



Guía docente

295921 - FAA - Fundamentos de Aprendizaje Automático

Última modificación: 20/01/2026

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: 2025 **Créditos ECTS:** 6.0 **Idiomas:** Inglés

PROFESORADO

Profesorado responsable: FRANCESC POZO MONTERO

Otros: Pozo Montero, Francesc

CAPACIDADES PREVIAS

Se espera que los estudiantes tengan una sólida formación a nivel de grado en álgebra lineal (vectores y matrices, operaciones matriciales, normas, valores propios y vectores propios), cálculo (funciones de una y varias variables, derivadas parciales, gradientes y conceptos básicos de optimización), y probabilidad y estadística (variables aleatorias, distribuciones de probabilidad habituales, esperanza, varianza y conceptos introductorios de estimación). Asimismo, los estudiantes deben ser capaces de programar en al menos un lenguaje de alto nivel, como Python, y estar familiarizados con los principales conceptos de programación, incluyendo variables, estructuras de control, funciones y estructuras de datos simples. Además, se espera que los estudiantes se sientan cómodos leyendo notación matemática y dispongan de habilidades básicas de pensamiento algorítmico y computacional; no se requieren conocimientos previos de aprendizaje automático, pero se recomienda a los estudiantes que no cuenten con parte de esta formación que revisen el material correspondiente durante las primeras semanas del curso.

REQUISITOS

Se recomienda encarecidamente que los estudiantes dispongan de un ordenador portátil personal para seguir las clases y las sesiones de laboratorio, ya que en el aula no se proporcionarán ordenadores; no obstante, habrá conexión eléctrica disponible para los dispositivos. Asimismo, se recomienda registrarse en el curso MITx 6.036 Introduction to Machine Learning de la MIT Open Learning Library (<https://openlearninglibrary.mit.edu/courses/course-v1:MITx+6.036+1T2019/course/>), que ofrece ejercicios, tareas y laboratorios que pueden utilizarse para la autoevaluación y la práctica de los contenidos del curso. El registro y el uso de este recurso en línea son recomendados, pero no obligatorios para la superación de la asignatura.

METODOLOGÍAS DOCENTES

La asignatura combina la exposición teórica con la aplicación práctica para proporcionar a los estudiantes una comprensión sólida de los principios fundamentales del aprendizaje automático. Los conceptos clave se introducirán mediante clases magistrales apoyadas por materiales visuales y formulaciones matemáticas, seguidas de ejemplos ilustrativos y discusiones guiadas. Las sesiones prácticas y las actividades evaluables pondrán énfasis en la experiencia directa con datos, modelos y algoritmos, permitiendo a los estudiantes aplicar las ideas teóricas en contextos realistas. Se fomentará la participación activa del estudiante a través de actividades de resolución de problemas y análisis de resultados, favoreciendo el pensamiento crítico y una comprensión más profunda de las hipótesis de los modelos, sus limitaciones y su rendimiento.

OBJETIVOS DE APRENDIZAJE DE LA ASIGNATURA

Al finalizar con éxito esta asignatura, el estudiante será capaz de comprender y explicar los conceptos fundamentales y las hipótesis subyacentes a los métodos de aprendizaje automático; formular problemas de aprendizaje supervisado y no supervisado en términos matemáticos; seleccionar modelos, funciones de pérdida y criterios de evaluación adecuados para una tarea determinada; aplicar algoritmos fundamentales de aprendizaje automático para problemas de clasificación, regresión, agrupamiento, así como nociones básicas de aprendizaje secuencial y por refuerzo; analizar el rendimiento de los modelos y su capacidad de generalización; implementar y evaluar modelos de aprendizaje automático utilizando herramientas computacionales apropiadas; e interpretar de manera crítica los resultados, las limitaciones y las posibles fuentes de error de los modelos basados en datos.

CONTENIDOS

Introducción

Descripción:

Este capítulo introduce el aprendizaje automático como la tarea de realizar predicciones o tomar decisiones a partir de datos, con especial énfasis en la capacidad de generalización más allá de los ejemplos observados. Se presentan la motivación del aprendizaje automático, el problema de la inducción y un marco unificado para describir los problemas y las soluciones de aprendizaje. El capítulo expone conceptos clave como las clases de problemas, las hipótesis, los criterios de evaluación, los tipos de modelos, las clases de modelos y los algoritmos de aprendizaje, estableciendo la base conceptual del resto de la asignatura.

