

# Análisis de Series de Tiempo

Minicurso práctico en Python

II Escuela de Verano de Modelación para la Sostenibilidad  
1 a 5 de agosto de 2016

Sede: Centro de Ciencias de la Complejidad (C3), UNAM



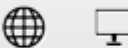



Juan C. Toledo (C3)  
`juan.toledo@nucleares.unam.mx`

# Resumen

- Preliminares
  - Instalación de Python + librerías
  - Mini tutorial de Python
- Día 1:
  - Series de tiempo: descripción general
  - Noción de estacionariedad
  - Modelación de series de tiempo:
    - Modelos Autoregresivos (AR)
    - Modelos de Media Móvil (MA)
    - Modelos combinados (ARMA)
- Día 2: análisis de Fourier y métodos de análisis avanzados

# Preliminares

- En este curso usaremos Python 3 + librerías
- ¿Por qué Python?
  - Lenguaje de programación general
  - Sintaxis intuitiva, ligera y muy poderosa
  - Muy popular en muchos contextos (inc. ciencia, big data)

Language Rank	Types	Spectrum Ranking
1. C		100.0
2. Java		98.1
3. Python		98.0
4. C++		95.9
5. R		87.9
6. C#		86.7



(2016 IEEE Spectrum  
Language Rankings)




# Librerías

Python es lenguaje general → no incluye herramientas específicas para cómputo científico o análisis de datos :(

Pero existe un gran ecosistema de librerías para esto:

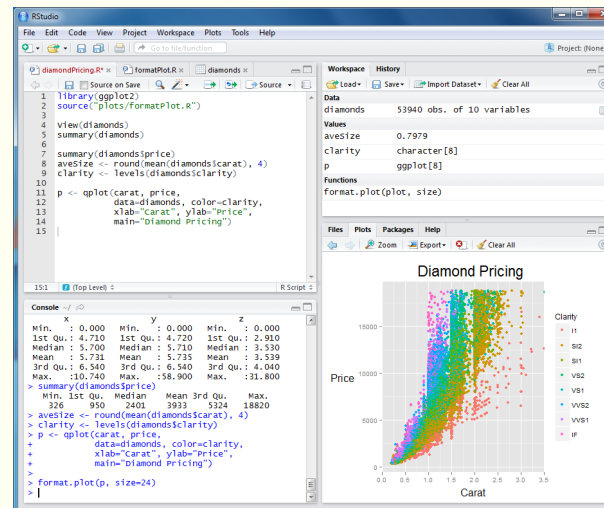
- **numpy**: cómputo numérico, álgebra, matrices <http://www.numpy.org/>
- **scipy**: herramientas para cómputo científico <https://www.scipy.org/>
- **matplotlib**: gráficas de calidad publicación <http://matplotlib.org/>
- **pandas**: análisis de datos <http://pandas.pydata.org/>
- **scikitlearn**: herramientas de machine learning <http://scikit-learn.org/>
- **networkx**: análisis de redes <https://networkx.github.io/>
- etc ...

Todas son librerías **open source** y **gratuitas**.



# Alternativa: R

- Creciente popularidad
- Entorno 100% integrado dedicado a análisis de datos, cómputo científico y estadística
- Muchas referencias con ejemplos para R
- Sugerencia R Studio: <https://www.rstudio.com/home/>



# Volviendo a Python: Anaconda

- Es una plataforma integrada para ciencia de datos
- Varios entornos gráficos de programación
- Integra numpy, scipy, matplotlib, jupyter, etc.
- Disponible para Windows, Mac y Linux
- Incluye instalación de Python



# Instalación de Anaconda

1) Descargar Anaconda: <https://www.continuum.io/downloads>

Esto incluye todo lo necesario.

ó

2) Descargar miniconda: <http://conda.pydata.org/miniconda.html>

Versión minimalista de Anaconda + instalar librerías requeridas desde la terminal usando el comando 'conda':

```
conda install numpy matplotlib pandas statsmodels jupyter
```

En cualquier caso, seleccionar **Python 3.5** y **64 bits**

3) Descargar el material del curso en:

<http://meithan.net/curso/>

y descomprimirlo en un lugar cómodo

# Jupyter Notebook

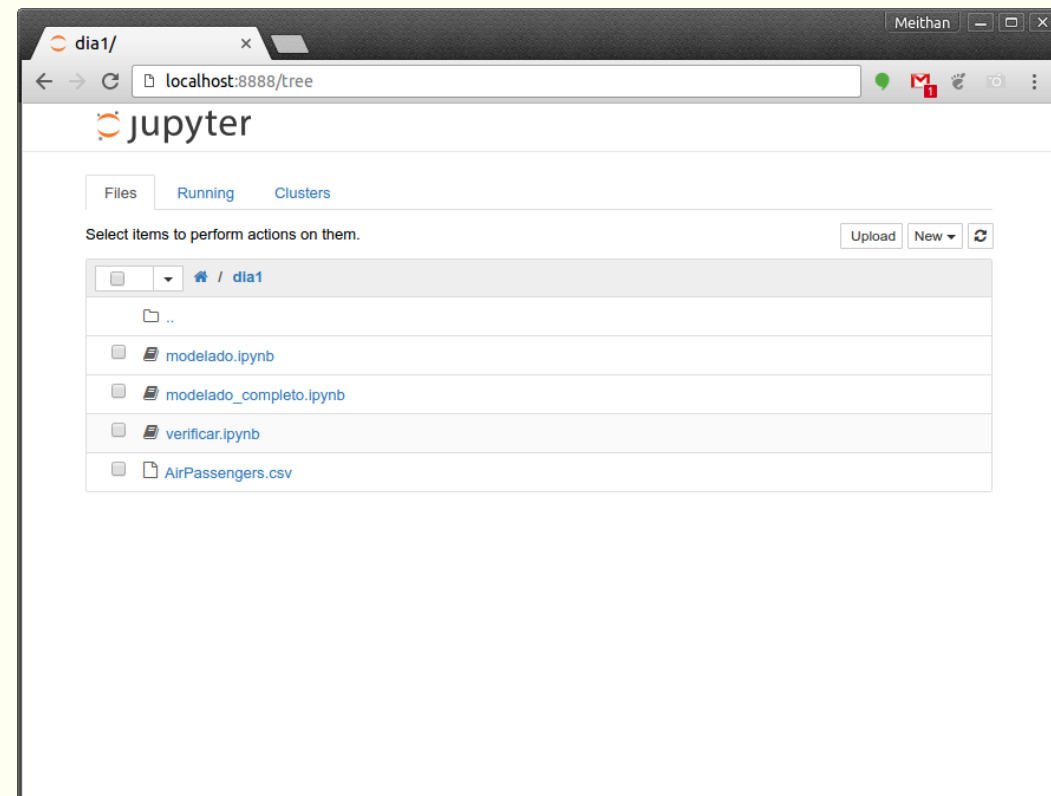
Usaremos el **Jupyter Notebook**, un intérprete interactivo multiplataforma que corre en el browser.

Para iniciarlo:

- 1) Abrir una terminal  
(Windows: WIN+R y luego cmd; Mac y Linux: lanzar terminal)
- 2) Navegar al directorio de trabajo **dia1**
- 3) Escribir **jupyter notebook** y dar ENTER

El Notebook se abrirá automáticamente en el browser predeterminado.

