



centro adscrito a:



UNIVERSITAT POLITÈCNICA
DE CATALUNYA
BARCELONATECH

GUIA DOCENTE DE

Análisis de Datos

Temporales

2026-27

DATOS GENERALES

Número:	Análisis de Datos Temporales
Código:	801362 (BUSINESSTECH)
Curso:	2026-27
Titulación:	Grado en Empresa, Innovación y Tecnología
Nº de créditos (ECTS):	6
Ubicación en el plan de estudios:	3º. Curso, 2º. cuatrimestre
Departamento:	Métodos Cuantitativos
Responsable departamento:	Dr. Iván Romero
Fecha de la última revisión:	Julio 2026
Profesor Responsable:	Dr. Iván Romero

1. DESCRIPCIÓN GENERAL

La asignatura Análisis de Datos Temporales se enmarca en el tercer curso de la mención de Analítica de Negocio del Grado en Empresa, Innovación y Tecnología. Su propósito es capacitar al estudiante para comprender, modelizar y predecir fenómenos económicos y empresariales que evolucionan a lo largo del tiempo, mediante el uso de técnicas estadísticas y computacionales avanzadas.

El análisis de series temporales constituye una disciplina fundamental en el ámbito de la analítica de negocio, dado que la mayoría de los datos empresariales —ventas, demanda, precios, indicadores financieros o métricas operativas— se registran y analizan en función del tiempo. Esta asignatura proporciona al estudiante las herramientas necesarias para extraer patrones, identificar tendencias, modelizar comportamientos y generar predicciones que apoyen la toma de decisiones informadas en contextos empresariales reales.

La asignatura se estructura en cinco bloques temáticos. En el primer bloque se establecen los conceptos fundamentales de las series temporales: su definición, tipología, componentes y las técnicas iniciales de exploración y visualización con Python. El segundo bloque aborda la estadística aplicada a series temporales, con especial atención a la estacionariedad, la autocorrelación y las herramientas de diagnóstico. En el tercer bloque se estudian los modelos clásicos de predicción, incluyendo estrategias de validación, descomposición, medias móviles y suavizado exponencial. El cuarto bloque introduce los modelos ARIMA y sus variantes estacionales y con variables exógenas, así como el modelo Prophet. El quinto y último bloque incorpora el enfoque del machine learning aplicado a la

predicción de series temporales, cubriendo algoritmos de ensemble y redes neuronales recurrentes.

A lo largo de la asignatura, el estudiante trabajará con herramientas de programación — principalmente Python— para el procesamiento, modelización y visualización de datos temporales, consolidando así competencias técnicas directamente transferibles al entorno profesional.

2. OBJETIVOS

Al finalizar el curso el estudiante será capaz de:

- Comprender la naturaleza específica de los datos temporales y diferenciarlos de otros tipos de datos estadísticos.
- Identificar y describir las principales componentes de una serie temporal: tendencia, estacionalidad, ciclo y residuo.
- Aplicar técnicas estadísticas para el análisis de la estacionariedad y la autocorrelación de series temporales.
- Implementar modelos clásicos de predicción como la descomposición, el suavizado exponencial y las medias móviles.
- Construir y validar modelos ARIMA, SARIMA y otras variantes para la predicción de series temporales.
- Aplicar algoritmos de machine learning a problemas de predicción temporal, evaluando su rendimiento con métricas adecuadas.
- Utilizar Python como herramienta principal para la implementación, visualización y evaluación de modelos de series temporales.
- Interpretar los resultados de los modelos en contextos empresariales reales y comunicar las predicciones de manera efectiva.
- Evaluar críticamente la idoneidad de cada modelo en función de las características de los datos y los objetivos del análisis.

3. RESULTADOS DEL APRENDIZAJE

- Identificar y caracterizar una serie temporal, reconociendo sus componentes y comprendiendo sus implicaciones analíticas en un contexto empresarial.

- Aplicar pruebas estadísticas de estacionariedad y analizar las funciones de autocorrelación (ACF) y autocorrelación parcial (PACF) para diagnosticar el comportamiento de una serie temporal.
- Seleccionar, estimar y validar modelos clásicos de predicción (medias móviles, suavizado exponencial, descomposición) justificando la elección en función de las propiedades de los datos.
- Identificar el orden de un modelo ARIMA/SARIMA a partir del análisis de los correlogramas, estimar sus parámetros e interpretar los resultados obtenidos.
- Implementar y comparar modelos de predicción basados en machine learning, aplicando técnicas de validación cruzada temporal y métricas de evaluación como MAE, RMSE y MAPE.
- Comunicar de forma clara y estructurada los resultados del análisis de series temporales, adaptando el discurso técnico a perfiles no especializados.

