




Series temporales

© Fernando Berzal, berzal@acm.org

Datos secuenciales



Start

Human
Chimpanzee
Macaque

GTTTTGAGC - - ATGTTCAACAAATGC TCGTTTCAATTCCCTATTTACAGACCTGGCGCA
GTTTTGAGC - - ATGTTCAAAATATGCTGCTTTCACTTCCTGTATTTACAGACCTGGCGCA
GTTTTGAGC - - ATGCTCAATAAATGCTCCTTTCATTCCTCCATTAAACTTGAGCT

Human
Chimpanzee
Macaque

GAC AATTCTGCTAGCAGCTTTGCTATTATCTGTTTCTAAACCTTAGTAATTGAGTGT
GACAATTCTGCTAGCAGCTTTGCTATTATCTGTTTCTAAACCTTAGTAATTGAGTGT
GACAATTCTGCTAGCAGCTTTGCTATTATCTGTTTCTAAACCTTAGTAATTGAGTGT

Human
Chimpanzee
Macaque

GATCTGGAGACTAA-CTCTGAATAATAAAGCTAAATTATTTTCACTTCTAAACAAACAA
GATCTGGAGACTAAACTGCTAAATAAAGCTAAATTATTTTCACTTCTAAACAAACAA
TATCTGGAGACTAAACTGCTAAATAAAGCTAAATTATTTTCACTTCTAAACAAACAA

Human
Chimpanzee
Macaque

CAGAATACGATTAGCAAAATTCTCTAAAGATAATTATTTTACATTTCTAAACAAACAA
CAGAATACGATTAGCAAAATTCTCTAAAGATAATTATTTTCACTTCTAAACAAACAA
CAGAATATGATTAGCAAAATTACCTCTAAAGATAATTATTTTCACTTCTAAACAAACAA

Human
Chimpanzee
Macaque

CCCTGAGTTGATGTTGAGCAATTAGTCACTTTCATAAAAGCCAGGTACAC- - TTATG
CCCTGAGTTGATGTTGAGCCATTAGTCACTTTCATAAAAGCCAGGTACAC- - TTATG
CCCTGAGTTGATGTTGAGCAATTAGTCACTTTCACAAAGCCAGGTACAC- - TTATG

Human
Chimpanzee
Macaque

GACAGGTAAAGTAAAAAACATATTATTTCTACGTTTTGTCCAAAATTITAAATTTC
GACAGGTAAAGTAAAAAACATATTATTTCTACGTTTTGTCCAAAATTITAAATTTC
GACAGGTAAAGTAAAAA-CATATTATTTCTACGTTTTGTCCAAAATTITAAATTTC

Human
Chimpanzee
Macaque

H I Y S T F L S K
GACAGGTAAAGTAAAAAACATATTATTTCTACGTTTTGTCCAAAATTITAAATTTC
GACAGGTAAAGTAAAAAACATATTATTTCTACGTTTTGTCCAAAATTITAAATTTC
GACAGGTAAAGTAAAAA-CATATTATTTCTACGTTTTGTCCAAAATTITAAATTTC

Human
Chimpanzee
Macaque

AACTGTTGCGCGTGTGTTGGTAA- - TGTAACAAACTCAGTACA- - TTATG
AACTGTTGCGCGTGTGTTGGTAA- - TGTAACAAACTCAGTACA- - TTATG
AACTGTTGCGCGTGTGTTGGTAA- - CGTAAACAAACTCAGTACA



Series temporales



- Características de las series temporales
- Visualización de series temporales
- Preprocesamiento
- Filtrado de series temporales
 - Medias móviles
 - Suavizado exponencial
- Técnicas de regresión
 - Regresión lineal
 - Coeficiente de correlación de Pearson
- Función de autocorrelación
- Caso práctico: Una sesión de análisis




Series temporales



Evolución de PIB en España. 1971 a 2020

— En % de variación interanual / — % de variación intertrimestral



Características




- Tendencias
- Estacionalidad (comportamientos periódicos)
- Ruido
- Otros, p.ej. cambios bruscos de comportamiento



Ejemplos



Tendencia y estacionalidad




Concentración de CO₂
medida en el observatorio de Mauna Loa, Hawaii.



