
Nombre de la unidad curricular: Redes Neuronales en la cognición natural y artificial

Forma parte de la Oferta Estable: No

Licenciaturas: Astronomía, Ciencias de la Atmósfera, Física, Matemática.

Frecuencia y semestre de la formación al que pertenece: semestre par

Créditos asignados:

Astronomía - 12 Área Electiva

Ciencias de la Atmósfera - 12 Métodos numéricos

Física - 12 - Área Herramientas para la investigación experimental y el desarrollo profesional.

Matemática - 12 créditos, Área B, Subárea Ciencias de la Computación o Ciencias Biológicas, nivel intermedio.

*Para cursar materias del Tramo de Orientación se deben tener 90 créditos del Tramo Común

Nombre del/la docente responsable: Juan Carlos Valle Lisboa

E-mail: juancvl@fcien.edu.uy

Requisitos previos: 2 años de formación universitaria de cualquier carrera de Ciencias, Ingeniería y Psicología. Conocimientos básicos de biología o de matemática o de psicología o de computación. Flexibilidad para el estudio de temas matemáticos.

Ejemplos de unidades curriculares de Facultad de Ciencias u otros que aportan dichos conocimientos:
180 créditos

Conocimientos adicionales sugeridos:

Álgebra lineal. Cálculo diferencial. Nociones de programación. Conocimientos básicos acerca del funcionamiento del sistema nervioso.

Objetivos de la unidad curricular:

a) Herramientas, conceptos y habilidades que se pretenden desarrollar

Conocimiento conceptual acerca de la teoría de redes neuronales y sus fortalezas y debilidades como modelos de la actividad del sistema nervioso y como modelos de la cognición y el aprendizaje.

Nociones acerca de los aspectos computacionales de la cognición y la inteligencia.

Rudimentos de programación en python.

Rudimentos de utilización de python como herramienta para el aprendizaje de redes neuronales.

b) En el marco del plan de estudios

Temario sintético de la unidad curricular:

Temario sintético

- a. Redes neuronales como modelo neurocognitivos.
- b. Modelos de neuronas digitales. Aprendizaje.
- c. Modelos de Neuronas analógicas. Memorias. Redes multicapa.
- d. Redes recurrentes.
- e. Redes profundas

Temario desarrollado:

Curso Teórico

1. Redes neuronales como modelos de la Cognición.
2. Redes de McCulloch & Pitts y la computación lógica. El problema del o-exclusivo
3. Perceptrones y máquinas que aprenden.
4. Memorias asociativas. Aprendizaje Hebbiano. Regla Delta
5. Perceptrones multicapa. Backpropagation. Redes recurrentes.
6. Modelos tensoriales contexto dependientes.
7. Autoorganización. PCA. Mapas auto-organizados.

8. Dinámica del aprendizaje y optimización del aprendizaje.
9. El problema del gradiente y las redes LSTM.
10. Redes de convolución.
11. Auto-codificadores. Modelos generativos.
12. Transformers y modelos de lenguaje.
13. Aplicaciones a la neurociencia cognitiva.

Curso práctico

1. Introducción a python
2. Algebra lineal en python. Pseudoinversa. Regresión lineal
3. Propiedades de memoria. Regla delta
4. Backpropagation
5. Redes recurrentes.
6. Modelos contexto dependientes
7. Aprendizaje no supervisado: regla de Oja y SOMsorks
6. Redes lineales profundas y angostas
7. Uso de paquetes de python (pytorch o tensorflow).
8. Redes de convolución. Semcor y el cerebro
9. PLN en redes. Huggin face. Traducción con seq2seq
10. Creando un transformer
11. Redes profundas como modelos del cerebro.

Bibliografía

a) Básica:

- Anderson, J. (1996) Neural networks: an introduction. MIT Press.
- Chollet, F. (2021). Deep Learning with Python, Second Edition. Simon and Schuster.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep Learning (Illustrated edition). The MIT Press.
- Kinsley, H., Kukiela, D. (2020) Neural Networks from Scratch in Python. Harrington Kinsley.
- Kohonen, T. (1978). Associative Memory: A System-Theoretical Approach. Springer-Verlag.
- Kohonen, T. (1997) Self organizing maps. Springer.
- Stevens, E., Antiga, L., & Viehmann, T. (2020). Deep Learning with PyTorch: Build, train, and tune neural networks using Python tools (First Edition). Manning.

b) Complementaria:

- Anderson, J. A. (1972). A Simple Neural Network Generating an Interactive Memory. 220, 197–220.

Caucheteux, C., & King, J.-R. (2020). Language processing in brains and deep neural networks: Computational convergence and its limits [Preprint]. Neuroscience. <https://doi.org/10.1101/2020.07.03.186288>

Cooper LN (1973) A possible organization of animal memory and learning. In: Lundquist B and S (eds) Proceedings of the Nobel Symposium on Collective Properties of Physical Systems. Academic Press, New York.

Elman, J. L. (1990). Finding Structure in Time. *Cognitive Science*. 14 (2), 179-211.

Hinton, G., & Anderson, J. R. (1981). *Parallel Models of Associative Memory*. Hillsdale Publishers.

Hinton, G. E., & Salakhutdinov, R. R. (2006). Reducing the dimensionality of data with neural networks. *Science (New York, N.Y.)*, 313(5786), 504–507. <https://doi.org/10.1126/science.1127647>

Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>

Khaligh-Razavi, S.-M., & Kriegeskorte, N. (2014). Deep Supervised, but Not Unsupervised, Models May Explain IT Cortical Representation. *PLOS Computational Biology*, 10(11), e1003915. <https://doi.org/10.1371/journal.pcbi.1003915>

Kohonen T (1972) Correlation matrix memories. *IEEE Transactions on Computers* 100:353-359.