Si se cierra, se puede volver a abrir navegando a **localhost:8888**



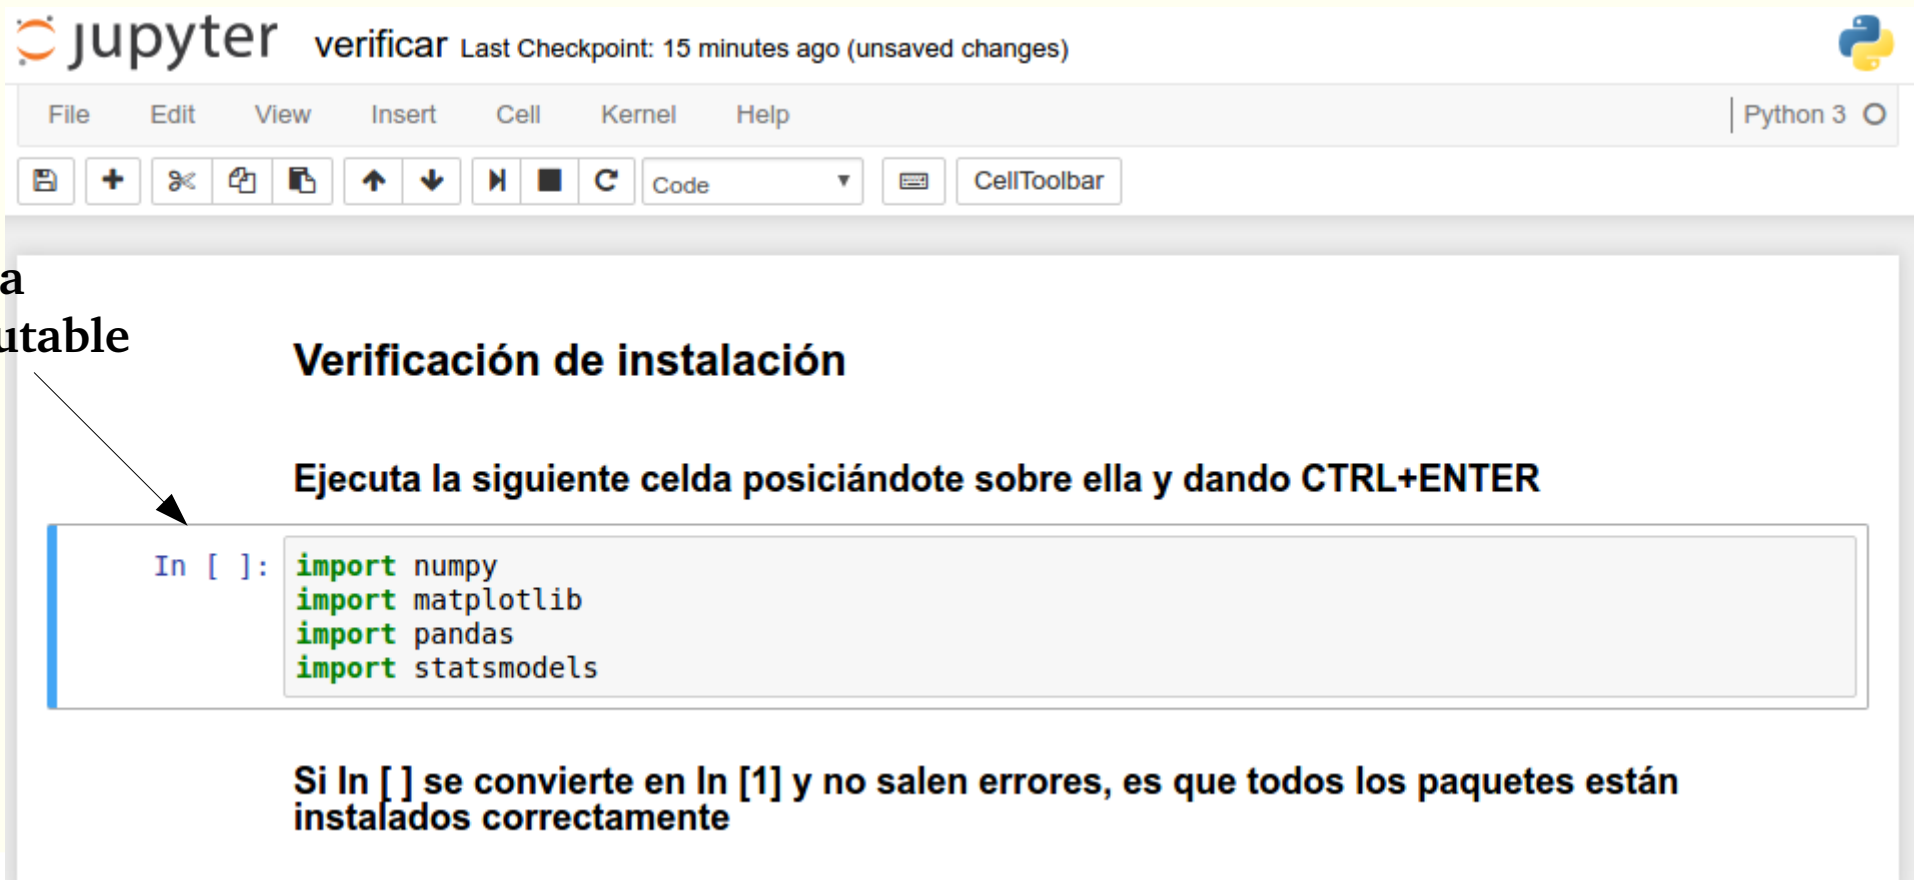


# Verificar instalación

Verifiquemos que los paquetes que necesitaremos se instalaron correctamente

- Abrir el notebook `verificar.ipynb`

Celda  
Ejecutable



The screenshot shows a Jupyter Notebook window titled "verificar" with a "Last Checkpoint: 15 minutes ago (unsaved changes)" status. The interface includes a menu bar (File, Edit, View, Insert, Cell, Kernel, Help) and a toolbar with icons for file operations and execution. The main content area displays a code cell with the following text:

```
In [ ]: import numpy
import matplotlib
import pandas
import statsmodels
```

Below the code cell, there is a bold instruction: "Si In [ ] se convierte en In [1] y no salen errores, es que todos los paquetes están instalados correctamente".

# Mini tutorial de Python3

- Cerrar el notebook anterior haciendo clic en **File** → **Close and halt**
- Abrir ahora el notebook **tutorial\_python.ipynb**

Más información:

Documentación oficial de Python: <https://docs.python.org>

Libro gratuito “Python para todos”: <http://mundogeek.net/tutorial-python/>

# Introducción a las series de tiempo

→ **Serie de tiempo:** secuencia de datos experimentales ordenados en el tiempo

**Ubicuas:** casi todos los sistemas naturales y artificiales están asociados a señales que cambian con el tiempo

Tasa de cambio USD/MXN,  
últimos diez años →  
(<http://www.xe.com/>)




# Introducción a las series de tiempo

¿En qué se **diferencian** de otros conjuntos de datos?

→ El ordenamiento temporal da cabida a que exista **correlación** entre valores sucesivos: el valor presente puede depender de los valores pasados.

Número de manchas solares desde 1750




# Introducción a las series de tiempo

El **análisis** de las series de tiempo ofrece entonces prospectos interesantes:

- Entender los **mecanismos causales** subyacentes detrás de un fenómeno:

“¿Por qué está aumentando la temperatura promedio global?”




# Introducción a las series de tiempo

- Determinar las **relaciones causales** entre dos o más fenómenos:

“¿Qué impacto tiene el programa Hoy No Circula sobre la contaminación atmosférica en la CDMX?”


Partículas atmosféricas de 2.5 micras en Coyoacán, 2016



# Introducción a las series de tiempo

- Modelar las series nos da una forma de **predecir** el comportamiento **futuro** del fenómeno asociado:

“¿Cómo crecerá la población mundial de aquí al 2050?”



