

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

<b>Código</b>	46581
<b>Nombre</b>	Aprendizaje máquina (III)
<b>Ciclo</b>	Máster
<b>Créditos ECTS</b>	3.0
<b>Curso académico</b>	2023 - 2024

**Titulación(es)**

<b>Titulación</b>	<b>Centro</b>	<b>Curso</b>	<b>Periodo</b>
2262 - Máster Universitario en Ciencia de Datos	Escuela Técnica Superior de Ingeniería	1	Segundo cuatrimestre

**Materias**

<b>Titulación</b>	<b>Materia</b>	<b>Carácter</b>
2262 - Máster Universitario en Ciencia de Datos	13 - Aprendizaje máquina (III)	Obligatoria

**Coordinación**

<b>Nombre</b>	<b>Departamento</b>
MUÑOZ MARI, JORDI	242 - Ingeniería Electrónica
SERRANO LOPEZ, ANTONIO JOSE	242 - Ingeniería Electrónica

**RESUMEN**

Aprendizaje Máquina 3 es una asignatura obligatoria dentro del plan de estudios del máster oficial de Ciencia de Datos por la Universitat de València. Se cursa cronológicamente después de Aprendizaje Máquina 1 y 2 y aprovecha los contenidos impartidos anteriormente para introducir tipos de aprendizajes más avanzados así como las últimas metodologías que permiten aprovechar los datos desde nuevas perspectivas (análisis de anomalías) o analizar el comportamiento de los modelos de aprendizaje máquina (IA explicable)

**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

## COMPETENCIAS (RD 1393/2007) // RESULTADOS DEL APRENDIZAJE (RD 822/2021)

### 2262 - Máster Universitario en Ciencia de Datos

- Que los/las estudiantes posean las habilidades de aprendizaje que les permitan continuar estudiando de un modo que habrá de ser en gran medida autodirigido o autónomo
- Ser capaces de valorar la necesidad de completar su formación técnica, científica, en lenguas, en informática, en literatura, en ética, social y humana en general, y de organizar su propio autoaprendizaje con un alto grado de autonomía
- Habilidad para defender criterios con rigor y argumentos, y de exponerlos de forma adecuada y precisa
- Capacidad de acceso y gestión de la información en diferentes formatos para su posterior análisis con el fin de obtener conocimiento a partir de datos.
- Capacidad para trabajar en equipo para llegar a soluciones de problemas interdisciplinarios usando técnicas de análisis de datos.
- Ser capaces de acceder a herramientas de información (bibliográficas y de empleo) y utilizarlas apropiadamente.
- Ser capaces de asumir la responsabilidad de su propio desarrollo profesional y de su especialización en uno o más campos de estudio, aplicando los conocimientos adquiridos en la identificación de salidas profesionales y yacimientos de empleo.
- Extraer conocimiento de conjuntos de datos en diferentes formatos.
- Entender la utilidad de la ciencia de datos y sus elementos asociados, así como su aplicación en la resolución de problemas, eligiendo las técnicas más adecuadas a cada problema, aplicando de forma correcta las técnicas de evaluación y, finalmente, interpretando los modelos y resultados.
- Capacidad para resolver problemas de clasificación, modelización, segmentación y predicción a partir de un conjunto de datos.
- 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.

**RESULTADOS DE APRENDIZAJE (RD 1393/2007) // SIN CONTENIDO (RD 822/2021)**

Aprender las técnicas más extendidas de IA Explicable. Conocer los diferentes tipos de aprendizaje no estándar existentes actualmente. Saber aplicar las diferentes técnicas de detección de anomalías.

**DESCRIPCIÓN DE CONTENIDOS****1. Otros aprendizajes**

Otros tipos de aprendizajes:  
Multietiqueta, multitarea y multimodal.  
Aprendizaje semi-supervisado.  
Aprendizaje activo.  
Aprendizaje on-line / incremental.

**2. Detección de anomalías**

Detección de anomalías:  
Anomalías en datos tabulares.  
Anomalías en series temporales.  
Anomalías en imágenes y video.  
Anomalías en grafos.

**3. AI Explicable****VOLUMEN DE TRABAJO**

ACTIVIDAD	Horas	% Presencial
Prácticas en laboratorio	18,00	100
Clases de teoría	8,00	100
Clases teórico-prácticas	4,00	100
Elaboración de trabajos en grupo	10,00	0
Estudio y trabajo autónomo	30,00	0
Preparación de actividades de evaluación	5,00	0
<b>TOTAL</b>	<b>75,00</b>	



## METODOLOGÍA DOCENTE

Actividades teóricas. Desarrollo expositivo de la materia con la participación del estudiante en la resolución de cuestiones puntuales. Realización de cuestionarios individuales de evaluación.

Actividades prácticas. 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.

Trabajos en laboratorio y/o aula ordenador. Aprendizaje mediante la realización de actividades desarrolladas de forma individual o en grupos reducidos y llevadas a cabo en aulas de ordenador.

## EVALUACIÓN

La evaluación del aprendizaje de los conocimientos y competencias conseguidas por los estudiantes se hará de forma continuada a lo largo del curso, y consta de los siguientes bloques de evaluación:

1. Ejercicios y trabajos entregados durante el curso y/o exámenes parciales: 40% de la nota final.
2. Examen final: 60% de la nota final.

Las calificaciones obtenidas en el apartado 1 se conservarán en las dos convocatorias del curso académico en que hayan sido realizadas, dado que su evaluación sólo es posible en el periodo de docencia.

## REFERENCIAS

### Básicas

- Interpretable Machine Learning: A Guide for Making Black Box Models Explainable, Christoph Molnar, <https://christophm.github.io/interpretable-ml-book>, 2022.
- Explanatory Model Analysis, Przemyslaw Biecek and Tomasz Burzykowski, Chapman and Hall/CRC, New York, <https://pbiecek.github.io/ema/>. 2021.
- TKishan G. Mehrotra, Chilukuri K. Mohan, and HuaMing Huang. 2017. Anomaly Detection Principles and Algorithms (1st. ed.). Springer Publishing Company, Incorporated.
- Baltruaitis, Tadas et al. Multimodal Machine Learning: A Survey and Taxonomy. IEEE Transactions on Pattern Analysis and Machine Intelligence 41 (2017): 423-443. <https://arxiv.org/abs/1705.09406>



- Xiaojin Zhu, Andrew B. Goldberg, Ronald Brachman, and Thomas Dietterich. 2009. Introduction to Semi-Supervised Learning. Morgan and Claypool Publishers.
- Settles, Burr. Active Learning. : Morgan & Claypool Publishers, 2012.

### **Complementarias**

- Aggarwal, C. C. (2013). Outlier Analysis. Springer. ISBN: 978-1-4614-6396-2
- Xu, P., Zhu, X., & Clifton, D.A. (2022). Multimodal Learning with Transformers: A Survey. IEEE transactions on pattern analysis and machine intelligence, <https://arxiv.org/abs/2206.06488>
- Olivier Chapelle, Bernhard Schölkopf, and Alexander Zien. 2006. Semi-Supervised Learning (Adaptive Computation and Machine Learning). The MIT Press.