Ejemplos



Variación “suave” pero sin tendencia a largo plazo




Concentración de gas a la salida de una caldera



Ejemplos



Tendencia no lineal



Coste de llamadas telefónicas de larga distancia (USA)



Ejemplos



Cambios “bruscos” de comportamiento



Índice Nikkei (Bolsa de Tokio)




Ejemplos




Conjuntos de datos reales...

Estacionalidad a corto y largo plazo,
posibles cambios de comportamiento
y ruido

Llamadas diarias
a un call-center



Visualización



Número anual de manchas solares durante 300 años

**Una relación de aspecto incorrecta
hace difícil reconocer los detalles de cada ciclo.**




Visualización



Banking [Banking to 45 degrees]

Los cambios casi verticales de la figura anterior nos cuesta trabajo apreciarlos. Sin embargo, reconocemos mejor los cambios en una serie cuando se dibujan con un ángulo de 45º:




Ahora podemos apreciar que las "subidas" son más rápidas que las bajadas, aunque la figura es tan pequeña que apenas se pueden analizar detalles...



Visualización



Stacking




Dividiendo el eje temporal en 3 fragmentos, mantenemos el “banking” y generamos un gráfico con unas dimensiones más razonables (p.ej. 4:3).



Preprocesamiento



Datos originales



Correlación entre las series temporales


	Minneapolis	Atlanta	Sao Paolo
Minneapolis	1.0000	0.7591	-0.7581
Atlanta	0.7591	1.0000	-0.5739
Sao Paolo	-0.7581	-0.5739	1.0000



Preprocesamiento



Normalización z-score mensual



Correlación entre las series temporales estacionalizadas

	Minneapolis	Atlanta	Sao Paolo
Minneapolis	1.0000	0.0492	0.0906
Atlanta	0.0492	1.0000	-0.0154
Sao Paolo	0.0906	-0.0154	1.0000




Preprocesamiento




Transformada de Fourier

Representación en el tiempo



Representación en frecuencia



Filtrado de series temporales



Medias móviles [moving averages]

IDEA: Reemplazar el punto central de una serie de un número impar de números consecutivos por su media aritmética (filtro “paso bajo”).

$$s_i = \frac{1}{2k+1} \sum_{j=-k}^k x_{i+j}$$



Filtrado de series temporales



Medias móviles [moving averages]

PROBLEMA: La presencia de un pico en la ventana $[i-k, i+k]$ distorsiona la media móvil.

POSIBLE SOLUCIÓN: Utilización de pesos (menores en los extremos de la ventana).

$$s_i = \sum_{j=-k}^k w_j x_{i+j} \quad \text{donde} \quad \sum_{j=-k}^k w_j = 1$$

Ejemplos: Gaussiana, ventana de Hamming...


http://en.wikipedia.org/wiki/Window_function#Hann_window



Filtrado de series temporales



Medias móviles [moving averages]



k=5



Filtrado de series temporales



Medias móviles [moving averages]

Limitaciones de las medias móviles:

- “Costosas” de calcular: Cuando se utilizan pesos, el cálculo hay que hacerlo desde cero para cada valor.
- Problemáticas en los extremos de las series de datos (dada la anchura de la ventana, no se pueden extender hasta el final de la serie, que suele ser lo más interesante).
- No se pueden definir fuera de la serie temporal, por lo que no se pueden utilizar para realizar predicciones.



Filtrado de series temporales



Suavizado exponencial [exponential smoothing]

Proporciona un filtrado fácil de calcular, además evita los problemas de las medias móviles:

- **Suavizado exponencial simple**
(para series sin tendencia ni estacionalidad).
- **Suavizado exponencial doble**
(para series con tendencia pero no estacionalidad).
- **Suavizado exponencial triple**
(para series con tendencia y estacionalidad).