Modelos y proyecciones  
poblacionales, ONU, 2007

# Análisis Exploratorio

Antes de adentrarse en el análisis matemático ...

**¡Graficar** la serie de tiempo!

Esto es crucial antes de cualquier tipo de análisis, pues nos permite:

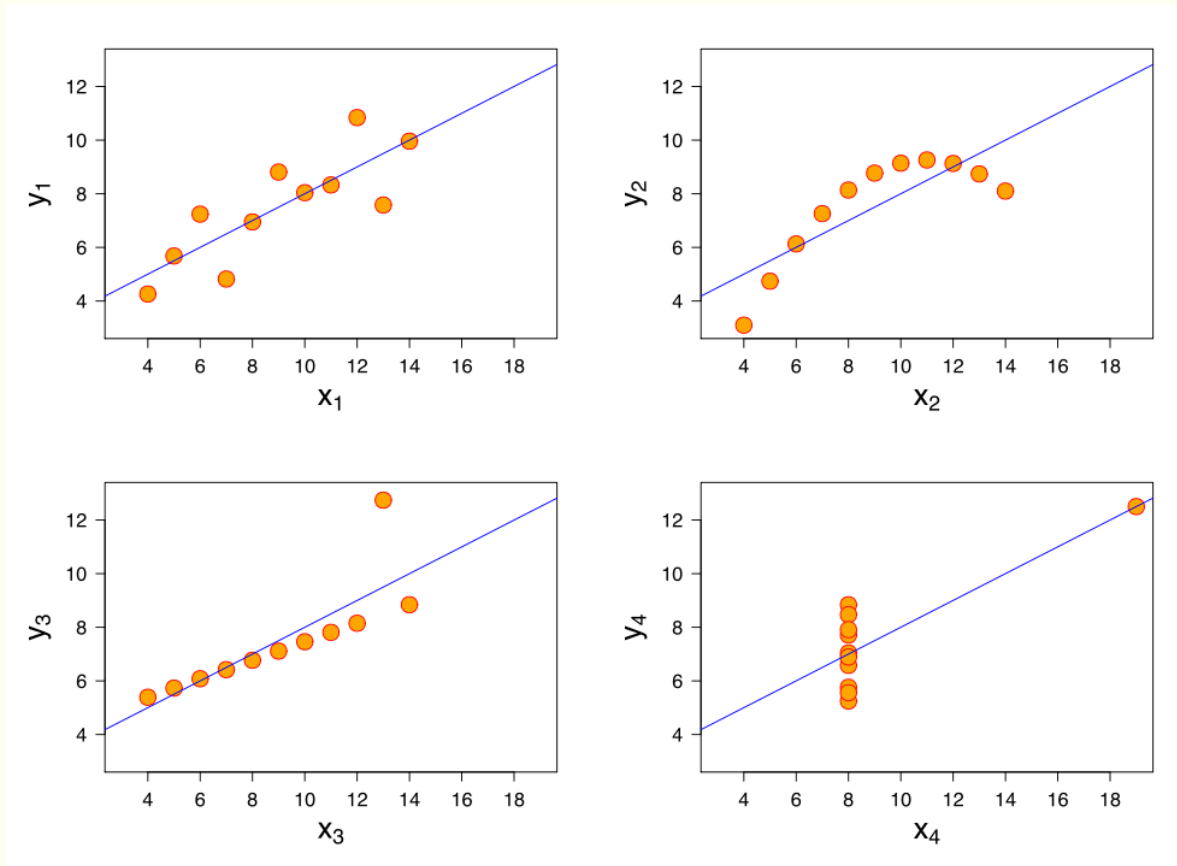
- Descubrir rápidamente las propiedades generales de la serie
- Determinar el tipo de preguntas que podemos contestar
- Seleccionar adecuadamente qué herramientas emplear para modelarla

Ejercicio: abrir **coyoacan.ipynb**



# Análisis Exploratorio

La importancia de graficar ...




Misma ...

Media (x y y)  
Varianza (x y y)  
Correlación  
Ajuste lineal

Anscombe's Quartet

# Componentes de una serie de tiempo

$$X_t = T_t + S_t + C_t + R_t$$




## Tendencia

Incremento o decremento a largo plazo en los datos.

No tiene que ser lineal, y puede cambiar de dirección (aunque lo hace lentamente)

# Componentes de una serie de tiempo

$$X_t = T_t + S_t + C_t + R_t$$



## Tendencia

Incremento o decremento a largo plazo en los datos.

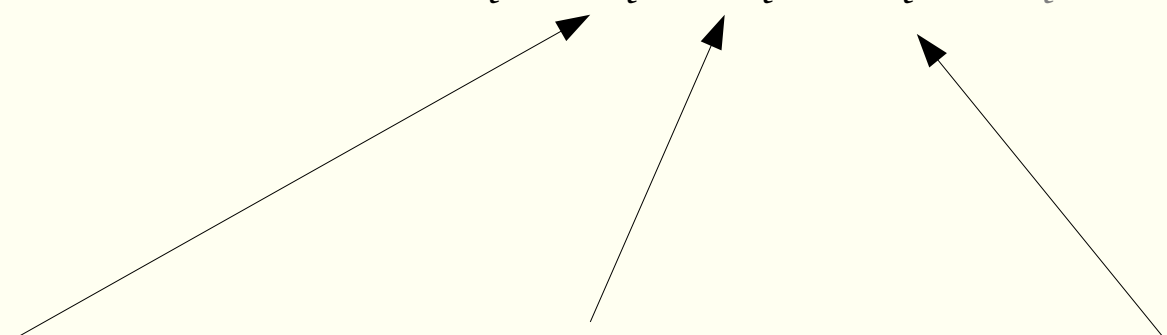
No tiene que ser lineal, y puede cambiar de dirección (aunque lo hace lentamente)

## Estacionalidad

Patrones repetitivos con un periodo definido.

Usualmente podemos asociar esta repetibilidad a un fenómeno (e.g. las estaciones del año)

# Componentes de una serie de tiempo

$$X_t = T_t + S_t + C_t + R_t$$


## Tendencia

Incremento o decremento a largo plazo en los datos.

No tiene que ser lineal, y puede cambiar de dirección (aunque lo hace lentamente)

## Estacionalidad

Patrones repetitivos con un periodo definido.

