



Guía docente

295922 - FDLE - Fundamentos del Deep Learning para la Ingeniería

Última modificación: 14/07/2026

Unidad responsable: Escuela de Ingeniería de Barcelona Este
Unidad que imparte: 749 - MAT - Departamento de Matemáticas.

Titulación: GRADO EN INGENIERÍA BIOMÉDICA (Plan 2009). (Asignatura optativa).
GRADO EN INGENIERÍA DE LA ENERGÍA (Plan 2009). (Asignatura optativa).
GRADO EN INGENIERÍA ELÉCTRICA (Plan 2009). (Asignatura optativa).
GRADO EN INGENIERÍA ELECTRÓNICA INDUSTRIAL Y AUTOMÁTICA (Plan 2009). (Asignatura optativa).
GRADO EN INGENIERÍA MECÁNICA (Plan 2009). (Asignatura optativa).
GRADO EN INGENIERÍA QUÍMICA (Plan 2009). (Asignatura optativa).
GRADO EN INGENIERÍA DE MATERIALES (Plan 2010). (Asignatura optativa).

Curso: 2026 **Créditos ECTS:** 6.0 **Idiomas:** Inglés

PROFESORADO

Profesorado responsable: Alférez Baquero, Edwin Santiago
Mujica Delgado, Luis Eduardo
Ruiz Ordoñez, Magda Liliana

Otros:

CAPACIDADES PREVIAS

Durante la formación de grado, los estudiantes han adquirido competencias básicas de programación y conceptos matemáticos fundamentales. En esta asignatura se aplicará la utilidad práctica de estas competencias al campo del aprendizaje profundo.

1. Python: conocimientos básicos de programación, incluyendo variables, tipos de datos, instrucciones, expresiones, operadores y precedencia. Se espera que el estudiantado sea capaz de implementar algoritmos sencillos y gestionar estructuras de datos.

2. Conceptos matemáticos: la asignatura se basa en los fundamentos de programación y análisis adquiridos durante el grado y los aplica a problemas prácticos de aprendizaje profundo en ingeniería. Los conceptos matemáticos más relevantes incluyen:

- Estadística: medidas estadísticas básicas (media, mediana, desviación estándar), probabilidad condicionada y contraste de hipótesis.
- Cálculo: conceptos fundamentales de diferenciación e integración, especialmente en relación con problemas de optimización en ciencia de datos.
- Álgebra: álgebra lineal básica, incluyendo operaciones con matrices y espacios vectoriales, ya que son esenciales para comprender representaciones de datos y modelos de aprendizaje automático.

Aunque una buena comprensión de estos conceptos matemáticos ayudará a seguir los contenidos, la evaluación detallada de estas competencias específicas no formará parte central de la evaluación de la asignatura, que se centrará en la síntesis y aplicación de modelos de aprendizaje profundo.

REQUISITOS

No hay requisitos formales. Es imprescindible tener interés por aprender a analizar datos, así como entusiasmo y disposición para abordar conceptos de nuevas tecnologías aplicadas a la resolución de problemas complejos.

METODOLOGÍAS DOCENTES

La asignatura adopta un modelo de aprendizaje integrado, en el que los conceptos teóricos y la aplicación práctica se entrelazan durante cuatro horas semanales. Cada sesión se realiza en un laboratorio informático. Tras la introducción de cada concepto teórico, se explora inmediatamente su implementación práctica mediante programación en Python, fomentando un entorno de aprendizaje activo. Al inicio de cada clase se proporcionarán los materiales de Python, de modo que el foco se situará en aprender y aplicar nuevos conceptos.

Además, la asignatura incorpora parcialmente el modelo de clase invertida, asignando el 60% del recorrido de aprendizaje al trabajo autónomo. Se espera que el estudiantado desarrolle aprendizaje autodirigido, investigación independiente y consolidación de conocimientos. Este componente favorece un entorno centrado en el aprendizaje, en el que el estudiante asume responsabilidad sobre su progreso y desarrolla habilidades de autorregulación, especialmente relevantes en inteligencia artificial y ciencia de datos.

