 <p>U D E L A R FACULTAD DE QUÍMICA</p>	<p><b><u>Deep Learning aplicado al diseño de compuestos bioactivos</u></b></p>
--	--

Carácter del curso	CURSO DE GRADO/POSGRADO
Semestre en que se dicta	Segundo Hemisemestre Semestre PAR
Número de créditos	6 (grado) 8 (posgrado)
Carga horaria semanal (hs)	4 (semanales, teóricos, total 16) y 30 (hemisemestrales, practicas estructuradas) + 30 horas (Proyecto Integrador) a lo largo del hemisemestre solo para posgrado
Previaturas	
Cupo	30

**Estructura Responsable:**

Área Bioinformática – Departamento DETEMA – Facultad de Química – UdelaR

**Docentes Responsables:**

Margot Paulino  
Pablo García

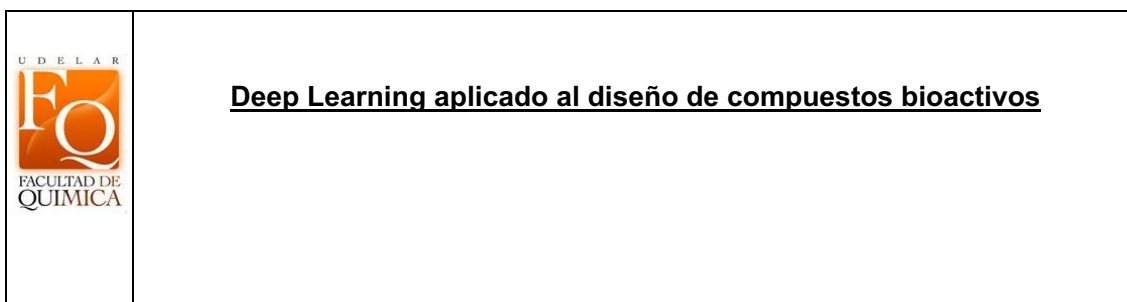
**Docentes Colaboradores:**

Andrés Camilo Ballesteros  
Jorge Cantero

**Objetivos:**

El curso se enfoca en introducir al alumno en el uso de inteligencia artificial aplicada al diseño de compuestos bioactivos. En particular se profundiza en el uso de técnicas de aprendizaje automático de la categoría de Deep Learning, introduciendo al alumno en la teoría de redes neuronales, diferentes arquitecturas de redes y su aplicación a diferentes etapas del diseño de compuestos bioactivos así como se lo introduce en las principales herramientas de aplicación de estas técnicas y entornos de ejecución de las mismas.

<b>Fecha</b>	26Jul2022	<b>V.2022</b>
	Página 1	de
	7	

**Contenido:****Clases teóricas de 2 horas cada una**

- 1 Introducción a las redes neuronales, teoría y algoritmos básicos y su aplicación a problemas de regresión y clasificación.

Introducción a las redes neuronales.

Redes neuronales biológicas.

Construcción de una red neuronal, tipos de capas, dimensionalidad (ancho y profundidad), visualización de la red.

Redes neuronales artificiales, forward propagation.

Algoritmos básicos :

- Gradient Descent
- Backpropagation
- Vanishing Gradient
- Funciones de activación.

- 2 Regularización y optimización (hyperparameters tuning).

Métodos de evaluación (Mean Squared Error, Binary Cross

Entropy, Categorical

Cross Entropy)

Hyperparámetros tuning.

Inicialización

Regularización Dropout.

Normalización batch.

