

---

# TEMARIO

Aprendizaje Estadístico

## Descripción

En Aprendizaje Estadístico (AE) se utilizan modelos con los cuales a partir de un conjunto de variables podamos predecir otras, sin importar su tipo, evaluando después el poder predictivo del modelo. Además de este enfoque predictivo o supervisado, en AE podemos hacer análisis no supervisado. En este, todas las variables son analizadas simultáneamente, obteniendo por ejemplo grupos de individuos similares o permitiendo reducir la dimensión de la información. Así mismo, en AE se generalizan técnicas en Estadística clásica al introducir no linealidad, como por ejemplo en algunas variaciones de modelos no lineales de regresión o métodos de clasificación con fronteras de separación entre clases no lineales.

En Ciencia de Datos la relevancia de AE radica en que se introducen modelos, conceptos y el tipo de enfoque estadístico en el que se fundamentan las técnicas de Deep Learning. Así, las redes neuronales introducidas en el curso son el fundamento para generar modelos sofisticados, como aquellos usados en clasificación de imágenes, procesamiento de lenguaje natural o la modelación de secuencias.

1. Introducción al Aprendizaje Estadístico
  - a) Elementos del problema de aprendizaje
  - b) Tipos y objetivos de análisis
  - c) Función de pérdida, riesgo teórico y empírico
  - d) Aprendizaje exitoso
  - e) Aprendizaje y sus tipos
  - f) Ejemplos
2. Evaluación y validación
  - a) Validación y sus tipos
  - b) Relación entre varianza y sesgo
  - c) Métodos de ensamble
    - (i) Bagging
    - (ii) Boosting
  - d) Métricas en clasificadores (curva ROC)
  - e) Evaluación en regresiones
3. Modelos de Aprendizaje
  - a) Aprendizaje supervisado y sus tipos
  - b) Aprendizaje no supervisado: Conglomerados y PCA
  - c) Aprendizaje reforzado
4. Métodos supervisados y no supervisados basados en distancias
  - a) Distancias
  - b) Métodos no supervisados
    - (i) Jerárquicos

- (ii) De Partición (k-means)
- c) Métodos supervisados (k vecinos más cercanos)
- 5. Árboles de regresión y de clasificación
  - a) Generalidades y definiciones
  - b) Árboles de regresión
  - c) Árboles de clasificación
- 6. Métodos basados en kernels
  - a) Generalidades e importancia
  - b) Matriz de Gram y kernel trick
  - c) Espacio vectorial generado por los kernels
  - d) Espacio de productos interiores y de Hilbert
  - e) Teorema de Mercer
  - f) Tipos de kernel
  - g) Ejemplos de algunas aplicaciones
    - (i) KPCA
    - (ii) Estimación de densidad
    - (iii) Regresión por kernels
- 7. Máquinas de soporte vectorial
  - a) Clasificador de máximo margen
  - b) Clasificador de soporte vectorial
  - c) Máquinas de soporte vectorial y kernels
- 8. Redes neuronales artificiales
  - a) Perceptrón multicapa
    - (i) Neurona artificial y TLU
    - (ii) Funciones de activación
    - (iii) Perceptrones y preceptrones multicapa
    - (iv) Ajuste (descenso del gradiente)
    - (v) Epoch, batch e iteraciones
  - b) Redes convolucionales
  - c) Redes recurrentes y neuronas LSTM
  - d) Redes RBF
- 9. Introducción a Deep Learning
  - a) IA, Machine learning y DL
  - b) Hiperparámetros y ANN
    - (i) Número de capas ocultas y nodos
    - (ii) Tasa de aprendizaje
    - (iii) Regularización
  - c) Redes neuronales profundas: vanishing y exploding gradients
- 10. Regresión no paramétrica y análisis discriminante
  - a) Regresión local
  - b) Splines
    - (i) Spline
    - (ii) Spline natural

- (iii) Spline suavizado
- c) Modelos aditivos generalizados
- d) Análisis discriminante

**Informes:** lumialearning@gmail.com