

**FICHA IDENTIFICATIVA****Datos de la Asignatura**

<b>Código</b>	36441
<b>Nombre</b>	Aprendizaje profundo
<b>Ciclo</b>	Grado
<b>Créditos ECTS</b>	4.5
<b>Curso académico</b>	2023 - 2024

**Titulación(es)**

<b>Titulación</b>	<b>Centro</b>	<b>Curso</b>	<b>Periodo</b>
1406 - Grado en Ciencia de Datos	Escuela Técnica Superior de Ingeniería	4	Segundo cuatrimestre

**Materias**

<b>Titulación</b>	<b>Materia</b>	<b>Caracter</b>
1406 - Grado en Ciencia de Datos	18 - Aprendizaje Profundo	Optativa

**Coordinación**

<b>Nombre</b>	<b>Departamento</b>
LAPARRA PEREZ-MUELAS, VALERO	242 - Ingeniería Electrónica
MARTIN GUERRERO, JOSE DAVID	242 - Ingeniería Electrónica
SORIA OLIVAS, EMILIO	242 - Ingeniería Electrónica

**RESUMEN**

La asignatura “Aprendizaje Profundo (AP)” trata probablemente el tema más popular dentro del aprendizaje automático. La idea básica del AP es construir redes neuronales (ya estudiadas en la asignatura “Modelos conexionistas”, de tercer curso del grado) pero con la particularidad de que existe un gran número de conexiones entre las neuronas como resultado de utilizar arquitecturas con múltiples capas.

La idea de utilizar este tipo de arquitecturas no es nueva; desde los albores de la investigación en redes neuronales, resultaba lógico pensar que una mayor conectividad repercutiría en una mayor capacidad de modelado. A las dificultades tecnológicas por la alta capacidad de cálculo requerida, se unía el hecho de carecer de métodos efectivos de entrenamiento, por lo que no fue hasta que estos problemas se comenzaron a resolver entre 2005 y 2010, cuando el AP empezó a utilizarse en diferentes problemas prácticos.

Los espectaculares resultados en aplicaciones hasta la fecha inabordables como la segmentación o



clasificación de imágenes, la traducción automática o el análisis de sentimientos han hecho de esta disciplina una de las más efervescentes a nivel académico (con numerosas propuestas nuevas y publicaciones asociadas), tecnológico (donde el uso rutinario de GPUs ha permitido su utilización en problemas cada vez más complejos) y social (ya que muchas aplicaciones se han extendido de manera sistemática).

A priori, cualquier problema susceptible de ser resuelto mediante una red neuronal no profunda, puede ser también resuelto por AP, en principio con una mayor capacidad de modelado si el conjunto de datos es suficientemente grande y diverso. No obstante, la mayoría de aplicaciones suelen estar relacionadas con imágenes y predicción de secuencias temporales (muy habitualmente dentro del procesado de lenguaje natural).

Las aproximaciones principales al AP son las siguientes:

- Autoencoders.
- Redes convolucionales.
- Redes recurrentes.
- Aproximaciones generativas.

La asignatura comenzará introduciendo y revisando los conceptos más importantes a tener en cuenta en el AP, el tipo de aplicaciones habituales y qué tipo de solución es la más habitual para cada tipo de aplicaciones. Una vez presentado el entorno de trabajo, se revisarán rápidamente las redes convolucionales, ya introducidas en la asignatura “Modelos Conexionistas”, y se describirán con más detalle el resto de aproximaciones. Finalmente, se introducirán aproximaciones relacionadas con otros tipos de aprendizaje, como el Aprendizaje por Refuerzo Profundo.

En las clases prácticas se reforzarán los conceptos introducidos en teoría mediante la implementación en Python de modelos de cada una de las aproximaciones para resolver una serie de problemas prácticos; algunos más académicos para asentar las nociones teóricas y otros más prácticos de problemas reales para mostrar la aplicabilidad y versatilidad del AP.

Las clases de teoría se impartirán en castellano y las clases prácticas y de laboratorio según consta en la ficha de la asignatura disponible en la web del grado.

## CONOCIMIENTOS PREVIOS

### Relación con otras asignaturas de la misma titulación

No se han especificado restricciones de matrícula con otras asignaturas del plan de estudios.