4. CONTENIDOS

TEMA 1. EL SISTEMA GENERADOR EN SERIES TEMPORALES

Resultados específicos del aprendizaje

El estudiante después de estudiar el tema y realizar los ejercicios, será capaz de:

- Comprender el concepto de sistema generador como mecanismo subyacente — determinista, estocástico o mixto— que produce los valores observados de una serie temporal.
- Diferenciar entre sistemas deterministas, estocásticos y mixtos, identificando ejemplos representativos en contextos empresariales.
- Comprender el problema de identificación del sistema generador: por qué distintos sistemas pueden producir series estadísticamente indistinguibles.
- Interpretar de forma conceptual los invariantes que caracterizan un sistema generador (memoria, horizonte de predictibilidad, complejidad), sin necesidad de su formalización matemática avanzada.
- Relacionar cada bloque temático posterior de la asignatura con el aspecto del sistema generador que pretende capturar.

Contenido

- 1.1. El sistema generador como mecanismo subyacente a la serie observada.
- 1.2. Taxonomía de sistemas generadores: deterministas, estocásticos y mixtos.

- 1.3. El problema de identificación: la serie como proyección observable del sistema.
- 1.4. Memoria del sistema y persistencia: nociones introductorias (exponente de Hurst).
- 1.5. Horizonte de predictibilidad: límites estructurales de cualquier modelo.
- 1.6. Heterocedasticidad: cuando lo impredecible es la volatilidad y no la media.
- 1.7. El modelo como aproximación al sistema generador: mapa conceptual de la asignatura.

TEMA 2. CONCEPTOS FUNDAMENTALES DE SERIES TEMPORALES

Resultados específicos del aprendizaje

El estudiante después de estudiar el tema y realizar los ejercicios, será capaz de:

- Definir qué es una serie temporal y distinguirla de otros tipos de datos estadísticos.
- Identificar fuentes y estrategias de búsqueda de datos de series temporales.
- Aplicar técnicas de ingeniería de características temporales: lags, ventanas deslizantes y variables temporales.
- Realizar un análisis exploratorio y de visualización de series temporales en Python.
- Identificar y describir las componentes de una serie temporal: tendencia, estacionalidad, ciclo y residuo.

Contenido

- 2.1. Definición y tipos de series temporales.
- 2.2. Búsqueda de datos de series temporales.
- 2.3. Ingeniería de características para series temporales: lags, ventanas deslizantes y variables temporales.
- 2.4. Análisis exploratorio y visualización de series temporales en Python.
- 2.5. Componentes de una serie temporal: tendencia, estacionalidad, ciclo y residuo.
- 2.6. Análisis exploratorio y visualización de series temporales en Python.

TEMA 3. ESTADÍSTICA APLICADA A SERIES TEMPORALES

Resultados específicos del aprendizaje

El estudiante después de estudiar el tema y realizar los ejercicios, será capaz de:

- Comprender y contrastar la estacionariedad de una serie temporal mediante pruebas estadísticas (ADF, KPSS).
- Calcular e interpretar las funciones de autocorrelación (ACF) y autocorrelación parcial (PACF).
- Interpretar correlogramas como herramienta de diagnóstico de un modelo.

- Aplicar transformaciones para la estabilización de la varianza y la media de una serie temporal.

Contenido

- 3.1. Estacionariedad: concepto, tipos y pruebas estadísticas (ADF, KPSS).
- 3.2. Función de autocorrelación (ACF) y autocorrelación parcial (PACF).
- 3.3. Correlogramas: interpretación y uso diagnóstico.
- 3.4. Transformaciones para la estabilización de la varianza y la media.

TEMA 4. MODELOS CLÁSICOS DE PREDICCIÓN

Resultados específicos del aprendizaje

El estudiante después de estudiar el tema y realizar los ejercicios, será capaz de:

- Aplicar estrategias de validación cruzada temporal: walk-forward y blocked cross-validation.
- Evaluar la precisión de las predicciones mediante métricas estándar (MAE, RMSE, MAPE).
- Justificar las limitaciones de la regresión lineal como estrategia de predicción temporal.
- Aplicar el método de descomposición aditiva y multiplicativa para separar las componentes de una serie temporal.
- Implementar modelos de medias móviles simples y ponderadas.
- Implementar modelos de suavizado exponencial simple, doble (Holt) y triple (Holt-Winters).