La distribución orientativa de los pesos de aprendizaje es:

- Conocimiento teórico: 20%
- Tareas y proyectos de laboratorio informático: 20%
- Aprendizaje autónomo: 60%

Como marco de evaluación, se desarrollarán actividades y proyectos orientados a fomentar la implicación continua y la aplicación de los conceptos, asegurando una experiencia de aprendizaje rigurosa y contextualizada.

OBJETIVOS DE APRENDIZAJE DE LA ASIGNATURA

- Adquirir una comprensión sólida de los principios fundamentales del aprendizaje profundo y de la representación no lineal, yendo más allá de los modelos lineales clásicos.
- Aprender a formular y contextualizar retos complejos de datos en distintos entornos de ingeniería y ciencia, identificando cuándo las arquitecturas profundas aportan una ventaja clara.
- Comprender un conjunto de algoritmos para el procesamiento de datos de alta dimensionalidad, incluyendo CNN, RNN y Transformers, así como sus ventajas matemáticas y limitaciones estructurales.
- Aplicar estos conocimientos a la resolución de problemas de ingeniería de complejidad moderada, reforzando el dominio de Python y de los entornos de aprendizaje profundo.
- Desarrollar capacidad de evaluación crítica de resultados, especialmente en la interpretación de espacios latentes y de las dinámicas de optimización de redes profundas.
- Fomentar habilidades de aprendizaje autónomo para navegar en un campo de IA en rápida evolución y dominar nuevas arquitecturas de forma independiente.
- Promover un entorno de trabajo colaborativo en el que se valore el intercambio de ideas y la participación constructiva en el diseño de modelos.
- Desarrollar una mentalidad orientada a la investigación, con capacidad para explorar literatura reciente y sintetizar información de fuentes técnicas diversas.
- Capacitar al estudiantado para comparar críticamente diferentes técnicas neuronales y recomendar las más adecuadas según la estructura de los datos: espaciales, secuenciales o generativos.

HORAS TOTALES DE DEDICACIÓN DEL ESTUDIANTADO

Tipo	Horas	Porcentaje
Horas grupo pequeño	30,0	50.00
Horas grupo grande	30,0	50.00

Dedicación total: 60 h

CONTENIDOS

Introducción

Descripción:

Las sesiones ofrecen una visión general del desarrollo de la inteligencia artificial y establecen las bases para comprender el papel del procesamiento automático en el análisis contemporáneo de datos e imágenes. Se examinará la importancia de la generalización y la hoja de ruta del aprendizaje profundo, junto con modelos fundamentales para la representación e interpretación de datos en contextos de ingeniería.

Objetivos específicos:

Familiarizarse con los fundamentos conceptuales del aprendizaje profundo y su aplicación en distintos campos de la ingeniería. Esto incluye comprender la importancia de la adquisición de datos, la transición del aprendizaje automático clásico hacia arquitecturas profundas, y una introducción a los tipos de algoritmos y entornos de trabajo que se encontrarán a lo largo del curso.

Actividades vinculadas:

Clases de teoría: presentación del curso e introducción a la hoja de ruta del aprendizaje profundo.

Sesiones de laboratorio: introducción al entorno de trabajo (Jupyter/Colab). Revisión de Python para ciencia de datos: Matplotlib, NumPy, Pandas y exploración inicial de datos mediante tensores de PyTorch.

Dedicación: 10h

Grupo grande/Teoría: 2h

Grupo pequeño/Laboratorio: 2h

Aprendizaje autónomo: 6h

Variables latentes

Descripción:

Las sesiones se centrarán en el descubrimiento de estructuras ocultas dentro de los datos mediante modelos de variables latentes. Este módulo va más allá de las etiquetas supervisadas para explorar cómo se organizan los datos en espacios de alta dimensionalidad. Se examinarán variables latentes discretas mediante modelos de mezcla y lógica de agrupamiento, y variables latentes continuas mediante el estudio de la reducción de dimensionalidad y las variedades. Se pondrá énfasis en la comprensión de los fundamentos matemáticos de la representación y en la transición de las proyecciones clásicas hacia la visualización no lineal de datos.