- 3 Métodos de optimización:

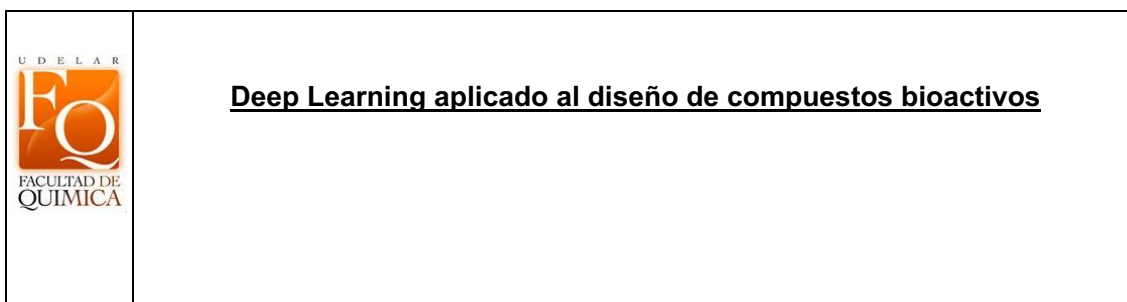
Gradient Descent

Stochastic Gradient Descent

Momentum

Variable and Adaptive Learning Rates

<b>Fecha</b>	26Jul2022	<b>V.2022</b>
	Página 2	de
	7	



Adam

4 Convolutional Neural Networks :

Concepto de convolución y kernels comúnmente utilizados.

Max Polling

Aplicación de las redes convolucionales a estructuras 3D e imágenes.

5 Redes neuronales deep, otras arquitecturas de uso específico:

RNN Recurrent Neural Networks

LSTM Long Short Term Memory

6 Introducción a los frameworks de mayor adopción en la implementación de redes neuronales deep aplicadas a diseño de compuestos bioactivos:

Sci-kit learn

Keras

Tensorflow

7 GAN Generative adversarial networks

Modelos generativos.

Teoría de las GANs.

Construcción de GANs.

Autoencoders y Variational Auto Encoders

8 Despliegue en producción:

Transfer Learning

Estándares de transferencia de modelos ONNX

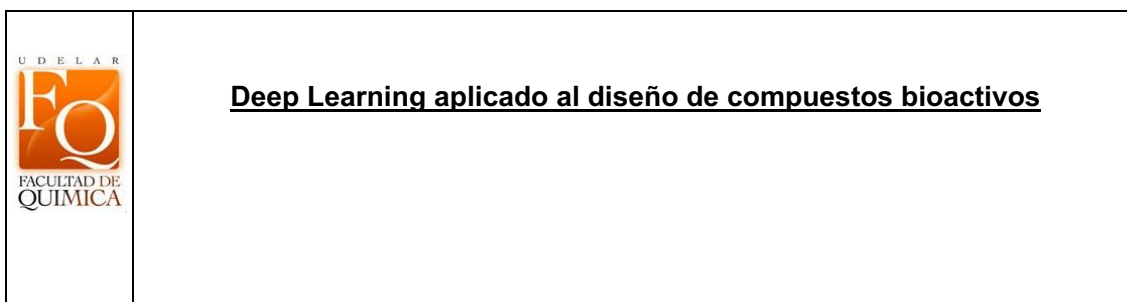
Desplegar en Docker containers.

Entrenar usando GPUs y TPUs.

Desplegar a la nube (GoogleColab, AzureML y Kaggle)

**TOTAL TEÓRICOS: 16 horas. (4 horas por semana)**

<b>Fecha</b>	26Jul2022	<b>V.2022</b>
	Página <b>3</b>	de
	<b>7</b>	



**TOTAL Prácticas estructuradas (Total 30 horas para grado y 30+30 para posgrado)**

**Desarrollo de las Prácticas Estructuradas Básicas ( se anotan horas en cada una, total 30 horas) :**

Herramientas básicas para Deep Life Sciences (2)  
 Introducción a MoleculeNet (2)  
 Molecular Fingerprints (2)  
 Creando modelos con TensorFlow (2)  
 Introduction a las Convoluciones para Grafos (2) Molecular Featurizations (2)  
 Interpretability de modelos (2)  
 Entrenamiento Avanzado de Modelos (2)  
 Unsupervised Embeddings para Moléculas (2)  
 Predicción de Ki de Ligandosa una proteína (2)  
 Modelado de interacciones proteína-ligando, con u sin atomic convolutions.(2)  
 Entrenando una Generative Adversarial Network (4)  
 Chemical Screens en grandes volúmenes de datos (4).