Kohonen, T. (1982). *Biological Cybernetics* 9. 69, 59–69.

LeCun, Y., Boser, B., Denker, J., Howard, R., Hubbard, W., & Jackel, L. (1989). Backpropagaapplied to handwritten zipcode recognition. *Neural Computation*, 1, 541–551.

McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, 5(4), 115–133. <https://doi.org/10.1007/BF02478259>

Mikolov, T., Chen, K., Corrado, G., & Dean, J. (2013). Efficient Estimation of Word Representations in Vector Space. ArXiv:1301.3781 [Cs]. <http://arxiv.org/abs/1301.3781>

Millet, J., Caucheteux, C., Orhan, P., Boubenec, Y., Gramfort, A., Dunbar, E., Pallier, C., & King, J.-R. (2022). Toward a realistic model of speech processing in the brain with self-supervised learning (arXiv:2206.01685). arXiv. <http://arxiv.org/abs/2206.01685>

Oja, E. (1982). Simplified neuron model as a principal component analyzer. *Journal of Mathematical Biology*.

Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 386–408. <https://doi.org/10.1037/h0042519>

Saxe, A. M., McClelland, J. L., & Ganguli, S. (2014). Exact solutions to the nonlinear dynamics of learning in deep linear neural networks (arXiv:1312.6120). arXiv. <http://arxiv.org/abs/1312.6120>

Schrimpf, M., Blank, I. A., Tuckute, G., Kauf, C., Hosseini, E. A., Kanwisher, N., Tenenbaum, J. B., & Fedorenko, E. (2021). The neural architecture of language: Integrative modeling converges on predictive

processing. Proceedings of the National Academy of Sciences, 118(45), e2105646118.
<https://doi.org/10.1073/pnas.2105646118>

Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). Attention is All you Need. ArXiv:1706.03762v5 [Cs.CL], 11.

Modalidad cursada: Presencial

Metodología de enseñanza: Una clase magistral de 2 hs por semana y un taller de computadoras de 3 hs por semana

Duración en semanas: 15

Carga horaria total: 180

Carga horaria detallada:

a) Horas aula de clases teóricas: 30

b) Horas aulas de clases prácticas: 45

c) Horas de seminarios: 0

d) Horas de talleres:

e) Horas de salida de campo: 0

f) Horas sugeridas de estudio domiciliario durante el período de clase: 105

Sistema de APROBACIÓN final

Como examen final del curso, se requiere de la presentación de un trabajo monográfico original de entre 15 y 20 páginas incluyendo la bibliografía, que aborde algún tema conectado a los temas del curso. Una vez entregado y corregido el trabajo, el estudiante deberá presentarlo oralmente a los efectos de indagar la real autoría del mismo.

La evaluación final (única para la aprobación del curso) será de la monografía, requiriendo la suficiencia técnica y formal. Las monografías se corregirán y el equipo docente le indicará al estudiante si reprobó o si la monografía es adecuada. En una reunión personalizada se evaluará el conocimiento del estudiante acerca de los temas de la monografía y se le harán devoluciones formativas.

Tiene examen final: Si

Se exonera el examen final: No

Nota de exoneración (del 3 al 12): -

Sistema de GANANCIA

a) Características de las evaluaciones:

El curso requiere de la asistencia a teóricos y laboratorios en un 70 %. Se controlará la asistencia. Se realizarán ejercicios en clase pero su evaluación será únicamente formativa.

b) Porcentaje de asistencia requerido para ganar la unidad curricular: 70% asistencia

c) Puntaje mínimo individual de cada evaluación y total: LA GANANCIA SE GARANTIZA POR LA ASISTENCIA AL 70 % DE LAS CLASES PRÁCTICAS Y TEÓRICAS.

d) Modo de devolución o corrección de pruebas:

Habilitada a rendir en calidad de examen libre: No*

* Por resolución del Consejo de Facultad de Ciencias de fecha 24/02/2022 este ítem no fue aprobado dado que se encuentra en un proceso de revisión institucional

COMENTARIOS o ACLARACIONES:

Las redes neuronales artificiales (RNA) nacieron como modelos de procesamiento de información en el sistema nervioso. A lo largo de la historia, los modelos de redes neurales fueron incorporando un conjunto de características, algunas inspiradas en la psicología y neurociencias cognitivas, otras para resolver problemas de cómputo o aprendizaje. Desde hace varios años se utilizan rutinariamente como modelos de la cognición y últimamente son la base de lo que conocemos como Inteligencia Artificial. Los modelos actuales se alejan en aspectos importantes de la biología y la psicología conocida, al punto de que en la comunidad de la Inteligencia Artificial no se los percibe como modelos cognitivos. No obstante,

en los últimos años, varios trabajos de la neurociencia utilizan RNAs para describir la actividad cerebral, mostrando que es posible que a pesar de las muchas diferencias, globalmente el cerebro y las RNA compartan aspectos del cómputo neural. También en las áreas más vinculadas a la Psicología y la Psicolingüística, los modelos utilizados en la Inteligencia Artificial están siendo crecientemente tomados en cuenta como modelos e incluso teorías del procesamiento cognitivo.

El objetivo del curso es brindar a los estudiantes las herramientas conceptuales para reflexionar en torno a estos temas. En este curso, el foco es en entender la teoría de las redes neurales, desde sus orígenes hasta el presente, apoyándonos en simulaciones computacionales, pero también en las considera