### Otros tipos de requisitos

La asignatura es de carácter optativo y se enmarca en el 4º curso del grado, donde por tanto se asume que el estudiante ya ha conseguido los conocimientos básicos para desarrollar su actividad profesional como científico de datos. La asignatura puede verse como una extensión de dos asignaturas de tercero (36426-Aprendizaje Máquina y especialmente 36428-Modelos Conexionistas). Por tanto, es altamente recomendable que los estudiantes matriculados en AP hayan superado ambas asignaturas para poder seguir l



## COMPETENCIAS

### 1406 - Grado en Ciencia de Datos

- (CG02) Capacidad de resolver problemas con iniciativa, creatividad, y de comunicar y transmitir conocimientos, habilidades y destrezas, comprendiendo la responsabilidad ética y profesional de la actividad del Científico de Datos.
- (CG03) Capacidad para la realización de modelos, cálculos, informes, planificación de tareas y otros trabajos análogos en el ámbito específico de la Ciencia de Datos.
- (CT03) Habilidad para defender su trabajo con rigor y argumentos, exponiéndolo de forma adecuada y precisa, apoyándose en los medios necesarios.
- (CT05) Capacidad para evaluar las ventajas e inconvenientes de diferentes alternativas metodológicas y/o tecnológicas en distintos ámbitos de aplicación.
- (CE03) Capacidad para resolver problemas de clasificación, modelización, segmentación y predicción a partir de un conjunto de datos.
- (CE07) Capacidad para modelar la dependencia entre una variable respuesta y varias variables explicativas, en conjuntos de datos complejos, mediante técnicas de aprendizaje máquina, interpretando los resultados obtenidos.
- (CE13) Saber diseñar, aplicar y evaluar algoritmos de Ciencia de Datos para la resolución de problemas complejos.
- (CB3) Que los estudiantes tengan la capacidad de reunir e interpretar datos relevantes (normalmente dentro de su área de estudio) para emitir juicios que incluyan una reflexión sobre temas relevantes de índole social, científica o ética.
- (CB4) Que los estudiantes puedan transmitir información, ideas, problemas y soluciones a un público tanto especializado como no especializado.

## RESULTADOS DE APRENDIZAJE

Los resultados de aprendizaje (RA) más importantes de la asignatura son:

- RA1: Aprender las principales arquitecturas neuronales profundas.
- RA2: Conocer los problemas del aprendizaje profundo y sus soluciones.
- RA3: Conocer los principales algoritmos de redes recurrentes.

Cada uno de estos tres resultados permite en mayor o menor medida adquirir todas las competencias de la asignatura. En particular:

- RA1 (CG2, CB3, CB4, CT3, CE3) es fundamental para que el estudiante sea capaz de saber en qué situaciones se puede abordar un problema basado en datos con AP.
- RA2 (CG2, CG3, CB3, CB4, CT3, CT5, CE3, CE7, CE13) permitirá al alumno decidir qué aproximación de AP es más adecuada para resolver un problema basado en análisis de datos, teniendo en cuenta las ventajas que puede aportar en cuanto a modelado, los inconvenientes y las posibles soluciones a éstos.
- RA3 (CG2, CG3, CB3, CB4, CT3, CT5, CE3, CE7, CE13) se centra fundamentalmente en una de las aproximaciones más importantes del AP, como es la de las redes recurrentes para la predicción de



secuencias.

## DESCRIPCIÓN DE CONTENIDOS

### 1. Introducción

1. El marco del aprendizaje profundo.
  - Definiciones.
  - Redes neuronales superficiales y profundas.
  - Redes profundas frente a métodos kernel.
  - Paralelización.
2. Contribuciones relevantes.
  - Funciones de activación lineales rectificadas: RELU y variantes.
  - Dropout.
  - Flexibilidad del modelado y transfer learning.
3. Revisión de redes neuronales convolucionales.
4. Aplicaciones destacadas.

### 2. Redes recurrentes

1. Predicción de secuencias temporales.
2. Redes recurrentes profundas para la predicción de secuencias de longitud variable.
3. Control del gradiente
  - Desvanecimiento y crecimiento descontrolado del gradiente.
  - La red LSTM (Long Short-Term Memory).
  - La red GRU (Gated Recurrent Unit).
4. Modelos de atención: redes Transformer.

### 3. Autoencoders

1. Justificación y necesidad de los autoencoders. Aproximaciones principales.
2. Autoencoders lineales y no lineales.
3. Autoencoders variacionales.



#### 4. Aproximaciones generativas

1. Aproximaciones generativas frente a discriminativas.
2. Redes generativas antagónicas: GAN.
3. Variantes de GAN.

#### 5. Aprendizaje por refuerzo profundo

1. Revisión de aprendizaje por refuerzo.
2. Aproximaciones profundas.

#### 6. Prácticas de laboratorio

Las prácticas de laboratorio permitirán asentar los conocimientos estudiados en teoría mediante la implementación de modelos y la resolución práctica de problemas académicos y reales. Se realizarán cinco prácticas de laboratorio:

1. Redes convolucionales.
2. Redes recurrentes y transfer learning.
3. Autoencoders.
4. Redes GAN.
5. Aprendizaje por refuerzo profundo.