**Desarrollo de Proyectos Integradores (total 30 horas):**

**Seleccionar dos experimentos a realizar:** (cada uno 15 horas total 30 horas) :

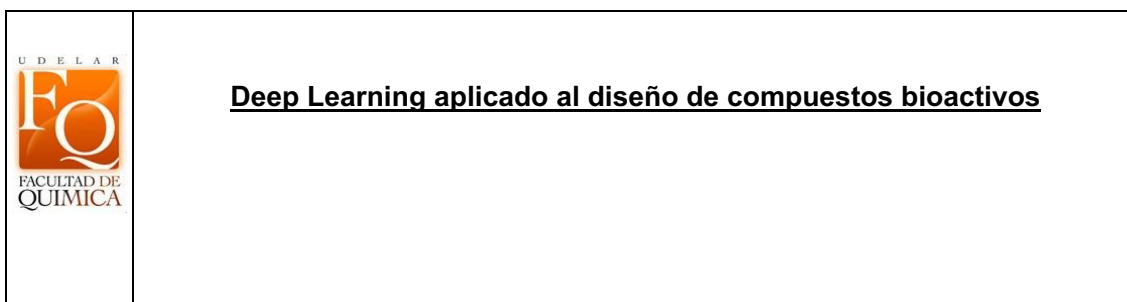
Ramsundar, Bharath, et al. "Is multitask deep learning practical for pharma?." Journal of chemical information and modeling 57.8 (2017): 2068-2076.

Delaney, John S. "ESOL: estimating aqueous solubility directly from molecular structure." Journal of chemical information and computer sciences 44.3 (2004): 10001005.

Ma, Junshui, et al. "Deep neural nets as a method for quantitative structure–activity relationships." Journal of chemical information and modeling 55.2 (2015): 263-274.

**Trabajo sobre el datasets** (cada uno 10 horas total 30 horas):

<b>Fecha</b>	26Jul2022	<b>V.2022</b>
	Página 4	de
	7	



Tox21: Ref: B Ramsundar, S Kearnes, P Riley, D Webster, D Konerding, V Pande arXiv preprint arXiv:1502.02072

Clintox: The Clintox dataset is a collection of "clinical toxicity" datasets that compares drugs approved by the FDA and drugs that have failed clinical trials for toxicity reasons. It contains two classification tasks for 1491 compounds

Harvard Organic photovoltaic: Lopez, Steven A., et al. "The Harvard organic photovoltaic dataset." Scientific data 3.1 (2016): 1-7

- **GANANCIA:** El curso se gana con la presentación de la resolución de un mínimo de 60% de las practicas estructuradas.

#### Créditos:

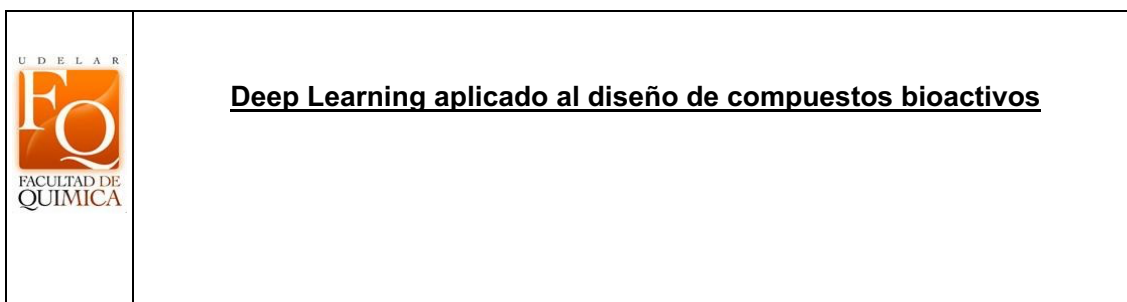
Contenido	Cantidad	Créditos
Teórico	16hs	2.1
Prácticas Estructuradas	30hs	2.4
Entregables	1	1
Proyecto Integrador (solo posgrado)	30	2
Total créditos		6 (grado) 8 (posgrado)

