



---

## SERIES TEMPORALES

Año 2019

Carrera: **Maestría en Inteligencia de Datos orientada a Big Data**

Carga Horaria: 64 Hs

Profesores a Cargo:

**Dr. Aurelio Fernández Bariviera,  
Dra. Laura Lanzarini**

---

### OBJETIVO

Una serie de tiempo es una colección de observaciones hechas secuencialmente en el tiempo. Su análisis es útil en una variedad de campos, que van desde la economía a la ingeniería. Este módulo se centra inicialmente en varios modelos de series de tiempo, incluyendo algunos desarrollos recientes, y proporciona herramientas estadísticas modernas para su análisis. La segunda parte del módulo cubre ampliamente los métodos de simulación. Estos métodos se están convirtiendo en herramientas cada vez más importantes, ya que los modelos de simulación pueden ser fácilmente diseñados y ejecutados en computadoras.

El primer objetivo es dotar a los estudiantes de herramientas actualizadas para operar con series temporales. Al finalizar el curso será capaz de seleccionar los modelos adecuados para el tratamiento y la solución de problemas concretos. Se desarrollarán modelos basados en regresión y distintos tipos de redes neuronales así como modelos basados en agrupamiento (clustering).

### MODALIDAD DE EVALUACION

La evaluación consistirá en una serie de ejercicios que se realizarán durante el desarrollo del curso y en un examen final. Los ejercicios serán de modalidad de hacer en casa y consistirán en aplicaciones de temas estudiados, utilizando software apropiado. El examen final consistirá en temas teóricos de la asignatura propiciando la investigación y profundización individual de los temas vistos en el curso. Los ejercicios tendrán un peso del 40% de la nota y el examen final del 60% de la nota definitiva del módulo.



## PROGRAMA

1. Introducción a las Series Temporales. Tipos de datos temporales. Estructura interna de la serie de tiempo: estacionalidad, cambios cíclicos, variaciones inesperadas.
2. Modelos lineales estacionarios: Caracterización y propiedades. Modelo de descomposición de Wold. Procesos ARMA. Función de autocorrelación parcial. Identificación de procesos ARMA
3. Modelos lineales estacionarios: estimación e inferencia. Estimación: el método de máxima verosimilitud. Inferencia de los parámetros de los modelos ARMA
4. Selección de modelos. Metodología de Box-Jenkins. Criterios de información: AIC, BIC.
5. Proyección de series temporales. Pronósticos basados en modelos ARMA y ARIMA. Predicción y su interpretación económica. Comparación de pronósticos con procesos estacionarios en tendencia y procesos con raíces unitarias.
6. Modelos lineales no estacionarios: el caso de un AR con raíz unitaria. Tendencia determinística versus tendencia estocástica. Procesos con raíces unitarias: tests y estimación.
7. Modelos con memoria de largo plazo aplicables a series temporales. Definición. Modelos ARFIMA. Modelización, estimación e inferencia de la memoria de largo plazo. Estimación del exponente de Hurst. Elementos de teoría de la información. Entropía de las permutaciones y complejidad estadística. El Plano de Complejidad-Entropía para la discriminación de procesos estocásticos y caóticos.
8. Redes neuronales para Series Temporales. Multiperceptrón. Redes Recurrentes con memoria a corto largo plazo. Redes Neuronales profundas.
9. Técnicas de agrupamiento aplicables al procesamiento de series temporales

## BIBLIOGRAFIA

Avishek Pal, PKS Prakash. Practical Time Series Analysis. Packt Publishing Ltd. 2017.  
ISBN 978-1-78829-022-7

Lewis. Deep Time Series Forecasting with Python: An Intuitive Introduction to Deep Learning for Applied Time Series Modeling. ISBN 978-1540809087. 2016



Lewis. *Neural Networks for Time Series Forecasting with R: An Intuitive Step by Step Blueprint for Beginners*. ISBN 978-1540809087. 2016

Baddeley, M. C.; Barrowclough, D.V. (2009). *Running Regressions. A Practical Guide to Quantitative Research in Economics, Finance and Development Studies*. New York: University of Cambridge

Cover, T. M., & Thomas, J. A. (2006). *Elements of information theory* (2nd ed.). New York: John Wiley.

Mills. T.C.; Markellos, R.N. *The Econometric Modelling of Financial Time Series 3rd Edition*. New York: Cambridge University Press

Olivares, F., Plastino, A., & Rosso, O. A. (2012). Contrasting chaos with noise via local versus global information quantifiers. *Physics Letters A*, 376(19), 1577–1583.  
<http://doi.org/10.1016/j.physleta.2012.03.039>

Rosso, O. A., Larrondo, H. A., Martin, M. T., Plastino, A., & Fuentes, M. A. (2007). Distinguishing Noise from Chaos. *Phys.Rev.Lett.*, 99(15), 154102.  
<http://doi.org/10.1103/PhysRevLett.99.154102>