Objetivos específicos:

Proporcionar al estudiantado las habilidades necesarias para identificar, modelar y visualizar estructuras subyacentes en conjuntos de datos complejos. El estudiantado aprenderá a interpretar espacios latentes como prerrequisito para el aprendizaje profundo, aplicando estas técnicas a conjuntos de datos de ingeniería y evaluando las implicaciones de la reducción de dimensionalidad en el análisis de datos de alta dimensionalidad.

Actividades vinculadas:

Clases de teoría y sesiones de laboratorio: variables latentes discretas y continuas; modelos de mezcla, variedades y proyecciones.

Implementación de algoritmos de agrupamiento y técnicas de reducción de dimensionalidad. Visualización de espacios latentes para comprender la topología de los datos mediante Python.

Dedicación: 10h

Grupo grande/Teoría: 2h

Grupo pequeño/Laboratorio: 2h

Aprendizaje autónomo: 6h

Fundamentos neuronales y retropropagación

Descripción:

Esta unidad establece la transición de los modelos lineales a las arquitecturas neuronales. Las sesiones cubrirán redes de una sola capa tanto para regresión como para clasificación, examinando modelos de funciones base lineales y fronteras de decisión para clases discretas. Posteriormente, el módulo introduce el perceptrón multicapa (MLP) como aproximador universal, centrándose en la formalización matemática de la retropropagación del error. Se analizará la regla de la cadena para la estimación del gradiente, el papel de las funciones de activación y la importancia de las aplicaciones no lineales en espacios de alta dimensionalidad.

Objetivos específicos:

Proporcionar una base matemática sobre cómo fluye la información a través de una red. El estudiantado aprenderá a distinguir entre las capacidades de una sola capa y de múltiples capas, implementando el algoritmo de retropropagación para comprender cómo los gradientes actualizan los parámetros del modelo durante el proceso de aprendizaje.

Actividades vinculadas:

Modelos de una sola capa para regresión y clasificación. Arquitecturas multicapa y algoritmo de retropropagación. Análisis comparativo de fronteras de decisión lineales y no lineales. Implementación de una red neuronal básica y verificación manual del flujo de gradientes.

Dedicación: 20h

Grupo grande/Teoría: 4h

Grupo pequeño/Laboratorio: 4h

Aprendizaje autónomo: 12h

Regularización y optimización

Descripción:

Las sesiones se centrarán en el doble reto de garantizar la generalización del modelo y lograr una convergencia eficiente en espacios de alta dimensionalidad. Se examinarán técnicas de regularización diseñadas para mitigar el sobreajuste y gestionar la complejidad del modelo, como Dropout, Weight Decay (L1/L2) y el papel crítico de las capas de normalización (Batch Norm y Layer Norm). Posteriormente, la unidad cubre la dinámica de optimización, analizando la evolución desde el descenso del gradiente estocástico (SGD) y Momentum hasta algoritmos de tasa de aprendizaje adaptativa como RMSProp y Adam.

Objetivos específicos:

Dotar al estudiantado de las habilidades diagnósticas y técnicas para estabilizar el proceso de entrenamiento de arquitecturas profundas. Al finalizar esta unidad, el estudiantado debería ser capaz de identificar las causas matemáticas de fallos comunes de entrenamiento, como gradientes que se desvanecen o explotan, y seleccionar estratégicamente las herramientas de regularización y optimización adecuadas para diversos problemas de ingeniería.

Actividades vinculadas:

Clases de teoría y sesiones de laboratorio: estrategias de generalización y regularización. Paisajes de optimización y métodos de tasa de aprendizaje adaptativa. Experimentación comparativa con diferentes optimizadores y técnicas de regularización. Ajuste de hiperparámetros y seguimiento de la dinámica de entrenamiento mediante herramientas de visualización.