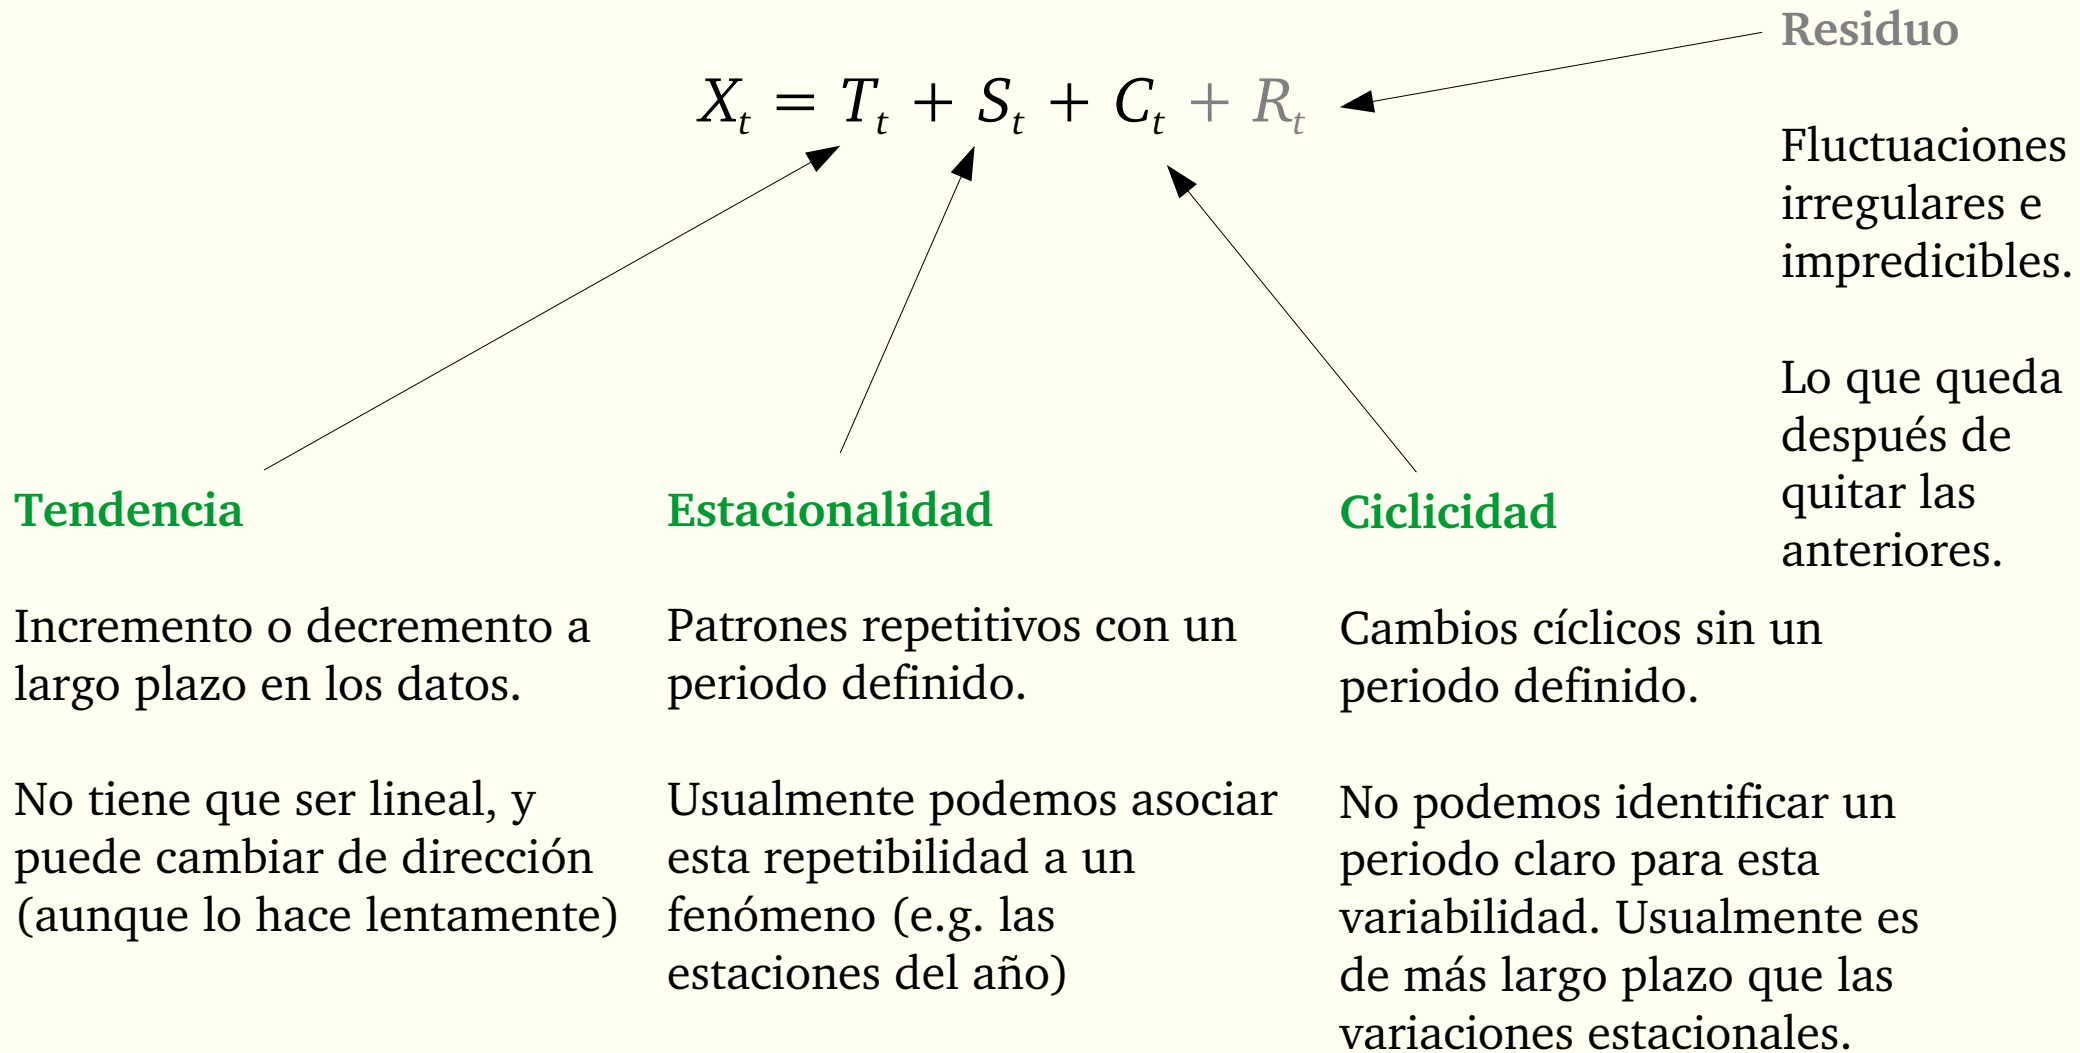
Usualmente podemos asociar esta repetibilidad a un fenómeno (e.g. las estaciones del año)

## Ciclicidad

Cambios cíclicos sin un periodo definido.


No podemos identificar un periodo claro para esta variabilidad. Usualmente es de más largo plazo que las variaciones estacionales.

