

MODELAMIENTO PREDICTIVO CON SERIES DE TIEMPO Y DEEP LEARNING

JUSTIFICACIÓN

Una serie temporal es una colección de observaciones en orden cronológico. Pueden ser los precios diarios de cierre de las acciones, las cifras semanales de los inventarios, las ventas anuales o un sinnúmero de cosas más. Con demasiados proyectos que requieren análisis de tendencias y predicciones basadas en datos pasados, el análisis de series de tiempo es una herramienta importante en el arsenal de conocimientos de cualquier científico de datos moderno. Este curso dotará de herramientas y técnicas que permiten pensar con confianza en un problema y llegar a su solución con el uso de predicción con series temporales y deep learning.

RESULTADOS DE APRENDIZAJE

- Entender distintos conceptos importantes en series de tiempo, tales como: preprocesamiento avanzado y visualización de datos de series temporales mediante el remuestreo, agrupación y el cálculo de medias móviles; estacionariedad y pruebas de hipótesis estadísticas para detectar la estacionariedad en una serie temporal; y varios métodos de descomposición de series temporales para estacionar una serie temporal no estacionaria.
- Aplicar los modelos de suavizado exponencial utilizando el modelo de Holt-Winters de primer orden para capturar niveles, de segundo orden para suavizar niveles y tendencia, y el suavizado de orden superior, que capta el nivel, la tendencia y la estacionalidad dentro de un conjunto de datos de series temporales.
- Analizar los modelos autorregresivos para la predicción con series de tiempo. Entender en detalle las matemáticas detrás del modelo e implementación algorítmica para la *media móvil (MA)*, *autorregresiva (AR)* *media móvil autorregresiva (ARMA)* y *media móvil integrada autorregresiva (ARIMA)* para capturar diferentes niveles de perturbación en los datos de las series temporales durante la predicción de series temporales.
- Analizar algoritmos recientes de deep learning que pueden adaptarse directamente para desarrollar modelos de predicción para datos de series temporales. Describir diferentes redes neuronales, como la *Vanilla RNN*, *Gated Recurrent Units (GRN)* y *Long Short Term Memory (LSTM)* para desarrollar modelos de predicción de datos de series temporales. Entender las formulaciones matemáticas implicadas en el desarrollo de estas RNN.

METODOLOGÍA

- Trabajo participativo y colaborativo
- Aprendizaje basado en proyectos de aplicación, que den solución a diferentes tipos de problema que se presentan en los diferentes sectores económicos, usando los modelos predictivos estudiados implementados con Python y Tensorflow
- Proyecto 1: Preprocesamiento avanzado y visualización de datos de series temporales. Estudio de *estacionariedad y tendencias*.
- Proyecto 1: Aplicación de los modelos de suavización exponencial
- Proyecto 2: Aplicación de los modelos ARIMA
- Proyecto 3: Aplicación de los modelos de *Deep Learning*

DIRIGIDO A

Empresas de todos los sectores económicos del país que poseen datos históricos con los cuales desean realizar estudios predictivo relacionados con

- *Predicción económica*
- *Predicción de ventas*
- *Análisis presupuestario*
- *Análisis bursátil*
- *Proyecciones de rendimiento*
- *Control de procesos y calidad*
- *Estudios de inventario*
- *Proyecciones de carga de trabajo*
- *Estudios de utilidad*
- *Análisis del censo*

CONTENIDO

INTRODUCCIÓN A LAS SERIES TEMPORALES

- Diferentes tipos de datos
- Estructuras internas de las series temporales
- Modelos de análisis de series temporales
- Autocorrelación y autocorrelación parcial

ANÁLISIS EXPLORATORIO DE SERIES TEMPORALES

- Remuestreo de datos de series temporales
- Procesos estacionarios
- Descomposición de series temporales

MÉTODOS BASADOS EN EL SUAVIZADO EXPONENCIAL

- Introducción al suavizado de series temporales
- Suavizado exponencial de primer orden
- Suavizado exponencial de segundo orden
- Modelado con suavizado exponencial de orden superior

MODELOS AUTORREGRESIVOS

- Modelos autorregresivos
- Modelos de media móvil
- Construcción de conjuntos de datos con ARIMA
- Intervalo de confianza

DEEP LEARNING PARA LA PREDICCIÓN DE SERIES TEMPORALES

- Perceptrones multicapa
- Redes neuronales recurrente
- Redes neuronales convolucionales

EXPERTO FACILITADOR

LIHKI JOSE RUBIO ORTEGA

Licenciado en Matemáticas, Universidad del Atlántico, Magíster en Matemáticas, Universidad del Norte, Doctor en Ingeniería Matemática, Universidad de Concepción, Chile Experiencia académica: Universidad del Norte, Profesor TC. Publicaciones:

EBITDA index prediction using Exponential Smoothing and ARIMA model, Preprint, Graph Re-write using Ghost Nodes for Target Value Rebalancing, US Patent, Implicit-Explicit Methods for the Efficient Simulation of the Settling of Dispersions of Droplets and Colloidal Particles, Paper; Linearly implicit-explicit schemes for the equilibrium dispersive model of chromatography, Paper, Polynomial Viscosity Methods for Multispecies Kinematic Flow Models, Paper.

Experiencia empresarial relacionada con el área del programa:

TradeLayer

C++ y Blockchain Developer

Algorithmic Trading

Modelamiento predictivo con Series de Tiempo e Inteligencia Artificial

DURACIÓN DEL PROGRAMA

48 HORAS

MODALIDAD

Presencial