Contenido

- 4.1. Estrategias de predicción: validación cruzada temporal (walk-forward y blocked cross-validation).
- 4.2. Métricas de evaluación: MAE, RMSE, MAPE.
- 4.3. Limitaciones de la regresión lineal en la predicción de series temporales.
- 4.4. Descomposición de series temporales: métodos aditivo y multiplicativo.
- 4.5. Medias móviles simples y ponderadas.
- 4.6. Suavizado exponencial simple, doble (Holt) y triple (Holt-Winters).

TEMA 5. MODELOS ARIMA Y VARIANTES

Resultados específicos del aprendizaje

El estudiante después de estudiar el tema y realizar los ejercicios, será capaz de:

- Comprender los modelos AR, MA y ARMA, sus propiedades, ventajas y desventajas frente a otros enfoques.
- Aplicar el proceso de identificación, estimación y validación de modelos ARIMA.
- Extender el modelo ARIMA a su variante estacional (SARIMA) para series con estacionalidad.
- Incorporar variables exógenas mediante modelos ARIMAX/SARIMAX.
- Aplicar criterios de selección de modelos (AIC, BIC) y analizar los residuos del modelo.
- Implementar el modelo Prophet (Meta) para predicción con estacionalidades múltiples.

Contenido

- 5.1. Modelos AR, MA y ARMA: definición y propiedades. Ventajas y desventajas de los métodos estadísticos.
- 5.2. Proceso de identificación, estimación y validación de modelos ARIMA.
- 5.3. Modelos SARIMA para series con estacionalidad.
- 5.4. Modelos ARIMAX/SARIMAX con variables exógenas.
- 5.5. Criterios de selección: AIC, BIC y análisis de residuos.
- 5.6. Prophet (Meta) para predicción con estacionalidades múltiples.

TEMA 6. PREDICCIÓN CON MACHINE LEARNING

Resultados específicos del aprendizaje

El estudiante después de estudiar el tema y realizar los ejercicios, será capaz de:

- Implementar y comparar modelos de ensemble: Random Forest y Gradient Boosting (XGBoost, LightGBM).
- Implementar redes neuronales recurrentes (LSTM y GRU) para la predicción de series temporales.
- Evaluar las ventajas y desventajas del deep learning frente a métodos estadísticos clásicos en series temporales.

Contenido

- 6.1. Modelos de ensemble: Random Forest y Gradient Boosting (XGBoost, LightGBM).
- 6.2. Redes neuronales recurrentes: LSTM y GRU.
- 6.3. Ventajas y desventajas del deep learning para series temporales.

5. METODOLOGÍA DE ENSEÑANZA Y APRENDIZAJE

La asignatura Análisis de Datos Temporales, situada en el tercer curso de la mención de Analítica de Negocio, capacita al estudiante para comprender, modelizar y predecir fenómenos económicos y empresariales que evolucionan a lo largo del tiempo. Su enfoque parte de la comprensión profunda de los mecanismos que generan los datos temporales (el sistema generador como marco conceptual de toda la asignatura) y progresa hacia la implementación práctica de modelos predictivos en Python sobre datos empresariales reales. La modalidad semipresencial combina sesiones presenciales de trabajo intensivo con sesiones asíncrona que permiten consolidar el aprendizaje autónomo.

La modalidad se articula en 6 sesiones presenciales en aula física, 6 sesiones asíncrona asíncronas (o síncronas cuando así lo determine el profesorado) y 1 sesión de examen final presencial, sumando un total de 13 sesiones.

Sesiones presenciales (6 sesiones):

Cada sesión combina una parte expositiva y una parte práctica de un mínimo de hora y media. En la parte teórica, el profesorado introduce los conceptos, modelos y marcos interpretativos del bloque temático correspondiente apoyándose en el material docente y los notebooks del campus virtual. Las sesiones parten del sistema generador como mecanismo subyacente a cualquier serie observada y progresan hacia la implementación de modelos clásicos, ARIMA y de machine learning. Se fomentará la participación activa mediante la interpretación conjunta de correlogramas, la discusión crítica sobre los límites de cada modelo y el análisis de casos empresariales reales. En la parte práctica, el estudiante (de forma individual o en grupo) implementará modelos y analizará datos temporales en Python. Al menos 4 de las 6 sesiones presenciales incluirán obligatoriamente esta parte práctica con actividad evaluable. El orden de ambas partes podrá variar según criterio pedagógico del profesorado, y no se avisará con antelación del momento exacto de la actividad práctica, con el fin de favorecer la asistencia completa a cada sesión.