Objetivos específicos:

Al finalizar este capítulo, el estudiante será capaz de:

- Explicar los objetivos y el alcance del aprendizaje automático y su relación con campos afines.
- Identificar las principales clases de problemas de aprendizaje automático y sus características.
- Comprender el papel de las hipótesis y de los criterios de evaluación en el aprendizaje a partir de datos.
- Describir los componentes fundamentales de un sistema de aprendizaje automático y su interacción.

Dedicación: 10h

Grupo grande/Teoría: 2h

Grupo pequeño/Laboratorio: 2h

Aprendizaje autónomo: 6h

Clasificadores lineales

Descripción:

Este capítulo introduce los clasificadores lineales como una clase fundamental de modelos para la clasificación supervisada. Se presentan las funciones de decisión lineales, la interpretación geométrica de la clasificación en el espacio de características y el concepto de separación de datos mediante fronteras lineales. El capítulo sienta las bases para comprender los métodos de clasificación lineal y sus limitaciones, y prepara el terreno para los algoritmos de aprendizaje que se abordarán posteriormente.

Objetivos específicos:

Al finalizar este capítulo, el estudiante será capaz de:

- Formular problemas de clasificación lineal utilizando notación matemática.
- Interpretar geométricamente los clasificadores lineales en el espacio de características.
- Comprender el papel de las fronteras de decisión en tareas de clasificación.
- Identificar las ventajas y las limitaciones de los clasificadores lineales.

Dedicación: 10h

Grupo grande/Teoría: 2h

Grupo pequeño/Laboratorio: 2h

Aprendizaje autónomo: 6h

El perceptrón

Descripción:

Este capítulo introduce el perceptrón como un algoritmo fundamental de aprendizaje para la clasificación lineal. Se presentan el modelo del perceptrón, su regla de actualización y su interpretación como un procedimiento iterativo para encontrar un hiperplano separador. El capítulo analiza las condiciones de convergencia, la relación entre el perceptrón y los clasificadores lineales, y pone de relieve las limitaciones del algoritmo cuando los datos no son linealmente separables.

Objetivos específicos:

Al finalizar este capítulo, el estudiante será capaz de:

- Describir el perceptrón como un modelo de clasificación lineal.
- Comprender y aplicar el algoritmo de aprendizaje del perceptrón.
- Interpretar la regla de actualización del perceptrón desde un punto de vista geométrico y algebraico.
- Analizar las propiedades de convergencia y las limitaciones del perceptrón.

Dedicación: 10h

Grupo grande/Teoría: 2h

Grupo pequeño/Laboratorio: 2h

Aprendizaje autónomo: 6h

Representación de características

Descripción:

Este capítulo se centra en el papel de la representación de características en el aprendizaje automático y en cómo la elección de la representación influye en el rendimiento de los modelos. Se introducen las transformaciones de características, las expansiones de base y las técnicas de normalización, destacando cómo los datos originales pueden transformarse en representaciones que faciliten las tareas de aprendizaje. El capítulo pone énfasis en la interacción entre la representación de los datos y la complejidad del modelo.

Objetivos específicos:

Al finalizar este capítulo, el estudiante será capaz de:

- Comprender la importancia de la representación de características en el aprendizaje automático.
- Aplicar transformaciones básicas de características y expansiones de base.
- Analizar cómo las decisiones de representación afectan al rendimiento y a la generalización de los modelos.
- Reconocer los compromisos entre la complejidad de las características y la capacidad de aprendizaje.

Dedicación: 10h

Grupo grande/Teoría: 2h

Grupo pequeño/Laboratorio: 2h

Aprendizaje autónomo: 6h

Maximización del margen

Descripción:

Este capítulo introduce la maximización del margen como un principio central en la clasificación supervisada. Se formula el aprendizaje como un problema de optimización cuyo objetivo es encontrar una frontera de decisión que no solo separe los datos, sino que lo haga con el mayor margen posible. El capítulo analiza la relación entre el margen, la robustez y la capacidad de generalización, e introduce la regularización como un mecanismo para controlar la complejidad del modelo.

Objetivos específicos:

Al finalizar este capítulo, el estudiante será capaz de:

- Comprender el concepto de margen en problemas de clasificación.
- Formular objetivos de aprendizaje basados en el margen en términos matemáticos.
- Explicar el papel de la regularización en el control de la complejidad del modelo.
- Analizar cómo la maximización del margen influye en la generalización.

