

# Aprendizaje Computacional

Eduardo Morales y Jesús González

## Objetivo General

La capacidad de aprender se considera como una de los atributos distintivos del ser humano y ha sido una de las principales áreas de investigación de la Inteligencia Artificial desde sus inicios. En los últimos años se ha visto un crecimiento acelerado en la capacidad de generación y almacenamiento de información, debido a la creciente automatización de procesos y los avances en las capacidades de almacenamiento de información. En gran parte debido a esto, se han desarrollado una gran cantidad de herramientas y técnicas que tienen que ver con el análisis de información. En este aspecto, el desarrollo en el área de aprendizaje ha sido fundamental. El área de aprendizaje en general trata de construir programas que mejoren su desempeño automáticamente con la experiencia.

Los objetivos del curso son: dar un panorama general de lo que es aprendizaje computacional y conocer a detalle las técnicas más importantes empleadas.

## Temario

Los temas que se van a ver en clase son:

1. Introducción a aprendizaje computacional
2. Técnicas principales:
  - Árboles de decisión y regresión
  - Reglas de clasificación
  - Reglas de asociación
  - Programación lógica inductiva
  - Aprendizaje basado en grafos
  - Aprendizaje bayesiano y Redes bayesianas
  - Aprendizaje basado en instancias y casos
  - Clustering

- Aprendizaje por refuerzo
3. Evaluación de algoritmos (intercalado con las técnicas)
  4. Conclusiones

Existen muchos otros temas de aprendizaje. Algunos de estos se ven en el segundo curso de aprendizaje (ver página) como:

- Aprendizaje basado en Kernels y Support Vector Machines
- Ensamblados de clasificadores
- Selección de atributos
- Aprendizaje semi-supervisado

Otros temas se cubren en otros cursos:

- Algoritmos genéticos
- Redes neuronales

Existen temas que se pueden incluir en el segundo curso de aprendizaje como son:

- Colonias de hormigas (*ant colony optimization* o ACO) y de enjambres (*particle swarm optimization* o PSO)
- Modelos lineales de regresión, Bayesianos.
- Modelos lineales para clasificación (funciones discriminantes, modelos generativos, modelos discriminativos, regresión logística)
- Modelos basados en muestreo
- Procesos Gaussianos
- Análisis de componentes principales

- Modelos para secuencias

## Evaluación

La evaluación del curso se hará en base a dos exámenes y un proyecto final (cada uno contando 1/3 parte de la calificación final).

### Lista de posibles Proyectos:

La siguiente es una lista tentativa (no exhaustiva) de posibles proyectos del curso.

- Analizar como afecta el ruido a las técnicas de muestreo (sobre y sub-muestreo).
- Algoritmo de selección de atributos favoreciendo la clase minoritaria
- Aprendizaje por refuerzo distribuido
- Aprendizaje de acciones continuas (en un simulador de vuelo o en robótica móvil)
- Aprendizaje de reglas por imitación (aplicado a ajedrez o simulador de vuelo o robot móvil)
- Aprendizaje semi-supervisado (evaluar asignación de pesos diferentes a las instancias no clasificadas).
- Crear nuevos atributos (*constructive induction*)
- Reimplementar algún algoritmo reciente de las técnicas vistas en clase con alguna mejora.
- Aprendizaje jerárquico multiclase
- Aprendizaje en secuencias

# Referencias

1. T. Mitchell (1997) *Machine Learning*, McGraw–Hill.
2. I.H. Witten, E. Frank (2005) *Data Mining: practical machine learning tools and techniques* 2nd. Edition. Morgan Kaufmann
3. J. Han, M. Kamber (2001) *Data Mining: concepts and techniques*, Morgan Kaufmann.
4. D. Hand, H. Mannila, P. Smyth (2001). *Principales of Data Mining*, MIT Press
5. R. Michalski, I. Bratko, M. Kubat (1998) *Machine Learning and data mining: methods and applications*, John Wiley and Sons.
6. B. Schölkopf, A. Smola (2002). *Learning with Kernels: Support Vector Machines, Regularization, Optimization, and Beyond*, MIT Press.
7. R. Sutton, A. Barto (1998). *Reinforcement Learning: An Introduction*. MIT Press.
8. N. Lavrac, S. Džeroski (1994). *Inductive Logic Programming: Techniques and Applications*. Ellis Horwood.
9. T. Hastie, R. Tibshirani, J. Friedman (2001). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. Springer-Verlag.
10. C. Bishop (2006). *Pattern Recognition and Machine Learning*. Springer.