# Componentes de una serie de tiempo

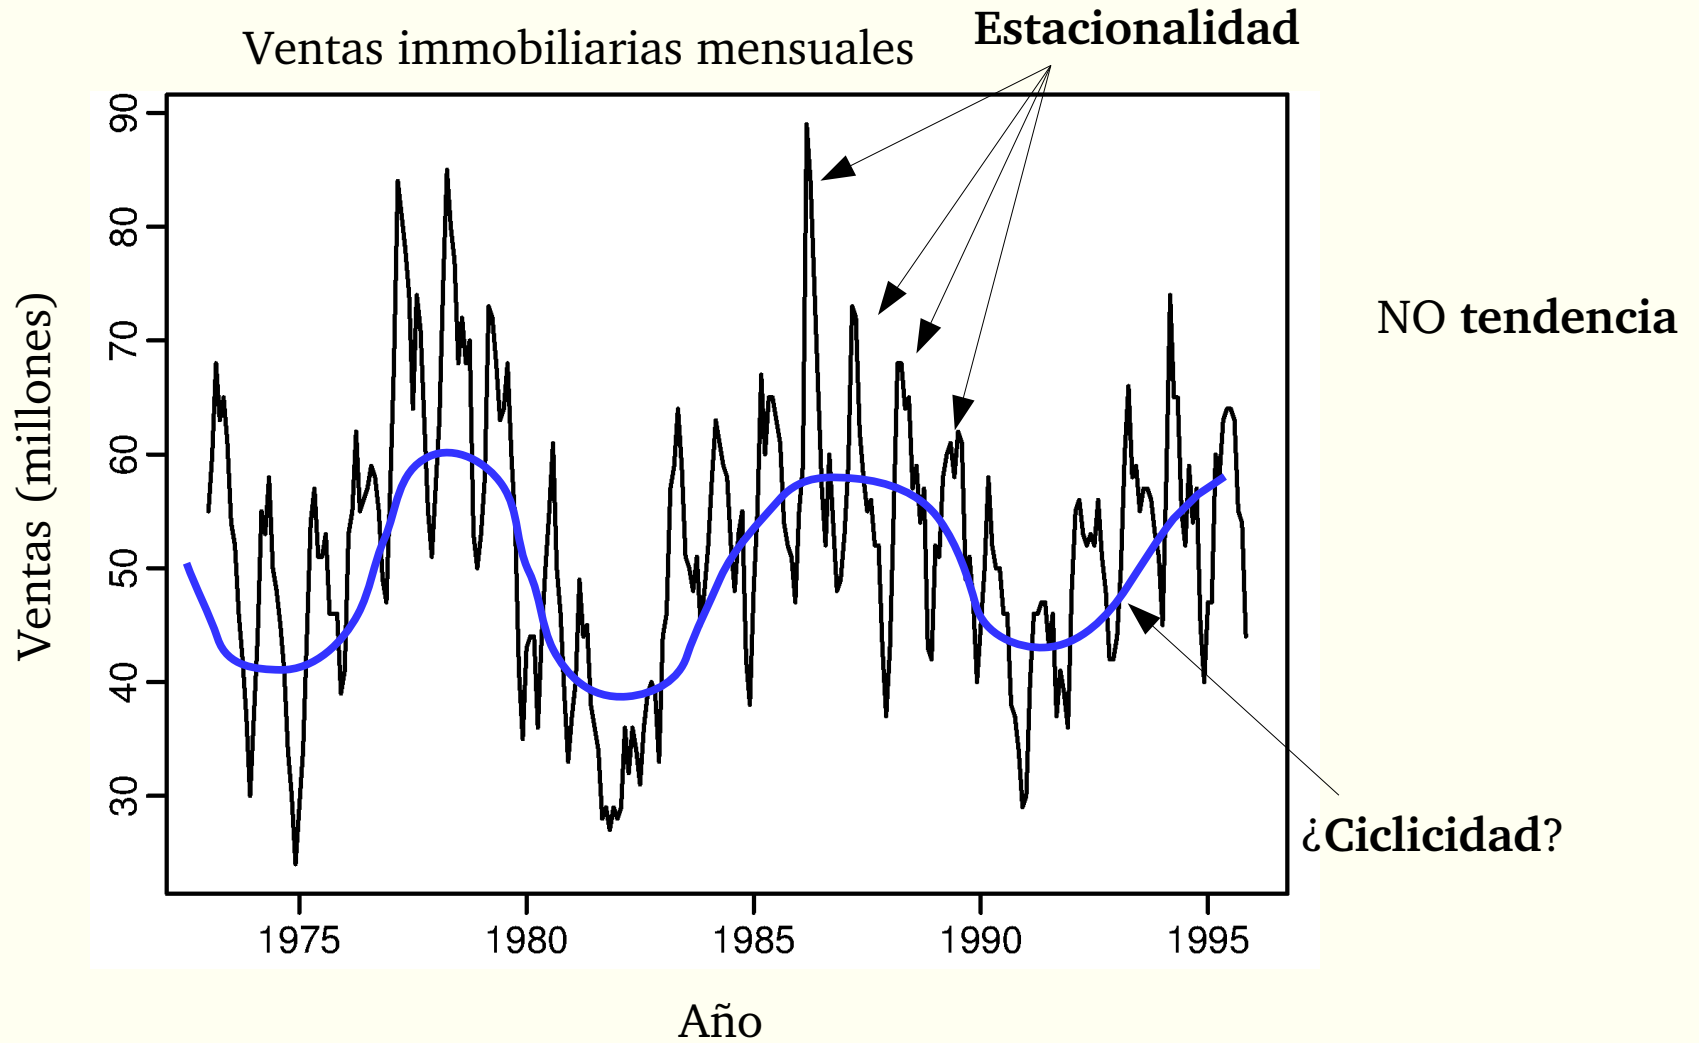


# Ejemplos

Ventas inmobiliarias mensuales




# Ejemplos



# Ejemplos


Producción eléctrica mensual en Australia





# Ejemplos


Producción eléctrica mensual en Australia



¿NO ciclicidad?


# Ejemplos

Contratos de deuda del Depto. Tesoro EE.UU




# Ejemplos

Contratos de deuda del Depto. Tesoro EE.UU




# Ejemplos

Índice Dow Jones



# Ejemplos

Índice Dow Jones



**NO tendencia**

**NO estacionalidad**

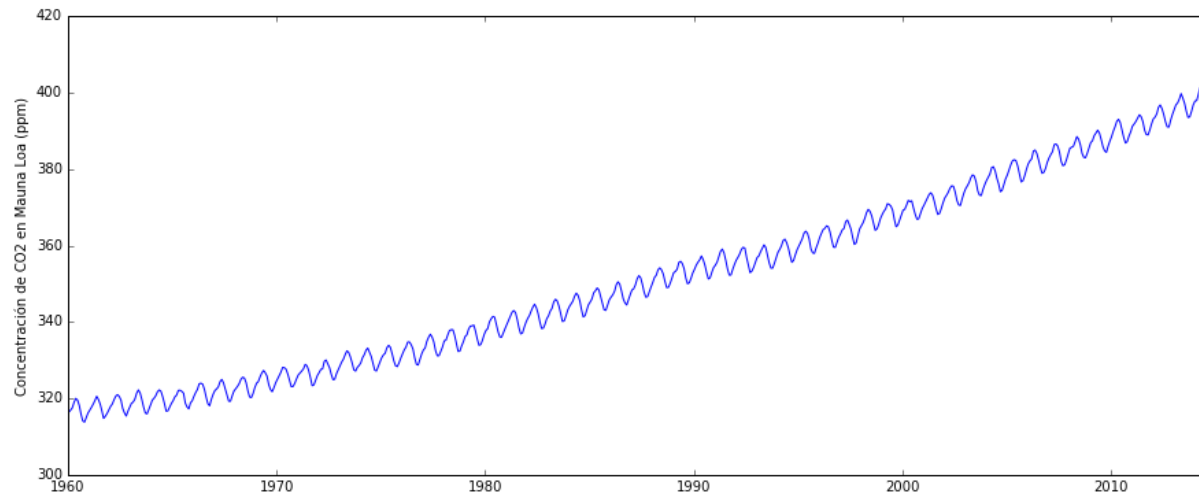
**NO ciclicidad**

# Ajustando la tendencia

La manera más sencilla de modelar la tendencia, puesto que cambia lentamente, es usando un **ajuste de curva**.

La función **curve\_fit()**, de `scipy.optimize`, permite hacer ajustes por mínimos cuadrados (no necesariamente lineal) de funciones a datos.