Dedicación: 10h

Grupo grande/Teoría: 2h

Grupo pequeño/Laboratorio: 2h

Aprendizaje autónomo: 6h

Descenso del gradiente

Descripción:

Este capítulo introduce el descenso del gradiente como un método fundamental de optimización para el entrenamiento de modelos de aprendizaje automático. Se presenta la idea de minimizar una función objetivo mediante actualizaciones iterativas de los parámetros basadas en la información del gradiente, y se discuten aspectos prácticos como la selección del tamaño del paso, el comportamiento de la convergencia y la eficiencia computacional. El capítulo proporciona la base de optimización utilizada por muchos algoritmos de aprendizaje a lo largo de la asignatura.

Objetivos específicos:

Al finalizar este capítulo, el estudiante será capaz de:

- Comprender el descenso del gradiente como una técnica de optimización para el aprendizaje de modelos.
- Aplicar métodos basados en gradientes para minimizar funciones objetivo.
- Analizar los efectos del tamaño del paso y las propiedades de convergencia.
- Reconocer el papel de la optimización en el entrenamiento de modelos de aprendizaje automático.

Dedicación: 10h

Grupo grande/Teoría: 2h

Grupo pequeño/Laboratorio: 2h

Aprendizaje autónomo: 6h

Regresión

Descripción:

Este capítulo aborda los problemas de regresión, en los que el objetivo es predecir salidas de valor continuo a partir de datos de entrada. Se presenta la regresión como una tarea de aprendizaje supervisado, se introducen modelos y funciones de pérdida habituales, y se analiza cómo se formulan y evalúan los problemas de regresión. El capítulo pone énfasis en la interpretación de las predicciones y en la relación entre la elección del modelo, las funciones de pérdida y la capacidad de generalización.

Objetivos específicos:

Al finalizar este capítulo, el estudiante será capaz de:

- Formular problemas de regresión dentro del marco del aprendizaje supervisado.
- Comprender las funciones de pérdida más habituales en regresión y sus implicaciones.
- Aplicar modelos de regresión a tareas de predicción continua.
- Analizar el rendimiento y la generalización de los modelos de regresión.

Dedicación: 10h

Grupo grande/Teoría: 2h

Grupo pequeño/Laboratorio: 2h

Aprendizaje autónomo: 6h

Redes neuronales

Descripción:

Este capítulo introduce las redes neuronales como modelos paramétricos flexibles para el aprendizaje supervisado. Se presentan las redes neuronales como composiciones de transformaciones lineales y funciones de activación no lineales, que permiten aproximar funciones complejas. El capítulo analiza las arquitecturas básicas, el papel de las capas ocultas y el entrenamiento de redes neuronales mediante métodos de optimización basados en gradientes.

Objetivos específicos:

Al finalizar este capítulo, el estudiante será capaz de:

- Comprender las redes neuronales como aproximadores de funciones para clasificación y regresión.
- Describir la estructura de las arquitecturas de redes neuronales feedforward.
- Explicar el papel de las funciones de activación y de las capas ocultas.
- Aplicar métodos basados en gradientes para entrenar modelos de redes neuronales.

Dedicación: 15h

Grupo grande/Teoría: 3h

Grupo pequeño/Laboratorio: 3h

Aprendizaje autónomo: 9h

Redes neuronales convolucionales

Descripción:

Este capítulo introduce las redes neuronales convolucionales (CNN) como arquitecturas especializadas diseñadas para procesar datos estructurados con organización espacial, como las imágenes. Se presentan los principios de la convolución, la compartición de pesos y las operaciones de pooling, y se explica cómo estos mecanismos explotan la estructura local y las invariancias de los datos. El capítulo pone de relieve por qué las CNN son especialmente eficaces para entradas de alta dimensión con correlaciones espaciales.

Objetivos específicos:

Al finalizar este capítulo, el estudiante será capaz de:

- Comprender la motivación de las redes neuronales convolucionales.
- Describir las operaciones de convolución y pooling y su papel en las arquitecturas CNN.
- Explicar cómo la compartición de pesos y la localidad reducen la complejidad del modelo.
- Analizar las ventajas de las CNN para datos estructurados espacialmente.

