

PROGRAMA DE CURSO

Código	Nombre			
MA5606	Tópicos Matemáticos en Aprendizaje de Máquinas, Redes Neuronales y Aprendizaje Profundo			
Nombre en Inglés				
Mathematical Topics in Machine Learning, Neural Networks and Deep Learning				
SCT	Unidades Docentes	Horas de Cátedra	Horas Docencia Auxiliar	Horas de Trabajo Personal
6SCT	10UD	3hrs.	1.5hrs.	5.5hrs.
Requisitos			Carácter del Curso	
AUTOR			Electivo de Carrera, Magíster y Doctorado	
Resultados de Aprendizaje				
<p>Al finalizar el curso, el/la estudiante:</p> <ul style="list-style-type: none"> - Comprende los resultados básicos y teóricos de redes neuronales. - Comprende su utilización reciente en problemas probabilísticos y de ecuaciones en derivadas parciales de difícil tratamiento numérico. - Comprende los resultados más avanzados al respecto de esta reciente área. 				

Metodología Docente	Evaluación General
Clases expositivas y de resolución de problemas.	Tres tareas, un trabajo numérico, y una presentación de un artículo avanzado.

Unidades Temáticas

Número	Nombre de la Unidad	Duración en Semanas
1	Preliminares 1, EDP	2
Contenidos	Resultados de Aprendizajes de la Unidad	Referencias a la Bibliografía
Breve repaso de los métodos de Análisis y EDPs, necesarios para el curso.	Noción de problema bien puesto, soluciones a ecuaciones elípticas y parabólicas.	

Número	Nombre de la Unidad	Duración en Semanas
2	Preliminares 2, Procesos estocásticos	2
Contenidos	Resultados de Aprendizajes de la Unidad	Referencias a la Bibliografía
Breve repaso de los métodos de Probabilidades y Cálculo estocástico, necesarios para el curso.	Revisión de elementos de procesos estocásticos necesarios para el curso, incluyendo lo esencial del cálculo de Ito, convergencia en ley e interpretaciones o representaciones probabilistas de soluciones ecuaciones de elípticas y parabólicas (Feynmann - Kaç y Fokker Planck).	

Número	Nombre de la Unidad	Duración en Semanas
3	Introducción a las redes neuronales	2
Contenidos	Resultados de Aprendizajes de la Unidad	Referencias a la Bibliografía
Se presentan las redes neuronales, propiedades básicas y resultados matemáticos	Se estudian de forma matemática las redes neuronales, presentado resultados clásicos de universalidad.	

Número	Nombre de la Unidad	Duración en Semanas
4	Modelos probabilistas avanzados con aplicación en redes neuronales	4
Contenidos	Resultados de Aprendizajes de la Unidad	Referencias a la Bibliografía
<ol style="list-style-type: none"> 1. Gradiente estocástico (SGD) y su límite de escala difusivo 2. Modelos de campo medio y representación probabilista de algunas EDP de evolución no lineales (McKean-Vlasov) 3. Ecuaciones diferenciales estocásticas Forward-Backward y representación probabilista de algunas EDP parabólicas semi-lineales 	Se profundiza en las herramientas probabilistas más avanzadas útiles para modelar y entender matemáticamente el proceso de entrenamiento o la estructura de redes neuronales. Estos incluyen: el gradiente estocástico y su dinámica límite, sistemas de partículas de campo medio, y ecuaciones FBSDE.	

Número	Nombre de la Unidad	Duración en Semanas
5	Métodos recientes de aprendizaje profundo para el estudio de Ecuaciones Diferenciales Parciales (EDP).	4 semanas
Contenidos	Resultados de Aprendizajes de la Unidad	Referencias a la Bibliografía
<ol style="list-style-type: none"> 1. Análisis y demostración del error en esquemas numéricos tipo deep learning. Método backward-forward para modelos parabólicos. 2. Método iterativo de Picard para modelos elípticos y parabólicos. 	Se estudian en detalle las dos técnicas más prometedoras desde el punto de vista EDP: la que consiste en esquemas numéricos de tipo Euler probabilista, y aquella que consiste en aproximaciones de tipo Picard.	

Bibliografía General

1. *Partial Differential Equations*, Lawrence C. Evans, 2nd Edn.
2. Han, J., Jentzen, A., E, W., *Solving high-dimensional partial differential equations using deep learning*. *Proc. Natl. Acad. Sci.* **115** (2018), 8505-8510. [\[arXiv\]](#).
3. *Deep backward schemes for high-dimensional nonlinear PDEs*, Côme Huré, Huyên Pham, Xavier Warin. <https://arxiv.org/abs/1902.01599>
4. Hutzenthaler, M., Jentzen, A., Kruse, T., Nguyen, T. A., von Wurstemberger, P., *Overcoming the curse of dimensionality in the numerical approximation of semilinear parabolic partial differential equations*. [\[arXiv\]](#) (2018).
5. Rotskoff, G.M., Van de Eijnden, E. *Trainability and Accuracy of Neural Networks: an interacting particle system approach* <https://arxiv.org/abs/1805.00915>. (2018)
6. Mei, S., Montanari, A., Phan-Mihn, N., *A mean field view of the landscape of two-layer neural networks*, *Proceedings of the National Academy of Sciences*, 115(33): E7665–E7671, 2018.
7. Karatzas, I., Shreve, S.E. *Brownian motion and stochastic calculus*. Springer (1998).
8. Pardoux, E., Tang E., *Forward-backward stochastic differential equations and quasilinear parabolic PDEs*, *Probab. Theory Relat. Fields* 114, 123–150 (1999).

Vigencia desde:	Otoño 2021
Elaborado por:	Joaquín Fontbona y Claudio Muñoz
Revisado por:	José Soto San Martín (Jefe Docente)