXACTAS Y NATURALES

### RESUELVE:

ARTÍCULO 1º: Dejar sin efecto la Res. CD 2300/2022.

ARTICULO 2º.- Aprobar el nuevo curso de posgrado “Introducción a Técnicas y Aplicaciones de Aprendizaje Automático en Geofluidos” de 80 horas de duración que será dictado por el Dr. Juan Ruiz y con la colaboración de los Dres. Manuel Pulido, Paola Salio, Pablo Negri, Pierre Tandeo, Leonardo Franco y Takemasa Miyoshi.

ARTICULO 3º.- Aprobar el programa del curso de posgrado “Introducción a Técnicas y Aplicaciones de Aprendizaje Automático en Geofluidos” que como anexo forma parte de la presente resolución, para su dictado durante el año 2023.

ARTICULO 4º.- Aprobar un puntaje máximo de tres (3) puntos para la Carrera de Doctorado.

ARTICULO 5º.- Establecer un arancel de CATEGORÍA 3 estableciendo que dicho arancel estará sujeto a los descuentos y exenciones estipulados mediante la Resolución CD N° 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 6º: 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 7º: Comuníquese a todos los Departamentos Docentes, a la Dirección de Estudiantes y Graduados, a la Dirección de Movimiento de Fondos, a la Dirección de Presupuesto y Contabilidad, a la Biblioteca de la FCEyN y a la Secretaría de Posgrado con copia del programa incluida. Cumplido, pase a Atmosfera#FCEN y resérvese.

## **ANEXO**

### **PROGRAMA:**

**UNIVERSIDAD DE BUENOS AIRES**

**FACULTAD DE CIENCIAS EXACTAS Y NATURALES**

**Departamento de Ciencias de la Atmósfera y los Océanos**

**CARRERA:** Doctorado de la UBA, Especialidad Ciencias de la Atmósfera y los Océanos

**ASIGNATURA:** Introducción a Técnicas y Aplicaciones de Aprendizaje Automático en Geofluidos

**Año presentación: 2022**

**CÓDIGO DE LA CARRERA:** 56 - Doctorado y Posgrado

**CARÁCTER DE LA ASIGNATURA**

**REGIMEN:** Intensivo

**HORAS DE CLASE: 80**

**Profesores:** Dr. Juan José Ruíz y Dra. Paola Salio

### **Fundamentos:**

Este curso constituye una introducción y descripción del estado del arte en lo que refiere a la aplicación de técnicas de aprendizaje automático en geofluidos. En los últimos años, las técnicas de aprendizaje automático se han perfeccionado notoriamente incrementando su eficacia en la resolución de problemas de clasificación y regresión a partir de conjuntos de datos complejos y multivariados. Estas técnicas permiten extraer información útil a partir de grandes conjuntos de datos lo cual las convierte en una herramienta fundamental para disciplinas como la meteorología y la oceanografía en

donde existe una gran abundancia de información. La cantidad de datos que se genera aumenta año a año en cantidad pero también en complejidad. Por ese motivo es cada vez más importante poder disponer de herramientas de análisis más complejas y eficientes.

### **Propósitos:**

Proveer a los estudiantes elementos teóricos para comprender las ideas subyacentes en diferentes algoritmos de aprendizaje automático.

Desarrollar un pensamiento crítico respecto de la selección, optimización y posterior utilización de los modelos de aprendizaje automático en la resolución de un problema determinado.

Proveer a los estudiantes un panorama actualizado del estado del arte en lo que respecta a la aplicación de las técnicas de aprendizaje automático en el estudio de fluidos geofísicos.

Generar experiencias de trabajo en grupo

Favorecer la discusión científica

### **Objetivos:**

Los objetivos principales son Introducir los conceptos básicos que sustentan los algoritmos de aprendizaje automático con particular énfasis en aquellos que resultan de interés para su aplicación en problemas relacionados con geofluidos.

Introducir las nociones básicas relacionadas con la preparación de bases de datos para su uso en la implementación de técnicas de aprendizaje automático.

Introducir aplicaciones de aprendizaje automático en el contexto de los geofluidos.

Introducir herramientas de código abierto para la implementación de técnicas de aprendizaje automático.

### **Contenidos:**

Módulo 1 (1 clase teórico y práctica): Introducción. Definición de aprendizaje automático y su utilidad. Tipos de aprendizaje automático (supervisado, no supervisado, etc). Underfitting y overfitting. Datos y su preparación. Control de calidad.

Modulo 2 (1 clase teórico y práctica): Teoría de probabilidad. Regresión. Máxima verosimilitud. Maximum a posteriori estimación.

Módulo 3 (1 clase teórico y práctica): Técnicas de aprendizaje supervisado para regresión y clasificación: DecisionTrees y Random Forest. Técnicas de entrenamiento y

funciones objetivo. hiper parámetros. Validación. Aplicaciones en geofluidos.

Módulo 4 (1 clase teórico y práctica): Técnicas de aprendizaje supervisado para regresión y clasificación: Support Vector Machines. Clasificación lineal y no lineal. Técnicas de reducción de dimensionalidad. Aplicaciones en geofluidos.

Módulo 5 (1 clase teórico y práctica): Técnicas de aprendizaje no-supervisado y semi-supervisado: Clustering. K-means y Gaussian Mixtures. Aplicaciones en geofluidos.

