



Universidad Nacional  
de Entre Ríos

## Doctorado en Ingeniería

*Facultad de Ciencias Agropecuarias, Ciencias de la Alimentación  
e Ingeniería*

**Carrera:** Doctorado en Ingeniería

**Mención:** Ciencias Agropecuarias, Ciencias de la  
Alimentación y Bioingeniería

**Curso de Posgrado:** “Reconocimiento de Imágenes con Machine-Learning”

**Carga Horaria:** 30hs.

**Docente/s a cargo:** Dr. Diego Sebastián COMAS / Dr. Gustavo Javier MESCHINO

**Semestre:** 2 (dictado en forma intensiva a lo largo de 2 semanas)

### Características del curso

**Modalidad:** Teórico-Práctico.

**Carácter:** Optativo.

**Programa Analítico foja:** 2

**Bibliografía de foja:** 3

**Aprobado Resoluciones de Consejos Directivos:**

**Fecha:**

**Modificado/Anulado/ Res. Cs. Ds.:**

**Fecha:**

**Carece de validez sin la certificación del Director/a del Doctorado:**



Universidad Nacional  
de **Entre Ríos**

**Facultades de Ingeniería, Ciencias Agropecuarias y  
Ciencias de la Alimentación**

## **PROGRAMA ANALÍTICO**

Repaso de fundamentos de redes neuronales artificiales. Aprendizaje supervisado y no supervisado. Machine Learning.

Deep Learning. Redes neuronales supervisadas para reconocimiento de escenas y segmentación de imágenes. Redes generadoras de imágenes.

Aprendizaje por transferencia (transfer-learning).

Validación de modelos. Estrategias de prevención de sobre-entrenamiento: regularización, dropout. Consideraciones sobre el conjunto de imágenes de entrenamiento. Técnicas de aumentación y balanceo de datos.

Redes convolucionales (CNN). Redes generativas adversariales (GAN). Implementaciones en lenguaje de alto nivel (MATLAB, Keras y PyTorch en Python).



Universidad Nacional  
de Entre Ríos

Facultades de Ingeniería, Ciencias Agropecuarias y  
Ciencias de la Alimentación

## BIBLIOGRAFIA

- Atienza R., *Advanced Deep Learning with Keras*, Birmingham (2018).
- Attik M. Bougrain L. and Alexandre F., "Self-organizing Map Initialization," in *Artificial Neural Networks: Biological Inspirations – ICANN 2005*. vol. 3696, W. Duch, J. Kacprzyk, E. Oja, and S. Zadrozny, Eds.: Springer Berlin Heidelberg, 2005, pp. 357-62.
- Ballard D.H. and Brown C.M., *Computer vision*, New Jersey (1992).
- Bauer H.-U. and Pawelzik K.R., "Quantifying the neighborhood preservation of self-organizing feature maps," *IEEE Transactions on Neural Networks*, 3, 570-9 (1992).
- Baxes G.A., *Digital image processing: principles and applications*, New York (1994).
- Bruijne, Marleen de. 2016. "Machine Learning Approaches in Medical Image Analysis: From Detection to Diagnosis." *Medical Image Analysis* 33 (October): 94–97. <https://doi.org/10.1016/j.media.2016.06.032>.
- Comas D.S. Meschino G.J. and Ballarin V.L., "Framework de segmentación y análisis de imágenes mediante reconocimiento de texturas," *Proc. Argentinian Symposium of Technology (AST)*, Buenos Aires, Argentina, 1529-41 (2010).
- Duda R. Hart P. and Stork D., *Pattern Classification*, (2001).
- Gonzalez R.C. and Woods R.E., *Digital image processing*, Upper Saddle River, N. J. (2002).
- Halkidi M. Batistakis Y. and Vazirgiannis M., "On Clustering Validation Techniques," *Journal of Intelligent Information Systems*, 17, 107–45 (2001).
- Haykin S., *Neural Networks: A Comprehensive Foundation*, Nueva Jersey, EE.UU. (1999).
- Jain A.K. Murty M.N. and Flynn P.J., "Data Clustering: A Review," *ACM Computing Surveys*, 31, 264-323 (1999).
- LeCun, Yann, Yoshua Bengio, and Geoffrey Hinton. 2015. "Deep Learning." *Nature* 521 (7553): 436–44. <https://doi.org/10.1038/nature14539>.
- Li Y. and Chi Z., "MR Brain Image Segmentation Based on Self-Organizing Map Network," *International Journal of Information Technology*, 11, 45-53 (2005).
- Litjens, Geert, Thijs Kooi, Babak Ehteshami Bejnordi, Arnaud Arindra Adiyoso Setio, Francesco Ciompi, Mohsen Ghafoorian, Jeroen A.W.M. van der Laak, Bram van Ginneken, and Clara I. Sánchez. 2017. "A Survey on Deep Learning in Medical Image Analysis." *Medical Image Analysis* 42 (December): 60–88. <https://doi.org/10.1016/J.MEDIA.2017.07.005>.
- Montavon, Grégoire, Wojciech Samek, and Klaus Robert Müller. 2018. "Methods for Interpreting and Understanding Deep Neural Networks." *Digital Signal Processing* 73 (February): 1–15. <https://doi.org/10.1016/j.dsp.2017.10.01>
- Moolayil J., *Learn Keras for Deep Neural Networks*, Vancouver (2019).
- Rao D., Brian McMahan B., *Natural Language Processing with PyTorch*, United States (2019).
- Razzak, Muhammad Imran, Saeeda Naz, and Ahmad Zaib. 2018. "Deep Learning for Medical Image Processing: Overview, Challenges and the Future." In , 323–50. Springer, Cham. [https://doi.org/10.1007/978-3-319-65981-7\\_12](https://doi.org/10.1007/978-3-319-65981-7_12).
- Ruspini E.H., "A new approach to clustering," *Information and Control*, 15, 22-32 (1969).
- Subramanian V., *Deep Learning with PyTorch*, Birmingham (2018).
- Wu, Guorong, Dinggang. Shen, and Mert Rory Sabuncu. 2016. *Machine Learning and Medical Imaging*. Academic Press is an imprint of Elsevier.
- Zeiler, Matthew D., and Rob Fergus. 2014. "Visualizing and Understanding Convolutional Networks." In , 818–33. Springer, Cham. [https://doi.org/10.1007/978-3-319-10590-1\\_53](https://doi.org/10.1007/978-3-319-10590-1_53).