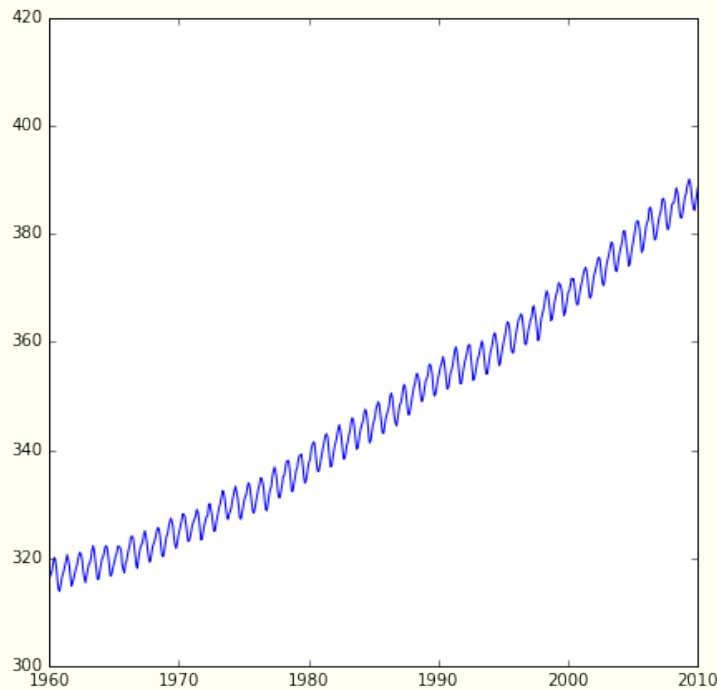
Ejercicio: CO2 atmosférico en Mauna loa  
→ primera parte de **CO2.ipynb**.



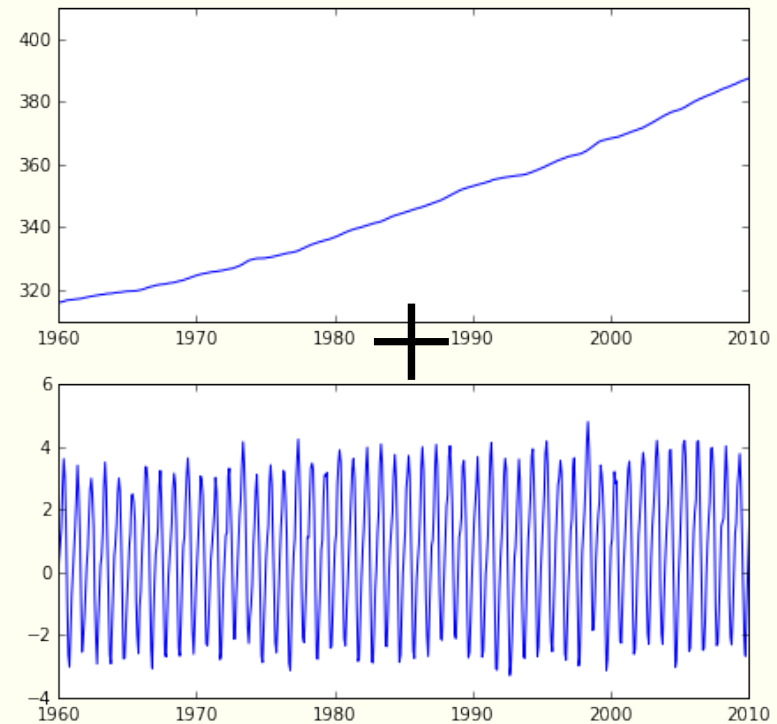
# Suavizado de series de tiempo

Los modelos matemáticos no siempre se ajustan bien a las series de tiempo reales. Otra técnica para extraer tendencia, muy simple y bastante efectiva, es el **suavizado**.

Esto elimina la variabilidad de alta frecuencia y permite separar la tendencia + ciclicidad de las demás componentes.



=



# Promedio Móvil Simple

La manera más sencilla de suavizar es **promediando**.

Para cada valor  $X_t$  de la serie de tiempo, calculamos:

$$M_t = \frac{X_t + X_{t+1} + \cdots + X_{t-N+1}}{N}$$

N-1 valores anteriores

Promedio móvil simple de  $N$  puntos



# Promedio Móvil Pesado

El promedio móvil simple se puede entender como un promedio en el que se da el **mismo peso** a los  $N-1$  valores anteriores.


$$M_t = \frac{1}{\sum w_i} \sum_{i=0}^{N-1} w_i X_{t-i}$$

↑  
Promedio pesado de  $N$  puntos

↑  
Pesos


Promedio pesado de  $N$  puntos

Una aplicación común es darle pesos *decrecientes* a los valores entre más lejos estén en el pasado.



# Promedio Móvil Pesado

Esto permite que el promedio móvil responda más rápido en cambios súbitos de la serie:



# Promedio Móvil Exponencial

Los promedios móviles anteriores (simple o pesado) tienen un **alcance finito** en el tiempo: “olvidan” el pasado más allá de cierta distancia temporal.

Este promedio asigna un peso que decrece exponencialmente, pero nunca se vuelve cero, a los valores pasado.

Se define recursivamente:

$$S_1 = X_1$$
$$S_t = \alpha X_t + (1 - \alpha) S_{t-1}$$

“Presente”

Factor de decaimiento

Promedio anterior

$$0 < \alpha < 1$$

# Promedio Móvil Exponencial

Aplicando la regla recursiva un par de veces, se ve que:

$$S_2 = \alpha X_2 + (1 - \alpha)S_1$$

$$= \alpha X_2 + (1 - \alpha)X_1$$

$$S_3 = \alpha X_3 + (1 - \alpha)S_2$$


$$= \alpha X_3 + \alpha(1 - \alpha)X_2 + (1 - \alpha)^2 X_1$$

⋮



Factores que van decreciendo  
exponencialmente

# Promedio Móvil Exponencial



# Suavizado de series de tiempo

Continuar con la segunda parte del notebook **CO2.ipynb**.

# Estacionariedad

Las series de tiempo se pueden entender como **procesos estocásticos** (es decir, fundamentalmente aleatorios).

Decimos que un proceso es **estacionario** cuando **sus propiedades estadísticas no cambian con el tiempo**.

Esto es útil pues nos permite hacer predicciones estadísticas sobre su comportamiento.


En concreto, una serie se puede ver como un proceso estacionario si:

- 1) Su media es constante en el tiempo, es decir, no tiene tendencia;
- 2) Su varianza es constante en el tiempo;
- 3) Su estructura de autocorrelación es constante en el tiempo.

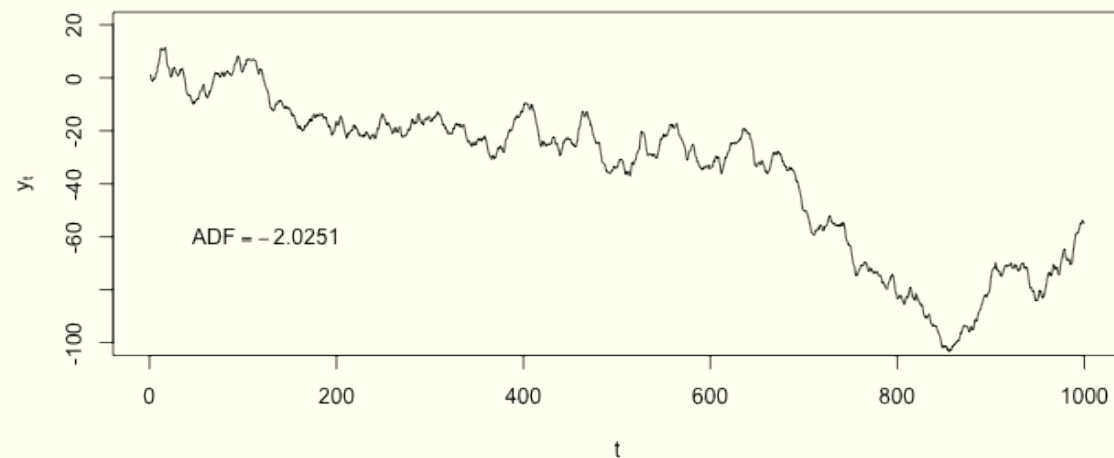
En la práctica, las series de tiempo casi nunca son estacionarias!