Dedicación: 30h

Grupo grande/Teoría: 6h

Grupo pequeño/Laboratorio: 6h

Aprendizaje autónomo: 18h

Visión por computador: redes neuronales convolucionales (CNN)

Descripción:

Las sesiones se centrarán en arquitecturas diseñadas específicamente para procesar datos con una topología de rejilla, como imágenes. Se estudiará la transición de conexiones densas a capas convolucionales, examinando los principios de conectividad local y compartición de parámetros. El módulo explora cómo estas redes logran invariancia y equivariancia a traslaciones, el papel de los mecanismos de pooling y el diseño de arquitecturas modernas de visión profunda.

Objetivos específicos:

Proporcionar al estudiantado la capacidad de diseñar e implementar modelos para el análisis automático de imágenes. El estudiantado comprenderá la lógica matemática de las operaciones convolucionales y aprenderá a aplicar estas técnicas a tareas de clasificación y extracción de características en contextos de ingeniería.

Actividades vinculadas:

Clases de teoría y sesiones de laboratorio: fundamentos de las redes neuronales convolucionales. Patrones arquitectónicos: filtros, strides, padding y pooling. Implementación de una CNN para reconocimiento de imágenes. Comparación entre MLP tradicionales y CNN en tareas de visión. Introducción al transfer learning.

Dedicación: 20h

Grupo grande/Teoría: 4h

Grupo pequeño/Laboratorio: 4h

Aprendizaje autónomo: 12h

Fundamentos estocásticos y muestreo básico

Descripción:

Esta unidad introduce los mecanismos estocásticos necesarios para extraer muestras de distribuciones aprendidas. Las sesiones se centran en muestreo ancestral, muestreo por rechazo y muestreo de importancia. Se examinará cómo estas técnicas permiten pasar de un espacio latente determinista a un proceso generativo.

Objetivos específicos:

Comprender la mecánica matemática de la generación de datos. El estudiantado aprenderá a extraer información de distribuciones complejas, proporcionando las herramientas necesarias para implementar y evaluar arquitecturas generativas.

Actividades vinculadas:

Clases de teoría y sesiones de laboratorio: principios de muestreo ancestral, por rechazo y de importancia. Implementación práctica de algoritmos de muestreo para visualizar la cobertura de distribuciones.

Dedicación: 10h

Grupo grande/Teoría: 2h

Grupo pequeño/Laboratorio: 2h

Aprendizaje autónomo: 6h

Modelado de secuencias

Descripción:

Las sesiones explorarán cómo las redes neuronales procesan datos secuenciales y temporales. Se comenzará con redes neuronales recurrentes (RNN) y sus versiones evolucionadas, como las LSTM, diseñadas para capturar dependencias de largo plazo. La unidad introducirá después el modelado secuencia-a-secuencia y discutirá las limitaciones del procesamiento estrictamente recurrente, preparando al estudiantado para el estudio posterior de arquitecturas basadas en atención.

Objetivos específicos:

Capacitar al estudiantado para tratar datos con estructura temporal o secuencial. Al finalizar esta unidad, el estudiantado será capaz de implementar modelos recurrentes y secuencia-a-secuencia, comprender sus puntos fuertes y limitaciones, e identificar por qué los mecanismos de atención son necesarios para un procesamiento de secuencias más escalable.

Actividades vinculadas:

Clases de teoría y sesiones de laboratorio: fundamentos de redes recurrentes y LSTM. Modelos secuencia-a-secuencia y procesamiento de datos temporales. Implementación de modelos recurrentes en Python y análisis de su comportamiento en datos secuenciales de ingeniería.

Dedicación: 20h

Grupo grande/Teoría: 4h

Grupo pequeño/Laboratorio: 4h

Aprendizaje autónomo: 12h

Atención y Transformers

Descripción:

La unidad final se centra en arquitecturas basadas en atención, con énfasis en el modelo Transformer. Las sesiones cubren self-attention, multi-head attention, codificación posicional y bloques Transformer, conectando estos conceptos con los grandes modelos de lenguaje modernos (LLM) y otras aplicaciones de ingeniería con datos de alta dimensionalidad.

