
TEMARIO

Diplomado de Análisis de series temporales

Descripción

En muchas áreas es común el seguimiento de información a través del tiempo. Por ejemplo, el seguimiento del precio de las acciones de una empresa, el número de defunciones por una enfermedad o la cantidad de producto vendido en una cadena de autoservicio. En estos casos se analizan las llamadas series temporales.

Un objetivo al analizar una serie temporal puede ser predecir su comportamiento a futuro. Esto puede abordarse a través del uso de modelos estadísticos clásicos que consisten en modelar el comportamiento a través de una descomposición de la serie en su tendencia y comportamientos estacionales. Otra opción es una modelación desde el enfoque de un tipo de proceso estocástico. Algunas veces también es posible contar con la información de otras series temporales, las cuales pueden usarse para obtener mejores predicciones, ya sea a través de un modelo de regresión o de una modelación multivariada. En el primer caso, la modelación podría tener un enfoque explicativo, para así determinar cómo algunas variables afectan a la serie de interés. Por otra parte, la presencia de volatilidad en nuestros datos puede hacer necesario la inclusión de modelos, los cuales, de forma individual o en combinación con cualquiera de los otros, pueden ayudarnos a obtener mejores resultados.

Además, pueden adaptarse algunas técnicas no supervisadas para encontrar grupos de series temporales similares, por ejemplo, series temporales de defunción en distintas localidades que son similares. Otro problema consiste en el análisis de datos que se siguen longitudinalmente, por ejemplo, en encuestas aplicadas a los mismos individuos a lo largo de los años. Finalmente, existen modelos basados en redes neuronales profundas que pueden usarse en este tipo de datos.

Todos estos temas son estudiados en este curso. La idea es que al terminar este, el alumno sea capaz de explorar series temporales usando el enfoque adecuado a su problema particular.

Duración: Curso de aproximadamente 34 horas

1. Introducción
 - a) Representación gráfica
 - b) Motivación y relación con regresión lineal simple
 - c) Tendencia y estacionalidad
2. Clustering y series temporales
 - a) Clustering jerárquico y no jerárquico

- b) Distancias, ligas y dendogramas
- c) Distancia DTW
- d) Obtención de clusters en series temporales y centroides
- e) Ejemplo
- 3. Métodos de pronóstico y suavizamiento para series de tiempo
 - a) Error Cuadrático Medio
 - b) Suavizamiento exponencial
 - c) Método para modelar tendencia: Holt o doble exponencial
 - d) Métodos que modelan tendencia y estacionalidad: Holt-Winters multiplicativo y aditivo.
 - e) Aplicaciones
- 4. Series estacionarias
 - a) Noción intuitiva de proceso estacionario
 - b) Autocovarianza, autocorrelación y autocorrelación parcial
 - c) Transformación de Box-Cox
 - d) Ruido blanco
 - e) Procesos tipo promedios móviles MA(p) y autoregresivos AR(q).
 - f) Descomposición de tendencia y estacionalidad.
 - (i) Promedios móviles y descomposición clásica
 - (ii) Uso de regresiones simples
 - (iii) Uso de diferencias.
 - g) Aplicaciones
- 5. Modelos ARMA(p,q)
 - a) Definición
 - b) Identificación de modelos.
 - c) Estimación de parámetros vía Yule-Walker y vía máxima verosimilitud.
 - d) Pruebas de raíces unitarias: Dickey-Fuller y Dickey-Fuller aumentado
 - e) Diagnósticos y selección de modelos
 - f) Pronósticos
 - g) Aplicaciones
- 6. Modelos SARIMA
 - a) Definición
 - b) Selección de parámetros asociados (p,d,q,P,D,Q)
 - c) Aplicaciones en R
- 7. Modelos de regresión con errores ARMA (modelos dinámicos)
 - a) Motivación y definición del modelo
 - b) Estimación por MCG y máxima verosimilitud
 - c) Aplicaciones
- 8. Series de tiempo multivariadas
 - a) Importancia, uso y ejemplos
 - b) Definiciones generales equivalentes al caso univariado: estacionariedad y ruido blanco

- c) Estimación de media y función de covarianza. Pruebas para checar independencia de series estacionarias bivariadas
 - d) Procesos AR multivariados (modelos VAR)
 - e) Estimación y pronóstico en modelos VAR
 - f) Aplicaciones
9. Modelos ARCH y GARCH usados bajo la presencia de heteroscedasticidad
- a) Relación con modelos ARMA, identificación del modelo GARCH adecuado y planteamiento de modelo de regresión con errores ARMA cuyo ruido blanco asociado tiene un modelo ARCH o GARCH
 - b) Estimación de los modelos GARCH: Máxima verosimilitud y estimación iterativa
 - c) Pronósticos
 - d) Aplicaciones
10. Algunos modelos para datos longitudinales o de panel
- a) Formas de manejar esta clase de datos mediante regresiones lineales
 - b) Modelos lineales mixtos (MLM) aplicados en datos longitudinales
 - c) Casos particulares de MLM: Modelos de efectos entre individuos (between), de efectos fijos (within) y aleatorios
 - d) Modelos de efectos aleatorios con matrices de varianza y covarianza para el error dentro de cada individuo correspondientes a modelos tipo ARMA
 - e) Ejemplos y aplicaciones
11. Redes neuronales recurrentes (RNN)
- a) Series temporales y secuencias
 - b) Definición y redes desdobladas
 - c) Limitaciones de RNN
 - d) LSTM networks

Informes: lumialearning@gmail.com