# Estacionariedad

Stationary Time Series



Non-stationary Time Series





# Autocorrelación

¿Cómo determinamos si una serie es estacionaria?

Las primeras dos condiciones (media y desviación estándar constantes) son fáciles de medir:

→ calculamos la media móvil y la desviación estándar móvil, y vemos si permanecen aprox. constantes.

Pero debemos también medir “la estructura de autocorrelación” ...


¿Qué es la autocorrelación?

# Autocorrelación

En términos simples, nos dice si la serie de tiempo **se parece a sí misma**, en términos estadísticos, **cuando se le retrasa** en el tiempo.

En otras palabras, indica qué tanto **depende** (linealmente) lo que pasará con los valores en un momento dado de lo que pasaba con ellos en un **tiempo anterior**.

Se entiende que es una medida de “memoria” del proceso subyacente, y es por esto que es una buena herramienta para juzgar aleatoriedad y estacionariedad.



← Temperatura en CU últimos 7 días

# Autocorrelación

La **función de autocorrelación (ACF)** de la serie  $X_t$  para el *retraso*  $\tau$  se define como:

$$ACF(\tau) = \frac{1}{(n - \tau)\sigma^2} \sum_{t=1}^{n-\tau} (X_t - \mu)(X_{t+\tau} - \mu)$$


Retraso      Longitud de la serie      Varianza      Serie desfasada en  $\tau$       Media

Si  $\tau=0$ ,

$$ACF(0) = \frac{1}{\sigma^2} \times \frac{1}{n} \sum_{t=1}^n (X_t - \mu)^2 = 1 \quad \dots \text{ naturalmente.}$$

# Autocorrelación

La función de autocorrelación (ACF) de una serie aleatoria:



# Autocorrelación Parcial


Una cantidad relacionada a la autocorrelación es la función de **autocorrelación parcial (PACF)**.

En términos simples, es una forma de la función de autocorrelación que “descuenta” el efecto de los valores intermedios que hay entre el valor actual y el valor retrasado.

Calcularla no es tan sencillo → puesto que es una herramienta común, la mayoría de las librerías incluyen una función para hacerlo (statsmodel tiene `pacf()`).

# ACF y PACF

Ejercicio: temperatura.ipynb



# Modelos de procesos estocásticos

Estos modelos representan un **enfoque alternativo, y complementario**, a los modelos que hemos visto.

Mientras hasta el momento nos hemos centrado en modelar los términos de tendencia, ciclicidad y estacionalidad de la serie, otro enfoque es modelar la **variabilidad estocástica** de la serie (a través de la autocorrelación).

Existen varios modelos para la parte estocástica de una serie de tiempo:

- Modelos Autoregresivos (AR)
- Modelos de Media Móvil (MA)
- Modelos generalizados: ARMA y ARIMA

# Modelo AR

El modelo autoregresivo establece que el valor actual de la serie de tiempo es una regresión lineal que depende de los valores **anteriores** y de un término de **ruido** estocástico

Definimos el modelo autoregresivo de **orden**  $p$ , AR( $p$ ), como:

$$X_t = c + \sum_{i=1}^p \varphi_i X_{t-i} + \varepsilon_t$$

parámetros (a ajustar)      ruido o error (aleatorio)



# Modelo AR

El modelo autoregresivo de orden cero, AR(0), es simplemente ruido:

$$X_t = c + \varepsilon_t$$


El modelo autoregresivo de orden 1, AR(1), es

$$X_t = c + \varphi X_{t-1} + \varepsilon_t$$

Es estacionario si  $|\varphi| < 1$ .

Los efectos del término de ruido al tiempo  $t$  contribuyen infinitamente lejos en el futuro, aunque con un efecto decreciente.

# Modelo AR



# Modelo MA

El modelo de media móvil (**m**oving **a**verage), en cambio, modela una serie de tiempo como una media móvil sobre los términos de ruido.

Definimos el modelo de media móvil de **orden**  $q$ , MA( $q$ ), como:

$$X_t = c + \varepsilon_t + \sum_{i=1}^q \theta_i \varepsilon_{t-i}$$

ruido actual      parámetros (a ajustar)      ruido reciente

En cierto sentido, dice que el valor actual de la serie de tiempo depende solamente de un promedio pesado de los términos de **ruido** recientes.

# La prueba de Dickey-Fuller

Es una **prueba de hipótesis de estacionariedad**.

Se fundamenta de comparar la serie con en el modelo AR(1),

$$X_t = c + \varphi X_{t-1} + \varepsilon_t$$

el cual es estacionario sólo si  $|\varphi| < 1$ .

**Hipótesis Nula:**  $\varphi = 1$ , es decir, la serie **no** es estacionaria.

- 1) Generar la estadística de prueba,  $t$ .
- 2) Obtener el valor crítico  $c$  tabulado de acuerdo al nivel de confianza deseado.
- 3) Si  $t < c$ , rechazamos la hipótesis nula  $\rightarrow$  sugiere que la serie **es** estacionaria.

# Modelo ARIMA

Finalmente, los modelos AR y MA pueden ser unificados y generalizados en el modelo **ARIMA**: AutoRegressive Integrated Moving Average.

Receta de **Box & Jenkins** para obtener un modelo  $ARIMA(p,d,q)$ :

- 1) Diferenciar la serie (i.e. tomando las diferencias entre valores vecinos)  $d$  veces hasta que la serie sea aproximadamente estacionaria (e.g. Dickey-Fuller).
- 2) Determinar los órdenes  $p$  y  $q$  de las componentes  $AR(p)$  y  $MA(q)$  usando las funciones de autocorrelación y autocorrelación parcial.
- 3) Finalmente, ajustar los parámetros de los modelos AR y MA hasta satisfacer un criterio de calidad de ajuste (e.g. AIC). Esto es altamente no trivial.

Ejercicio completo: **arima.ipynb**

# Análisis Espectral (Fourier)

Hasta ahora todo el análisis se ha hecho en el **dominio del tiempo**.

Otra forma de analizar una serie de tiempo es hacerlo en el dominio de la **frecuencia**.

**Idea fundamental:** transformar la serie de tiempo a una representación en términos de componentes periódicas simples

Nos permite:

- Determinar las componentes periódicas (aún cuando estén “escondidas”)
- Establecer el tipo de correlaciones presentes en la serie
- Modelar varios tipos de ruido

# La Serie de Fourier

Teorema de Fourier: **cualquier** función *periódica* puede ser descrita **exactamente** como una suma (infinita) de funciones armónicas (senosoidales)

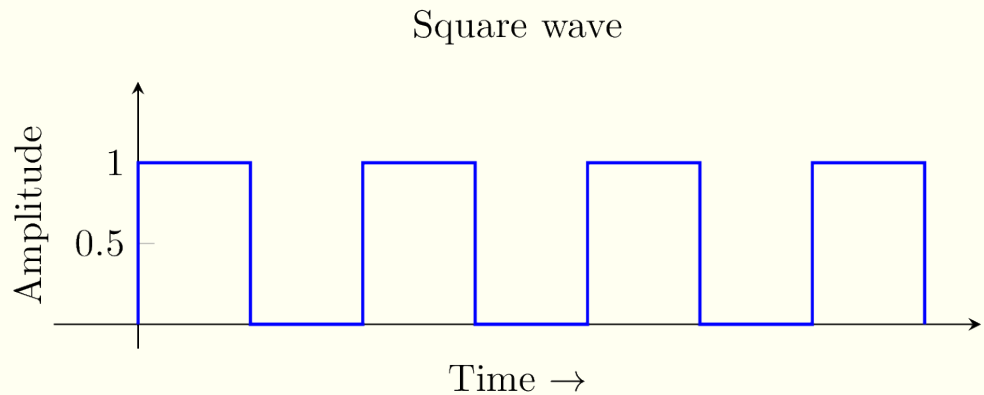
$$f(x) = A_0 + \sum_{n=1}^{\infty} A_n \sin \left( \frac{2\pi n}{P} x + \phi_n \right)$$

Diagram illustrating the Fourier series equation with labels and arrows:



- $f(x)$ : Función arbitraria con periodo  $P$
- $A_0$ : Constant term
- $A_n$ : amplitud
- $\frac{2\pi n}{P}$ : frecuencia
- $\phi_n$ : fase
- The terms  $A_n \sin \left( \frac{2\pi n}{P} x + \phi_n \right)$  are collectively labeled as "armónicos".