Sesiones asíncronas (6 sesiones):

Las sesiones asíncronas se articularán mediante materiales docentes, notebooks de Python estructurados por tema y recursos publicados en el campus virtual, preparados específicamente para los contenidos de la asignatura. Al menos 4 de estas 6 sesiones incluirán una parte práctica de un mínimo de hora y media que el estudiante podrá

desarrollar de forma asíncrona, o de forma síncrona si así lo decide el profesorado. Al menos 4 sesiones asíncrona contarán con algún tipo de actividad evaluable.

Las principales actividades que se realizarán a lo largo de las sesiones presenciales y asíncrona son:

- Estudio y preparación de los contenidos a partir del material docente y notebooks del campus virtual.
- Clases expositivas (presenciales u asíncrona) sobre el sistema generador, series temporales, modelos estadísticos y técnicas de machine learning aplicadas a la predicción.
- Análisis exploratorio y visualización de series temporales en Python, incluyendo ingeniería de características (lags, ventanas deslizantes, variables temporales).
- Diagnóstico estadístico: pruebas de estacionariedad (ADF, KPSS), cálculo e interpretación de ACF/PACF y correlogramas.
- Implementación y comparación de modelos clásicos (descomposición, medias móviles, Holt-Winters) y modelos ARIMA/SARIMA/Prophet con evaluación mediante MAE, RMSE y MAPE.
- Implementación de modelos de machine learning para predicción temporal (Random Forest, XGBoost, LightGBM, LSTM/GRU) con validación cruzada temporal.
- Entregas prácticas por tema, con elaboración autónoma previa y resolución o exposición obligatoria en sesión.

Se proporcionarán notebooks de Python estructurados por tema, disponibles en el campus virtual, para consolidar el aprendizaje autónomo fuera de las sesiones. La progresión técnica irá desde la conceptualización del sistema generador y el análisis exploratorio hasta los modelos de deep learning aplicados a series temporales empresariales.

6. EVALUACIÓN

Las tareas y actividades evaluativas se ajustarán al contenido del material docente expuesto en clase y facilidad en el Campus para comprobar que el alumnado los ha consolidado. De acuerdo con el Plan Bolonia, el modelo premia el esfuerzo constante y continuado del estudiantado. Un 40% de la nota se obtiene de la evaluación continua y el 60% restante, del examen final presencial. El examen final tiene dos convocatorias.

La nota final de la asignatura (NF) se calculará a partir de la siguiente fórmula:

- **NF = Nota Examen Final x 60% + Nota Evaluación Continuada x 40%**
- Nota mínima del examen final para calcular la NF será de 40 puntos sobre 100.
- La asignatura queda aprobada con una NF igual o superior a 50 puntos sobre 100.

Tipo de actividad	Descripción	% Evaluación continua	
Entregas por tema:			40%
Ex. Tema 1	Entrega por Classlife	16%	
Ex. Tema 2	Entrega por Classlife	16%	
Ex. Tema 3	Entrega por Classlife	16%	
Ex. Tema 4	Entrega por Classlife	16%	
Ex. Tema 5	Entrega por Classlife	16%	
Ex. Tema 6	Entrega por Classlife	20%	
Actividades en sesión	Ejercicios, análisis de casos, pruebas cortas u otras actividades realizadas durante la parte práctica de las sesiones. Mínimo 6 tendrán evaluación numérica.	(integradas en el 30%)	
Examen final			60%
	Examen final	100%	

7. BIBLIOGRAFÍA

Box, G.E.P., Jenkins, G.M., Reinsel, G.C. y Ljung, G.M. (2015). Time Series Analysis: Forecasting and Control. 5ª ed. Hoboken, Estados Unidos: Wiley.

Brockwell, P.J. y Davis, R.A. (2016). Introduction to Time Series and Forecasting. 3ª ed. Nueva York, Estados Unidos: Springer.

Nielsen, A. (2019). Practical Time Series Analysis. Sebastopol, Estados Unidos: O'Reilly.

Peixeiro, M. (2022). Time Series Forecasting in Python. Shelter Island, Estados Unidos: Manning Publications.