### VOLUMEN DE TRABAJO

ACTIVIDAD	Horas	% Presencial
Clases de teoría	25,00	100
Prácticas en laboratorio	15,00	100
Prácticas en aula	5,00	100
Asistencia a eventos y actividades externas	2,00	0
Elaboración de trabajos en grupo	5,00	0
Elaboración de trabajos individuales	4,00	0
Estudio y trabajo autónomo	28,00	0
Lecturas de material complementario	2,00	0
Preparación de actividades de evaluación	15,00	0



Preparación de clases de teoría	2,50	0
Preparación de clases prácticas y de problemas	2,50	0
Resolución de casos prácticos	5,00	0
Resolución de cuestionarios on-line	1,50	0
<b>TOTAL</b>	<b>112,50</b>	

## METODOLOGÍA DOCENTE

Las metodologías docentes utilizadas en esta asignatura son:

MD1 - Actividades teóricas (CG3, CB4, CT3, CT5, CE3, CE7, CE13): Desarrollo expositivo de la materia con la participación del estudiante en la resolución de cuestiones puntuales. Realización de cuestionarios individuales de evaluación.

MD2 - Actividades prácticas (CG2, CB3, CT5, CE3, CE7, CE13): Aprendizaje mediante resolución de problemas, ejercicios y casos de estudio a través de los cuales se adquieren competencias sobre los diferentes aspectos de la materia.

MD4 - Trabajos en laboratorio y/o aula ordenador (CG2, CG3, CB3, CB4, CT3, CT5, CE3, CE7, CE13): Aprendizaje mediante la realización de actividades desarrolladas de forma individual o en grupos reducidos y llevadas a cabo en laboratorios y/o aulas de ordenador.

## EVALUACIÓN

La calificación final de la asignatura se obtendrá como resultado de la media pesada entre las partes de teoría y de prácticas. De acuerdo con los créditos asignados a cada parte, la teoría tendrá una representación de 2/3 en la nota final y la práctica el tercio restante.

La nota de teoría correspondiente a la primera convocatoria saldrá como resultado de:

- SE1 (30%; CG2, CG3, CB3, CB4, CT5, CE3, CE7, CE13): Pruebas objetivas, consistentes en uno o más exámenes de cuestiones teóricas, problemas sintéticos y problemas prácticos reales. Para superar la asignatura, se exigirá una calificación mínima de 4 (sobre 10) en esta parte.

- SE2 (60%; CG2, CG3, CB3, CB4, CT3, CT5, CE3, CE7, CE13): Trabajos, memorias y exposiciones orales.

- SE3 (10%; CG2, CB4, CT3, CE3, CE7, CE13): Evaluación continua de cada alumno, basada en la participación y grado de implicación del alumno en

el proceso de enseñanza-aprendizaje, teniendo en cuenta la asistencia regular a las actividades presenciales previstas y la resolución de cuestiones y problemas propuestos periódicamente.

Respecto a la calificación de prácticas, el 40% de la nota corresponderá con SE2 (CG2, CG3, CB3, CB4, CT3, CT5, CE3, CE7, CE13) y el 60% con SE1 (CG2, CG3, CB3, CB4, CT5, CE3, CE7, CE13). Para superar la asignatura, se exigirá una calificación mínima de 4 (sobre 10) en SE1. Del 40% correspondiente a la evaluación continua, el 70% corresponderá con la realización de los ejercicios propuestos en la sesión de prácticas, que podrán ser evaluados por el profesor a la finalización de la



práctica. El 30% restante provendrá de la preparación previa a la sesión de prácticas y que se evaluará rápidamente al principio de cada sesión de prácticas. Las prácticas pueden realizarse de manera individual o por parejas; SE1 se evaluará individualmente. Además, el profesor puede optar para evaluar de manera individual las sesiones regulares de prácticas aunque estas se hayan desarrollado por grupos de dos estudiantes.

La segunda convocatoria se evaluará igual que la primera con la excepción de que en la parte de teoría, SE1 tendrá un peso del 40% y SE3 del 0%; en la parte de prácticas el 20% corresponderá a SE2 y el 80% a SE1.

En cualquier caso, el sistema de evaluación se regirá por lo establecido en el Reglamento de Evaluación y Calificación de la Universidad de Valencia para Grados y Másteres (<https://webges.uv.es/uvTaeWeb/MuestraInformacionEdictoPublicoFrontAction.do?accion=inicio&idEdictoSeleccionado=5639>).

## REFERENCIAS

### Básicas

- Ian Goodfellow, Yoshua Bengio and Aaron Courville (2016). Deep learning. The MIT Press.
- Valentina Emilia Balas, Sanjiban Sekhar Roy, Dharmendra Sharma, Pijush Samui (2019). Handbook of Deep Learning Applications. Springer
- Nikhil Ketkar (2017). Deep learning with Python: a hands-on introduction. Apress.
- Charu C. Aggarwal (2018). Neural Networks and Deep Learning: A Textbook. Springer.

### Complementarias

- Kaizhu Huang, Amir Hussain, Qiu-Feng Wang, Rui Zhang (2019). Deep Learning: Fundamentals, Theory and Applications. Springer.
- Ovidiu Calin (2020). Deep Learning Architectures: A Mathematical Approach. Springer.
- Santanu Pattanayak (2017). Pro Deep Learning with TensorFlow: A Mathematical Approach to Advanced Artificial Intelligence in Python. Apress.