# La Serie de Fourier



Fourier



Animación: onda cuadrada con 3 armónicos

<https://www.youtube.com/watch?v=LznjC4Lo7lE>

En serio, aplica para cualquier función ...


<https://www.youtube.com/watch?v=QVuU2YCwHjw>




# Dominio de la frecuencia

Esto nos lleva a una representación alternativa de cualquier señal en términos de las **amplitudes** de cada una de sus **frecuencias** componentes.

$$f(x) = A_0 + \sum_{n=1}^{\infty} A_n \sin\left(\underbrace{\frac{2\pi n}{P}x + \phi_n}_{\omega}\right)$$



“Dominio del tiempo”



“Dominio de la frecuencia”

# La Transformada de Fourier

La **transformada** de Fourier generaliza esta idea: representamos una señal en el dominio de la frecuencia empleando una frecuencia que varía **continuamente**

$$\hat{f}(\omega) \equiv \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} f(t) e^{-i\omega t} dt$$

Transformada de Fourier de la señal  
(dominio de la frecuencia)

Señal original  
(dominio del tiempo)

Forma “matemática” de  
escribir senos y cosenos

# DFT: Transf. de Fourier Discreta

Como las series de tiempo son señales **discretas** (están definidas para una serie de instantes temporales discretos), usamos la versión discreta de la FT:

$$\hat{X}_k \equiv \sum_{t=0}^{N-1} X_t \cdot e^{-2\pi i k t / N}$$

DFT (un valor para cada  $k$  en  $[0, N-1]$ )

Serie de tiempo



“frecuencia”

Longitud de la serie de tiempo

Aunque, como veremos, la mitad son redundantes.

# Cálculo del DFT con numpy

## Parte 1 de `fourier.ipynb`



# Espectro de Potencia

Usualmente se trabaja con la transformada de Fourier no directamente, sino a través de su “primo” el **espectro de potencia**, también conocido como la “densidad espectral de potencia”, **PSD** (Power Spectral Density).

Se define simplemente tomando el cuadrado del valor absoluto del DFT:

$$\text{PSD} \equiv S_k \equiv |\hat{X}_k|^2$$

Debido a que el cuadrado amplifica los valores, se suele graficar en escala log-log.

Ejemplo rápido: manchas solares  
**manchas.ipynb**


# Artefactos: filtrado espectral

(Parte 2 de `fourier.ipynb`)

Cuando las periodicidades de la serie de tiempo no completan un número entero de ciclos, el DFT **ensancha artificialmente** los picos asociados a esa frecuencia.

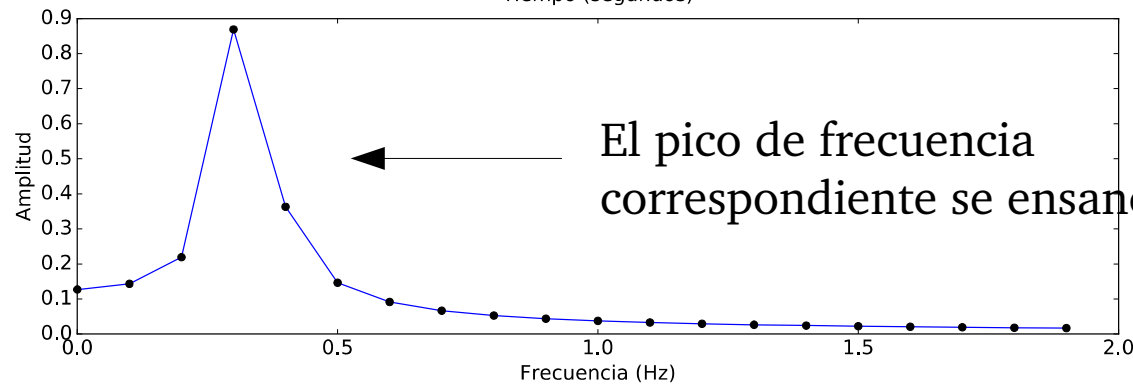
Esto se conoce como **filtrado espectral** (*spectral leakage*).

Seno de  
0.33 Hz



La serie no  
completa un  
número entero  
de ciclos

DFT




El pico de frecuencia  
correspondiente se ensancha

# Artefactos: filtrado espectral

Esto también ocurre si la componente periódica **no es estacionaria**, por ejemplo porque su amplitud cambia con el tiempo:

Seno de 0.33 Hz  
con amplitud  
creciente




PSD


# Artefactos: armónicos

Si la periodicidad no es de forma sinusoidal, esto introduce **armónicos espurios**.

Función  
sierra de  
0.1 Hz



PSD






# No-estacionariedad

(tiempo\_frecuencia.ipynb)

Si el contenido espectral de una serie de tiempo no es estacionario, la transformada de Fourier tiene problemas para descomponerla.




# Análisis Tiempo-Frecuencia

Una forma de lidiar con series no-estacionarias es hacer el análisis en **tiempo y frecuencia simultáneamente**.


Una técnica sencilla es usar la transformada de Fourier "ventaneada" o **Short-Time-Fourier-Transform (STFT)**.

La idea es calcular la transformada de Fourier en una **ventana temporal** pequeña la cual se va **recorriendo** sobre la serie. Con esto se puede capturar un contenido espectral que cambia con el tiempo.



# Transf. de Fourier Ventaneada

El resultado es un diagrama 2D que tiene tiempo en un eje y frecuencia en el otro conocido como **espectrograma**.



# Transformadas de Wavelet



Otra herramienta relacionada de análisis de tiempo-frecuencia son las **transformadas de wavelets** (o CWT, **Continuous Wavelet Transform**).

Es una generalización de la transformada de Fourier: en lugar de usar funciones armónicas se usan **wavelets**: formas de onda arbitraria que pueden cambiar de escala en el tiempo. En scipy existe `scipy.signal.cwt()` para esto.

Ricker wavelet, alias  
“Mexican Hat”





5 Hz Ricker wavelet



# Ejemplo: detección de ondas gravitacionales (LIGO)

<http://stuver.blogspot.mx/2016/02/LIGO-FirstDetection.html>



# Muchos, muchos temas más ...

- Modelos ARIMA estacionales
- Métodos para series de tiempo multivariadas
- Teoría de filtrado
- Transformadas de tiempo-frecuencia avanzadas
- Métodos de decomposición adaptativos
  - Empirical Mode Decomposition
  - Singular Spectrum Analysis
- etc.

# Libros ...

- Time Series Analysis and Its Applications: With R Examples  
Shumway and Stoffer  
Hay versión "EZ" gratuita:  
<http://www.stat.pitt.edu/stoffer/tsa4/tsaEZ.pdf>
- Time Series Analysis: With Applications in R  
Cryer and Chan
- Introductory Time Series with R  
Covpewartait and Metcalfe
- Time Series Analysis and Forecasting by Example  
Bisgaard and Kulahci