Objetivos específicos:

Dominar los mecanismos centrales de las arquitecturas Transformer. El estudiantado será capaz de implementar mecanismos de atención y bloques Transformer básicos, interpretar mapas de atención y comprender por qué los Transformers se han convertido en una herramienta estándar para procesar datos secuenciales y no secuenciales de alta dimensionalidad.

Actividades vinculadas:

Clases de teoría y sesiones de laboratorio: mecanismos de atención, self-attention y arquitectura Transformer completa. Implementación de un bloque basado en Transformer. Experiencia práctica con mapas de atención y análisis del comportamiento del modelo.

Dedicación: 30h

Grupo grande/Teoría: 6h

Grupo pequeño/Laboratorio: 6h

Aprendizaje autónomo: 18h

SISTEMA DE CALIFICACIÓN

Cualquier acto de fraude académico, plagio o uso o mera tenencia al alcance de medios no autorizados en cualquier actividad de evaluación comportará la calificación de cero (0) en la prueba o entrega afectada. Además, de acuerdo con la normativa de la Universidad, la posible derivación de los hechos para la apertura de un expediente disciplinario implicará que la asignatura quede en el estado provisional de "pendiente de evaluación" hasta la resolución del expediente. La gestión de estas incidencias se lleva a cabo de acuerdo con el [Marco de actuación para la integridad académica en la evaluación de la UPC](#).

La asignatura se basa en un sistema de evaluación orientado a proyectos, que garantiza la implicación continua y la aplicación práctica de los conceptos de aprendizaje profundo mediante dos hitos principales y verificaciones periódicas. Seis pruebas conceptuales breves a lo largo del semestre representarán el 20% de la calificación. El 80% restante se dividirá en dos proyectos integradores: el primero cubre las unidades 1 a 4 y culmina con la presentación de un póster científico; el segundo cubre las unidades 5 a 8 y requiere una implementación técnica y una defensa oral.

NORMAS PARA LA REALIZACIÓN DE LAS PRUEBAS.

La evaluación se realizará mediante dos grandes proyectos colaborativos y una serie de pruebas conceptuales individuales. Para los proyectos, los participantes formarán grupos de dos o tres estudiantes. La composición de los grupos podrá cambiar entre el primer y el segundo proyecto. Los proyectos son colaborativos, mientras que las pruebas conceptuales son individuales, para garantizar que cada estudiante domine los principios matemáticos fundamentales de la asignatura.

BIBLIOGRAFÍA

Básica:

- Bishop, Christopher M; Bishop, Hugh. Deep learning : foundations and concepts. Cham: Springer, [2024]. ISBN 9783031454677.
- James, Gareth. An Introduction to statistical learning : with applications in R [en línea]. New York: Springer, 2013 [Consulta: 29/07/2026]. Disponible a: <https://link-springer-com.recursos.biblioteca.upc.edu/book/10.1007/978-1-4614-7138-7>. ISBN 9781461471370.
- Raschka, Sebastian; Liu, Yuxi (Hayden); Mirjalili, Vahid; Dzhuigakov, Dmytro. Machine learning with PyTorch and Scikit-Learn. Second edition. Packt Publishing, 2022. ISBN 9781801816380.
- Géron, Aurélien. Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow : concepts, tools, and techniques to build intelligent systems. Second edition. Sebastopol, CA: O'Reilly Media, Inc, 2019. ISBN 9781492032649.

Complementaria:

- Hastie, Trevor; Tibshirani, Robert; Friedman, Jerome. The Elements of statistical learning : data mining, inference, and prediction. 2nd ed. New York [etc.]: Springer, cop. 2009. ISBN 0387952845.
- Goodfellow, Ian; Bengio, Yoshua; Courville, Aaron. Deep learning. Cambridge, MassachusettsThe MIT Press: The MIT Press, 2016. ISBN 9780262035613.