

## **SEMBLANZA DEL DR. MARIO ALEJANDRO MERCADO**

Mario Mercado es egresado de la Facultad de Economía de la UNAM y también es egresado de la carrera de Matemáticas de la Facultad de Ciencias de la UNAM. Realizó la Especialidad en Estadística Aplicada en el Instituto de Investigaciones en Matemáticas Aplicadas y en Sistemas. Realizó su Maestría en Economía en la UNAM. Realizó su Doctorado en el Instituto de Investigaciones Económicas de la UNAM en el tema de Sistemas Energéticos. Asimismo, cursó su internship en la Universidad de Oxford con el entonces director de la Saïd Business School, Dr. John Hoffmire; adicionalmente, cursó el Entrepreneurship Program en Cornell University obteniendo el tercer mejor plan de negocios de entre más de 30 participantes internacionales; también realizó estancia en el programa de Matemáticas Aplicadas en King Abdullah University of Science and Technology. En el ámbito laboral ha trabajado como investigador financiero para Banco de México; Científico de Datos para Nestlé en el área de IA; consultor de Ciencia de Datos para Wildfork; consultor en diferentes proyectos para Volkswagen, Instituto Nacional de Pediatría y el IMSS entre otros. También trabajó en el proyecto UNAM de modelación espacial para el COVID-19 y fue Investigador Asociado en Iniciativa Climática de México

## Propuesta de Materia: “Series de Tiempo y Programación”

**Área de Adscripción:** Teoría y Método.

**Instructor:** Mario Alejandro Mercado Mendoza.

**Horario tentativo:** Jueves 15:00-18:00 hrs

**Objetivo:** Que el alumno obtenga los conocimientos necesarios para desempeñarse como un profesional en el pronóstico mediante métodos de series de tiempo tanto tradicionales como la nueva generación basada en aprendizaje de máquina.

**Materiales:** Se busca que el alumno obtenga conocimiento en programación con Python que es de libre acceso.

### **Evaluación:**

Proyecto final escrito: 30%

Presentación oral: 20%

Tareas: 50%

### **Temario**

1. Introducción a la Programación y Entorno en Python
  - Fundamentos de Programación en Python
  - Variables, operadores, y estructuras de control
  - Funciones y módulos
  - Manejo de errores y debugging
2. Configuración del Entorno y Paquetes Esenciales
  - Introducción a Google Colab y Jupyter Notebooks
  - Instalación y uso de Darts y otros paquetes esenciales (pandas, numpy, matplotlib, etc.)
  - Introducción a las estructuras de datos (DataFrame, Series)
3. Preprocesamiento y Limpieza de Datos (ETL)
  - Fuentes de datos de series de tiempo (descarga desde APIs y archivos locales)
  - Extracción y limpieza de datos (revisión de valores faltantes, duplicados, tipos de datos)
  - Exploración inicial de series de tiempo: visualización básica y estadística descriptiva
4. Limpieza y Transformación de Series de Tiempo

- Identificación y manejo de valores faltantes (fillna, interpolación)
  - Detección y manejo de valores atípicos
  - Transformaciones de series de tiempo (log, diferencias)
5. Resamplio y Agregación
- Cambios de frecuencia de la serie (resamplio y agregación)
  - Submuestreo y sobremuestreo
6. Visualización y Análisis Exploratorio
- Visualización básica usando matplotlib y Darts
  - Gráficos avanzados: múltiples series, histogramas y boxplots
  - Exploración de estacionalidad y tendencias con gráficos
7. Análisis de Componentes de Series de Tiempo
- Descomposición de series: tendencia, estacionalidad y ruido
  - Identificación visual de patrones y estacionalidad
  - Introducción a los modelos ARIMA (Autoregressive Integrated Moving Average)
8. Modelos Exponenciales y Suavizamiento
- Modelos de suavizamiento exponencial (SES, Holt-Winters)
  - Comparación de modelos y selección del mejor ajuste
9. Evaluación de Modelos
- Métricas de evaluación: MAE, MSE, RMSE, MAPE ●  
Validación cruzada en series de tiempo
10. Modelado con Aprendizaje de Máquina (3 semanas)
- Diferencias entre enfoques clásicos y machine learning
  - Selección de variables predictoras en series de tiempo ● Preparación de datos para modelos de ML
11. Modelos de ML Clásicos: Random Forest y XGBoost
- Modelos de árboles de decisión en series de tiempo
  - Implementación en Darts y comparación con métodos estadísticos

## 12. Modelos de Redes Neuronales Recurrentes (RNN y LSTM)

- Introducción a redes neuronales recurrentes
- Modelos LSTM aplicados a series de tiempo
- Block RNN
- D-Linear
- N-Linear
- N Beats
- TCN Model
- Temporal Fusion TRansformer
- AutoML