Universidad Nacional  
de Entre Ríos

Facultades de Ingeniería, Ciencias Agropecuarias y  
Ciencias de la Alimentación

## PLANIFICACIÓN DEL CURSO

### Objetivos Generales:

Que el alumno sea capaz de:

- Adquirir los conocimientos básicos de las técnicas de machine-learning y entender su aplicación en imágenes médicas.
- Estudiar redes neuronales artificiales tradicionales pudiendo identificar etapas de preprocesamiento requeridas y estructuras básicas.
- Aprender a utilizar redes neuronales basadas en deep-learning, identificando estructuras básicas, enfoques de aprendizaje y su implementación computacional en distintas plataformas.
- Aprender/revisar técnicas de validación de modelos y estimación del error de generalización.

**Conocimientos previos requeridos (Si correspondiese):** Se espera de los asistentes un mínimo conocimiento de los conceptos básicos de machine-learning y del uso de alguna de los lenguajes/plataformas utilizados: MATLAB y Python.

**Fecha tentativa de inicio del dictado y duración del Curso (en semanas).** Se propone el dictado en el mes de diciembre de 2021, con un total de 6 clases teórica-prácticas de 2h 30min, que se complementarán con resolución de ejercicios y un trabajo final de aprobación, con fecha límite de entrega en marzo 2022.

### Cronograma:

Clase #	Fecha	Temas a tratar
1	9/12	Introducción general. Machine-Learning. Aprendizaje supervisado y no supervisado. Técnicas de validación de modelos. Redes neuronales artificiales. Prevención de sobreentrenamiento: regularización, dropout. Introducción a los entornos de trabajo: MATLAB, Keras y PyTorch en Python. Google Colab.
2	10/12	Deep-Learning. Clasificación de imágenes: Redes convolucionales (CNN). Utilización de redes previamente entrenadas: Transfer-learning. Ejemplos.
3	13/12	Consideraciones sobre el conjunto de imágenes de entrenamiento. Técnicas de aumentación y balanceo de datos. Ejemplos.
4	14/12	Segmentación de imágenes y detección y seguimiento de objetos.
5	15/12	Codificación de imágenes (autoencoders). Visualización e interpretación de características.
6	16/12	Generación de imágenes. Redes generativas adversariales (GAN). Otros paradigmas de deep-learning (RNN, etc).

**Cupo de alumnos** (cantidades mínima y máxima): Durante 2021, se plantea el dictado virtual, por lo que inicialmente no se presenta la necesidad de imponer un cupo.

**Lugar:** El curso se dictará en forma virtual durante 2021.

### Día(s) y horario(s) tentativo(s) de dictado:

Clase #1: Jueves 9/12 de 18.00 a 20.30hs.

Clase #2: Viernes 10/12 de 18.00 a 20.30hs.

Clase #3: Lunes 13/12 de 18.00 a 20.30hs.

Clase #4: Martes 14/12 de 18.00 a 20.30hs.

Clase #5: Miércoles 15/12 de 18.00 a 20.30hs.

Clase #6: Jueves 16/12 de 18.00 a 20.30hs.

La totalidad de las clases se realizará en forma virtual.

**Fecha de Recuperatorio:** No corresponde (evaluación a través de trabajo práctico final).

**Profesores**

**Docente responsable:** Dr. Diego Sebastián COMAS.

**Docente(s) colaborador(es):** Dr. Gustavo Javier MESCHINO.

**Condiciones de Regularidad y Promoción:**

Se prevé la evaluación del contenido y la aprobación del curso a partir de la resolución de un problema concreto utilizando las herramientas aprendidas en el curso, tanto partiendo de un problema que sea de interés para el estudiante o bien de un caso concreto propuesto por los docentes.

**Infraestructura necesaria:**

No se requiere infraestructura específica para el dictado en forma virtual. Los ejemplos y ejercicios prácticos estarán mayormente basados en la API Keras sobre TensorFlow en lenguaje Python, utilizando la plataforma gratuita de Google Colab con procesamiento en la nube.