



# UTN.BA

UNIVERSIDAD TECNOLÓGICA NACIONAL  
FACULTAD REGIONAL BUENOS AIRES

## **TEMARIO Big Data - Programación Distribuida y Data Science Aplicada**

### Unidad 1: Conceptos generales de big data

Repaso de conceptos de big data.

Repaso de la plataforma Hadoop para soluciones distribuidas.

Repaso de conceptos de bases de datos NoSQL y su relación a las arquitecturas distribuidas.

Rol del profesional de big data en las organizaciones (tales como data scientist, data engineer, etc).

Historia de la programación distribuida.

### Unidad 2: Arquitectura distribuida

Introducción al concepto de cluster para aplicaciones relacionadas con problemáticas de big data.

Implementación de distribución y replicación de datos. Ventajas y desventajas.

Problemáticas y técnicas de escalabilidad en big data. Planificación a futuro.

Introducción a arquitectura lambda

### Unidad 3: Machine learning y algoritmos de data mining

Problemáticas de clasificación y algoritmos tales como Naive Bayes, Decision Tree, etc

Problemáticas de regresión y su diferencia con clasificación.

Problemáticas de clustering y algoritmos tales como k-means y variantes.

Reducción dimensional, usos y aplicaciones.

### Unidad 4: Lenguajes y Motores de procesamiento

Nociones generales de Python para ambientes distribuidos.

Primitivas fundamentales de Spark y Map reduce.

Procesamiento real time vs procesamiento batch en herramientas distribuidas.

### Unidad 5: Validación de resultados y testing

Técnicas de validación como (por ejemplo, cross validation, split validation).

Interpretación y visualización de resultados.

Técnicas de fabricación de variables artificiales.

