



FICHA TÉCNICA DE LA ASIGNATURA

Datos de la asignatura	
Nombre completo	Inteligencia Artificial Geométrica
Código	DCIA-MIA-522
Título	Máster Universitario en Inteligencia Artificial por la Universidad Pontificia Comillas
Impartido en	Máster Universitario en Inteligencia Artificial [Primer Curso]
Créditos	7,5 ECTS
Carácter	Obligatoria
Departamento / Área	Departamento de Ciencias de la Computación e Inteligencia Artificial

Datos del profesorado	
Profesor	
Nombre	Javier Borondo Benito
Departamento / Área	Departamento de Ciencias de la Computación e Inteligencia Artificial (DCIA)
Correo electrónico	jborondo@comillas.edu
Profesor	
Nombre	Sergio Rivera López
Departamento / Área	Departamento de Ciencias de la Computación e Inteligencia Artificial (DCIA)
Correo electrónico	srivera@comillas.edu
Profesor	
Nombre	Antonio Jesús Díaz-Cano Rincón
Departamento / Área	Departamento de Ciencias de la Computación e Inteligencia Artificial (DCIA)
Correo electrónico	ajdiazcano@icai.comillas.edu

DATOS ESPECÍFICOS DE LA ASIGNATURA

Contextualización de la asignatura	
Competencias - Objetivos	
Competencias	
Conocimientos o contenidos	
CO03	Conocer los algoritmos y modelos de inteligencia artificial basados en técnicas innovadoras, basadas en modelos generativos, probabilísticos, geométricos y por refuerzo profundo.
Competencias	
CP01	Capacidad para definir e implementar modelos y algoritmos de inteligencia artificial, así como para interpretar y evaluar modelos propuestos en la frontera del conocimiento gracias al fundamento matemático adquirido.



CP02	Capacidad para planificar, gestionar y desplegar proyectos de inteligencia artificial de manera efectiva en entornos colaborativos.
Habilidades o destrezas	
HAB01	Definir modelos matemáticos de algoritmos de inteligencia artificial avanzada y tener las bases para entender los propuestos por otros autores.
HAB03	Desarrollar e innovar soluciones de inteligencia artificial que mejoren los modelos existentes mediante nuevas técnicas avanzadas basadas en deep learning
HAB07	Realizar revisiones bibliográficas a partir de fuentes documentales para el desarrollo de trabajos de investigación

BLOQUES TEMÁTICOS Y CONTENIDOS

Contenidos – Bloques Temáticos

1. Aprendizaje en espacios de alta dimensionalidad: High-dimensional learning
2. Deep Learning en estructuras: Graphs & Sets in Deep Learning. Grids & Groups in Deep Learning:
3. Graph Neural Networks (GNNs): Introducción. Escalabilidad. Interpretabilidad. Robustez frente a ataques adversariales. Graph Transformers.
4. Modelado y transformación de grafos: Heterogeneous Graphs.
5. Advanced topics in Geometric Deep Learning.

Estos temas comprenden los siguientes tópicos:

Tema	Contenidos específico
1. Aprendizaje en espacios de alta dimensionalidad (High-dimensional learning)	<ul style="list-style-type: none"> - Geodesics & Manifolds - Gauges & Bundles - Reservoir Computing - Recommender Systems and Social Networks - Text and Speech Synthesis - Protein Biology - Chemistry and Drug Design - Particle Physics and Astrophysics - Traffic Forecasting - Healthcare
2. Deep Learning en estructuras (Graphs & Sets – Grids & Groups in Deep Learning)	<ul style="list-style-type: none"> - Introduction - Geometric Priors & Blueprint (Intro to 5 Gs) - Graphs and Sets - Grids & Euclidean Spaces - Groups & Homogeneous Spaces - Gauges & Bundles (también avanzado)