Módulo 6 (2 clases teórico y práctica): Redes neuronales artificiales. El perceptrón. Entrenamiento e hiper parámetros asociados. Funciones de activación. Redes neuronales recurrentes. Aplicaciones en geofluidos.

Modulo 7 (1 clase teórico y práctica): Entrenamiento. Funciones de costo. Gradiente descendente y sus variantes más utilizadas (Batch, estocástico, mini-batch, etc). Desafíos: no-linealidad, mínimos locales, velocidad de convergencia. Técnicas para la detección del overfitting.

Módulo 8 (2 clases teórico y práctica): Redes neuronales profundas. Desafíos para su entrenamiento y métodos para afrontarlos. Optimizadores (ejAdagrad, Adam, etc). Técnicas de regularización. Redes convolucionales, U-net, autoencoders, GAN. Aplicaciones en geofluidos.

### **Modalidad de evaluación:**

La evaluación del presente curso constará de tres partes: por un lado se observará el desempeño de los estudiante durante los trabajo prácticos, se tomará un examen parcial presencial de los temas discutidos en el curso y por último los estudiantes deberán rendir un examen final donde se hará una revisión de un tema de interés relacionado con los temas de la materia.

Para aprobar el presente curso se requiere que los alumnos demuestren que conocen por lo menos el 70% de los contenidos teóricos, y que poseen habilidades para trabajar resolver problemas asociados a las situaciones meteorológicas estudiadas en la materia.

### **Recursos**

Los estudiantes tendrán a su disposición el campus virtual y acceso de una base de datos especialmente diseñada para las prácticas de laboratorio.

## **Bibliografía**

Bishop C., 2006: Pattern Recognition and Machine Learning. Springer.

Beusch L, Foresti L, Gabella M, y Hamann U, 2018: Satellite-Based Rainfall Retrieval: From Generalized Linear Models to Artificial Neural Networks. Remote Sensing.; 10(6):939

Bonavita, M., Arcucci, R., Carrassi, A., Dueben, P., Geer, A. J., Le Saux, B., Longépé, N., Mathieu, P., & Raynaud, L. (2021). Machine Learning for Earth System Observation and Prediction, Bulletin of the American Meteorological Society, 102(4), E710-E716.

Bolton, T., & Zanna, L. (2019). Applications of deep learning to ocean data inference and subgrid parameterization. Journal of Advances in Modeling Earth Systems, 11, 376–399. <https://doi.org/10.1029/2018MS001472>

Chase, Randy J., Harrison, David R., Burke, Amanda, Lackmann, Gary M., and McGovern, Amy, 2022, "A Machine Learning Tutorial for Operational Meteorology. Part I: Traditional Machine Learning" Weather and Forecasting Vol. 37, No. 8, pp 1509, 1520-0434

Duan, M., Xia, J., Yan, Z., Han, L., Zhang, L., Xia, H. y Yu, S., 2021: Reconstruction of the Radar Reflectivity of Convective Storms Based on Deep Learning and Himawari-8 Observations. Remote Sens., 13, 3330.

Cuomo, J., & Chandrasekar, V. (2021). Use of Deep Learning for Weather Radar Nowcasting, Journal of Atmospheric and Oceanic Technology, 38(9), 1641-1656.

Gagne, D. J., II, McGovern, A., Haupt, S. E., Sobash, R. A., Williams, J. K., & Xue, M. (2017). Storm-Based Probabilistic Hail Forecasting with Machine Learning Applied to Convection-Allowing Ensembles, Weather and Forecasting, 32(5), 1819-1840.

Géron A., 2019: Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow. O'Reilly Media Inc.

Goodfellow I., Bengio Y., Courville A., 2017. Deep Learning. MIT Press

Hayatbini, N., Kong, B., Hsu, K. L., Nguyen, P., Sorooshian, S., Stephens, G., Fowlkes, C., Nemani, R., y Ganguly, S., 2019: Conditional Generative Adversarial Networks (cGANs) for Near Real-Time Precipitation Estimation from Multispectral GOES-16 Satellite Imagery – PERSIANN-cGAN, Remote Sens., 11, 2193

Herman, G. R., & Schumacher, R. S. (2018). Money Doesn't Grow on Trees, but Forecasts Do: Forecasting Extreme Precipitation with Random Forests, Monthly Weather Review,

146(5), 1571-1600.

McGovern, A., Elmore, K. L., Gagne, D. J., II, Haupt, S. E., Karstens, C. D., Lagerquist, R., Smith, T., & Williams, J. K. (2017). Using Artificial Intelligence to Improve Real-Time Decision-Making for High-Impact Weather, *Bulletin of the American Meteorological Society*, 98(10), 2073-2090.

McGovern, A., Lagerquist, R., John Gagne, D., II, Jergensen, G. E., Elmore, K. L., Homeyer, C. R., & Smith, T. (2019). Making the Black Box More Transparent: Understanding the Physical Implications of Machine Learning, *Bulletin of the American Meteorological Society*, 100(11), 2175-2199.

Ravuri, S., Lenc, K., Willson, M. et al. Skilful precipitation nowcasting using deep generative models of radar. *Nature* 597, 672–677 (2021). <https://doi.org/10.1038/s41586-021-03854-z>

Schultz M. G., Betancourt C., Gong B., Kleinert F., Langguth M., Leufen L. H., Mozaffari A. and Stadtler S. 2021 Can deep learning beat numerical weather prediction? *Phil. Trans. R. Soc. A.*  
<http://doi.org/10.1098/rsta.2020.0097>