

# Aprendizaje Máquina Teórico

## (Theoretical Machine Learning)

**Descripción.** En este curso se abordan temas clásicos y contemporáneos del aprendizaje máquina (ML, por sus siglas en inglés) teórico, donde el principal objetivo es establecer garantías estadísticas y de optimización para diversas metodologías. Además de los temas propios del ML, en este curso se presentan de manera autocontenida las técnicas matemáticas necesarias, e.g., grandes desviaciones, elementos de teoría de la información, optimización convexa.

**Prerrequisitos.** Se recomienda haber cursado con anterioridad al menos un curso de álgebra lineal, análisis matemático, probabilidad y estadística. El curso se enfoca en los aspectos teóricos del aprendizaje máquina, por lo que no es necesario contar con conocimientos de programación.

**Objetivos.** Al finalizar el curso los participantes deberán:

- conocer los retos en el análisis de diversas metodologías de ML;
- familiarizarse con el arquetipo de garantías estadísticas y de optimización en ML;
- exponerse, a través de un proyecto final, al estado del arte en algún tema de ML teórico.

### Contenido

#### Módulo 1: Garantías Estadísticas

1. Primeros Ejemplos y Elementos Básicos
2. Aprendizaje Correcto Probablemente Aproximado
3. Convergencia Uniforme
4. Complejidad de Rademacher
5. Dimensión Vapnik–Chervonenkis (VC)
6. Teorema Fundamental del Aprendizaje Estadístico
7. Métodos basados en Teoría de la Información
  - a) Elementos Básicos de Teoría de la Información
  - b) Información Mutua y Generalización
  - c) Distancia de Wasserstein y Generalización

#### Módulo 2: Garantías de Optimización

1. Descenso por Gradiente Estocástico
2. Variantes del Descenso por Gradiente Estocástico
3. Técnicas de Optimización y Aprendizaje PAC
4. Análisis del Paisaje de Optimización
  - a) Comportamiento Asintótico de Puntos Críticos
  - b) Quasi-convexidad Local

### Bibliografía Básica.

- Shalev-Shwartz, S., & Ben-David, S. (2014). Understanding machine learning: From theory to algorithms. Cambridge University Press.
- Cover, T. M., & Thomas, J. A. (2012). Elements of information theory. John Wiley & Sons.
- Nocedal, J., & Wright, S. (2006). Numerical optimization. Springer Science & Business Media.
- Devroye, L., Györfi, L., & Lugosi, G. (2013). A probabilistic theory of pattern recognition. Springer Science & Business Media.
- Bishop, C. M. (2006). Pattern recognition and machine learning. Springer, Heidelberg.

### Acerca del Curso.

- Evaluación: tareas (40%), exámenes parciales (30%) y proyecto final (30%)
- Horario: lunes y miércoles de 3:30pm a 5:00pm, salón 204 IIMAS
- Instructor: Mario Diaz, IIMAS - Oficina 115, [mario.diaz@sigma.iimas.unam.mx](mailto:mario.diaz@sigma.iimas.unam.mx)