Tema	Contenidos específico
3. Graph Neural Networks (GNNs) Intro, escalabilidad, interpretabilidad, robustez, Graph Transformers	<ul style="list-style-type: none"> - Graph Neural Networks - Deep Sets, Transformers, and Latent Graph Inference - Equivariant Message Passing Networks - Drug Repositioning
4. Modelado y transformación de grafos (Heterogeneous Graphs)	<ul style="list-style-type: none"> - Object Recognition - Healthcare (<i>redes heterogéneas</i>) - Recommender Systems and Social Networks (<i>multi-relación</i>) - Protein Biology (<i>interacciones diversas</i>) - Chemistry and Drug Design (<i>grafos moleculares heterogéneos</i>)
5. Advanced topics in Geometric Deep Learning	<ul style="list-style-type: none"> - Group-equivariant CNN - Intrinsic Mesh CNNs - Equivariant Message Passing Networks (<i>también GNNs, pero avanzados</i>) - Geodesics & Manifolds (<i>también en alta dimensionalidad</i>) - Gauges & Bundles (<i>formalismo avanzado</i>) - Virtual and Augmented Reality - Game Playing

METODOLOGÍA DOCENTE

Aspectos metodológicos generales de la asignatura

Metodología Presencial: Actividades

Clases magistrales expositivas y participativas	CO03, CP01, CP02, HAB01, HAB03, HAB07
Actividades de evaluación continua del rendimiento	CO03, CP01, CP02, HAB01, HAB03, HAB07
Sesiones prácticas o de laboratorio	CO03, CP01, CP02, HAB01, HAB03, HAB07
Presentaciones orales	CO03, CP01, CP02, HAB01, HAB03, HAB07

Metodología No presencial: Actividades

Trabajos o Proyectos	CO03, CP01, CP02, HAB01, HAB03, HAB07
Estudio personal	CO03, CP01, CP02, HAB01, HAB03, HAB07

RESUMEN HORAS DE TRABAJO DEL ALUMNO

HORAS PRESENCIALES

HORAS NO PRESENCIALES

CRÉDITOS ECTS: 7,5 (0 horas)

EVALUACIÓN Y CRITERIOS DE CALIFICACIÓN

El uso de IA para crear trabajos completos o partes relevantes, sin citar la fuente o la herramienta o sin estar permitido expresamente en la descripción del trabajo, será considerado plagio y regulado conforme al Reglamento General de la Universidad.

Actividades de evaluación	Criterios de evaluación	Peso
Examen final	<ul style="list-style-type: none">Examen final (50%). Mínima ponderación para dar peso al proyecto y las prácticas semanales.	50 %
Proyecto individual	<ul style="list-style-type: none">Proyecto individual (30%; report 20%/defensa oral 10%). El objetivo es que aprendan a estructurar un proyecto de GDL (principalmente de grafos) de cero y sean capaces de entrenar arquitecturas sobre dicha geometría.	30 %
Prácticas en laboratorio	Prácticas en laboratorio (20%). Suficiente peso ya que son seis prácticas totales con recurrencia semanal.	20 %

Calificaciones

- Examen final (50%).** Mínima ponderación para dar peso al proyecto y las prácticas semanales.
- Proyecto individual (30%; report 20%/defensa oral 10%).** El objetivo es que aprendan a estructurar un proyecto de GDL (principalmente de grafos) de cero y sean capaces de entrenar arquitecturas sobre dicha geometría.
- Prácticas en laboratorio (20%).** Suficiente peso ya que son seis prácticas totales con recurrencia semanal.

PLAN DE TRABAJO Y CRONOGRAMA

Actividades	
*	Main Block
W1	Introduction



W2	Graphs and Sets
W3	Deep Sets, Transformers, and Latent Graph Inference
W4	Grids & Euclidean spaces
W5	Convolutional Neural Networks
W6	Recurrent Neural Networks
W7	Long Short-Term Memory Networks
W8	Groups & Homogeneous spaces
W9	Group-equivariant CNN
W10	Geodesics & Manifolds
W11	Intrinsic Mesh CNNs
W12	Gauges & Bundles
W13	Equivariant Message Passing Networks
W14	Recommender Systems and Social Networks

BIBLIOGRAFÍA Y RECURSOS

Bibliografía Básica

- Geometric Deep Learning: Grids, Groups, Graphs, Geodesics, and Gauges, by Michael M. Bronstein, Joan Bruna, Taco Cohen, Petar Veličković. [Read online](#).
- WEB: <https://geometricdeeplearning.com/>