#### Bibliografía:

Demystifying Deep Convolutional Neural Networks. Adam Harley  
<https://www.cs.ryerson.ca/~aharley/neural-networks/>

Ramsundar, B. (2018). *Molecular machine learning with DeepChem* (Doctoral dissertation, Stanford University).

Fecha	26Jul2022	V.2022
	Página 5	de
	7	



Haghighatlari, M., Vishwakarma, G., Altarawy, D., Subramanian, R., Kota, B. U., Sonpal, A., ... & Hachmann, J. (2019). Chemml: A machine learning and informatics program package for the analysis, mining, and modeling of chemical and materials data. *Wiley Interdisciplinary Reviews: Computational Molecular Science*, e1458.

Wen, Ming, et al. "Deep-learning-based drug–target interaction prediction." *Journal of proteome research* 16.4 (2017): 1401-1409.

Baskin, I. I. (2020). The power of deep learning to ligand-based novel drug discovery. *Expert Opinion on Drug Discovery*, 1-10.

Lin, E., Lin, C. H., & Lane, H. Y. (2020). Relevant Applications of Generative Adversarial Networks in Drug Design and Discovery: Molecular De Novo Design, Dimensionality Reduction, and De Novo Peptide and Protein Design. *Molecules*, 25(14), 3250.

Colby, S. M., Nuñez, J. R., Hodas, N. O., Corley, C. D., & Renslow, R. R. (2019). Deep learning to generate in silico chemical property libraries and candidate molecules for small molecule identification in complex samples. *Analytical chemistry*, 92(2), 1720-1729.

Senior, Andrew W., et al. "Improved protein structure prediction using potentials from deep learning." *Nature* 577.7792 (2020): 706-710.

Bronstein, M. M., Bruna, J., LeCun, Y., Szlam, A., & Vandergheynst, P. (2017). Geometric deep learning: going beyond euclidean data. *IEEE Signal Processing Magazine*, 34(4), 18-42.

ODENA, Augustus. Semi-supervised learning with generative adversarial networks. *arXiv preprint arXiv:1606.01583*, 2016.

GUI, Jie, et al. A review on generative adversarial networks: Algorithms, theory, and applications. *arXiv preprint arXiv:2001.06937*, 2020.


Frameworks:

Keras: [https://keras.io/getting\\_started/](https://keras.io/getting_started/)

Tensorflow: <https://www.tensorflow.org/learn>

Scikit-learn: [https://scikit-learn.org/stable/user\\_guide.html](https://scikit-learn.org/stable/user_guide.html)

<b>Fecha</b>	26Jul2022	<b>V.2022</b>
	Página 6	de
	7	

	<p><b><u>Deep Learning aplicado al diseño de compuestos bioactivos</u></b></p>
---	--

**Modalidad del Curso:**

	Teórico	Practico	Laboratorio	Otros (*)
Asistencia Obligatoria	si	si		Proyecto Integrador (solo posgrado)
Modalidad Flexible	100%	100%		100%

**Régimen de ganancia:**

La nota del curso se compone de dos partes: i) prácticos semanales ii) entregable final. Los porcentajes de cada componente para la nota final es el siguiente: 60% prácticos semanales. A los estudiantes de posgrados se les pedirá la exposición oral con la presentación del Proyecto Integrador desarrollado durante el curso que consistirá en el 40% restante de la calificación.

La nota de la asignatura (nota final) corresponde 100% de la nota del curso.

**Requisitos para ganar el curso:** el estudiante debe alcanzar un 66% en su calificación.

<b>Fecha</b>	26Jul2022	<b>V.2022</b>
	Página 7	de 7