Dedicación: 15h

Grupo grande/Teoría: 3h

Grupo pequeño/Laboratorio: 3h

Aprendizaje autónomo: 9h

Modelos secuenciales

Descripción:

Este capítulo introduce modelos para datos secuenciales, en los que las observaciones y las predicciones están ordenadas en el tiempo y pueden presentar dependencias temporales. Se presentan los modelos basados en estados como un marco para representar secuencias, destacando cómo los estados internos resumen la información pasada para influir en las predicciones futuras. El capítulo proporciona la base conceptual para el modelado de datos dependientes del tiempo en el aprendizaje automático.

Objetivos específicos:

Al finalizar este capítulo, el estudiante será capaz de:

- Comprender los retos asociados a los datos secuenciales y temporales.
- Describir representaciones basadas en estados para el modelado de secuencias.
- Formular problemas de aprendizaje que involucren secuencias de entrada y de salida.
- Analizar cómo las dependencias temporales afectan a la predicción y al aprendizaje.

Dedicación: 10h

Grupo grande/Teoría: 2h

Grupo pequeño/Laboratorio: 2h

Aprendizaje autónomo: 6h

Aprendizaje por refuerzo

Descripción:

Este capítulo introduce el aprendizaje por refuerzo como un paradigma de aprendizaje en el que un agente aprende mediante la interacción con un entorno a partir de señales de recompensa. Se presenta el marco del aprendizaje por refuerzo, incluyendo estados, acciones, recompensas y políticas, y se explica cómo el aprendizaje difiere de los entornos supervisados debido a la retroalimentación retardada y la toma de decisiones secuencial. El capítulo establece las bases para comprender cómo los agentes aprenden a actuar de manera óptima a lo largo del tiempo.

Objetivos específicos:

Al finalizar este capítulo, el estudiante será capaz de:

- Comprender el marco del aprendizaje por refuerzo y sus componentes.
- Formular problemas de toma de decisiones como tareas de aprendizaje por refuerzo.
- Distinguir el aprendizaje por refuerzo del aprendizaje supervisado y no supervisado.
- Analizar el papel de las recompensas y de las políticas en la toma de decisiones secuencial.

Dedicación: 10h

Grupo grande/Teoría: 2h

Grupo pequeño/Laboratorio: 2h

Aprendizaje autónomo: 6h

Redes neuronales recurrentes

Descripción:

Este capítulo introduce las redes neuronales recurrentes (RNN) como arquitecturas neuronales diseñadas para modelar datos secuenciales y temporales. Se explica cómo la recurrencia permite que la información de pasos temporales anteriores influya en las predicciones actuales mediante estados ocultos. El capítulo analiza la estructura básica de las RNN, su entrenamiento mediante métodos basados en gradientes y los retos asociados al aprendizaje de dependencias a largo plazo.

Objetivos específicos:

Al finalizar este capítulo, el estudiante será capaz de:

- Comprender las redes neuronales recurrentes como modelos para datos secuenciales.
- Describir el papel de los estados ocultos y de la recurrencia en las RNN.
- Explicar cómo se entrenan las RNN mediante optimización basada en gradientes.
- Reconocer los principales retos del entrenamiento de modelos recurrentes, como los gradientes que se desvanecen o explotan.

Dedicación: 10h

Grupo grande/Teoría: 2h

Grupo pequeño/Laboratorio: 2h

Aprendizaje autónomo: 6h

Sistemas de recomendación

Descripción:

Este capítulo introduce los sistemas de recomendación como métodos de aprendizaje automático diseñados para predecir las preferencias de los usuarios y sugerir elementos relevantes. Se presentan los principios básicos de las tareas de recomendación, incluyendo la predicción de preferencias y el ranking de ítems, y se analizan enfoques habituales basados en las interacciones usuario-ítem. El capítulo pone de relieve los retos de la escasez de datos, la escalabilidad y la evaluación de los sistemas de recomendación.

Objetivos específicos:

Al finalizar este capítulo, el estudiante será capaz de:

- Comprender los objetivos y la estructura de los sistemas de recomendación.
- Formular problemas de recomendación a partir de datos usuario-ítem.
- Identificar retos habituales como la escasez de datos y la escalabilidad.
- Analizar la evaluación del rendimiento de los sistemas de recomendación.

Dedicación: 10h

Grupo grande/Teoría: 2h

Grupo pequeño/Laboratorio: 2h

Aprendizaje autónomo: 6h

Métodos no paramétricos

Descripción:

Este capítulo introduce los métodos no paramétricos en el aprendizaje automático, que realizan pocas o ninguna suposición sobre la forma funcional del modelo subyacente. Se presentan enfoques de aprendizaje en los que la complejidad del modelo puede crecer con la cantidad de datos, poniendo énfasis en la flexibilidad y el comportamiento guiado por los datos. El capítulo analiza los compromisos entre sesgo, varianza, interpretabilidad y coste computacional en el aprendizaje no paramétrico.

Objetivos específicos:

Al finalizar este capítulo, el estudiante será capaz de:

- Comprender las características definitorias de los métodos de aprendizaje no paramétricos.
- Distinguir los enfoques no paramétricos de los modelos paramétricos.
- Analizar las ventajas y las limitaciones de los métodos no paramétricos.
- Evaluar el impacto del tamaño de los datos y de la flexibilidad del modelo en el rendimiento.

Dedicación: 10h

Grupo grande/Teoría: 2h

Grupo pequeño/Laboratorio: 2h

Aprendizaje autónomo: 6h

SISTEMA DE CALIFICACIÓN

El rendimiento del estudiante se evaluará mediante dos exámenes parciales y un proyecto final. Cada examen parcial tendrá un peso del 40 % en la calificación final y evaluará la comprensión de las bases teóricas y de las técnicas de resolución de problemas correspondientes a la parte del curso tratada. El 20 % restante de la calificación final corresponderá a un proyecto final, que consistirá en la aplicación de conceptos de aprendizaje automático a un problema práctico e incluirá una memoria escrita y una presentación oral. La calificación final se calculará como la media ponderada de estos elementos de evaluación, y los criterios de evaluación detallados se proporcionarán con antelación.

NORMAS PARA LA REALIZACIÓN DE LAS PRUEBAS.

Los exámenes parciales y cualquier otra prueba evaluable se realizarán de acuerdo con la normativa académica vigente de la institución. Los estudiantes deberán asistir a los exámenes en la fecha y hora establecidas y presentar una identificación válida si así se requiere. No se permitirá el uso de materiales o dispositivos no autorizados, ni ninguna forma de deshonestidad académica, y estas situaciones se gestionarán de conformidad con los procedimientos disciplinarios aplicables. Los estudiantes son responsables de seguir todas las instrucciones proporcionadas durante la prueba, y el incumplimiento de las mismas podrá dar lugar a sanciones o a la invalidación de la evaluación. Cualquier ausencia justificada o solicitud de adaptación especial deberá comunicarse con antelación y estar debidamente documentada, de acuerdo con las directrices institucionales.

BIBLIOGRAFÍA

Básica:

- Mitchell, Tom M. Machine learning . New York [etc.] : The McGraw-Hill Companies, cop. 1997. ISBN 978-0070428072.
- 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, September 2019. ISBN 978-1492032649.
- Bishop, Christopher M. Pattern recognition and machine learning . New York : Springer, cop. 2006. ISBN 978-0387310732.
- Murphy, Kevin P. Machine learning : a probabilistic perspective . Cambridge, Mass. : MIT Press, cop. 2012. ISBN 978-0262018029.
- Alpaydin, Ethem. Introduction to machine learning . Fourth edition. Cambridge, Massachusetts ; London : The MIT Press, [2020]. ISBN 978-0262043793.

Complementaria:

- Burkov, Andriy. The Hundred-page machine learning book . Leipzig : Andriy Burkov, 2019. ISBN 978-1999579500.

RECURSOS

Enlace web:

- <https://openlearninglibrary.mit.edu/courses/course-v1:MITx+6.036+1T2019/course/>. El curso MITx 6.036 Introduction to Machine Learning disponible en la MIT Open Learning Library es una versión archivada y de libre acceso del curso de pregrado de MIT sobre aprendizaje automático. Presenta una introducción a los principios, algoritmos y aplicaciones del aprendizaje automático desde el punto de vista de la modelización y la predicción. El material incluye apuntes de clase, ejercicios, prácticas de laboratorio y tareas que abarcan aprendizaje supervisado, representación de datos, over-fitting, generalización y aprendizaje por refuerzo, con ejemplos prácticos y aplicaciones en secuencias temporales. En esta versión no se obtiene un certificado.