Filtrado de series temporales



Suavizado exponencial simple

$$s_i = \alpha x_i + (1 - \alpha)s_{i-1}$$

Los distintos métodos de suavizado exponencial actualizan el resultado del anterior valor con el último dato de la serie original (combinando la información ya disponible con la aportada por el nuevo dato mediante un parámetro, $0 < \alpha < 1$).



Filtrado de series temporales



Suavizado exponencial simple

¿Por qué se llama suavizado exponencial?

Si expandimos la recurrencia, obtenemos:

$$s_i = \alpha \sum_{j=0}^i (1-\alpha)^j x_{i-j}$$

Todas las observaciones previas contribuyen al valor suavizado, pero su contribución se suprime por el exponente creciente del parámetro α .



Filtrado de series temporales



Suavizado exponencial simple

“Uso” en predicción: Si extendemos el suavizado más allá del final de los datos disponibles, la predicción es extremadamente simple :-)

$$x_{i+h} = s_i$$

Ante la presencia de tendencias, la señal suavizada tiene ir retrasada con respecto a los datos originales salvo que utilicemos un valor de α cercano a 1.



Filtrado de series temporales



Suavizado exponencial doble

$$s_i = \alpha x_i + (1 - \alpha)(s_{i-1} + t_{i-1})$$

$$t_i = \beta(s_i - s_{i-1}) + (1 - \beta)t_{i-1}$$

El suavizado exponencial doble retiene información acerca de la tendencia: la señal suavizada s_i y la tendencia suavizada t_i .

El parámetro β se utiliza para realizar un suavizado exponencial sobre la tendencia.



Filtrado de series temporales



Suavizado exponencial doble

“Uso” en predicción:

Si extendemos el suavizado más allá del final de los datos disponibles, la predicción es la siguiente:

$$x_{i+h} = s_i + ht_i$$



Filtrado de series temporales



Suavizado exponencial triple

(a.k.a. método de Holt-Winters)

Una tercera cantidad se utiliza para describir la estacionalidad, que puede ser aditiva o multiplicativa según nos interese.

NOTA:

p_i modela el componente periódico de la señal, donde k es el período observado.



Filtrado de series temporales



Suavizado exponencial triple

(a.k.a. método de Holt-Winters)

ESTACIONALIDAD ADITIVA

$$s_i = \alpha(x_i - p_{i-k}) + (1-\alpha)(s_{i-1} + t_{i-1})$$

$$t_i = \beta(s_i - s_{i-1}) + (1-\beta)t_{i-1}$$

$$p_i = \gamma(x_i - s_i) + (1-\gamma)p_{i-k}$$

$$x_{i+h} = s_i + ht_i + p_{i-k+h}$$



Filtrado de series temporales



Suavizado exponencial triple

(a.k.a. método de Holt-Winters)

ESTACIONALIDAD MULTIPLICATIVA

$$s_i = \alpha \frac{x_i}{p_{i-k}} + (1 - \alpha)(s_{i-1} + t_{i-1})$$

$$t_i = \beta(s_i - s_{i-1}) + (1 - \beta)t_{i-1}$$

$$p_i = \gamma \frac{x_i}{s_i} + (1 - \gamma)p_{i-k}$$


$$x_{i+h} = (s_i + ht_i)p_{i-k+h}$$



Filtrado de series temporales



Suavizado exponencial [exponential smoothing]



Número mensual de pasajeros (en miles).



Filtrado de series temporales



Suavizado exponencial [exponential smoothing]

For more competitions, visit [kaggle.com](#) Sign in

kaggle
in class

First International Competition of Time Series Forecasting

PRIIZE POOL Kudos TEAMS 16 COMPLETED 6 days ago

Information Data Forum Results

Private Leaderboard

This competition has completed, this leaderboard reflects the preliminary final standings. The results will become final after the competition organizers verify the results.

#	Δfw Team Name	SMAPE	Entries	Last Submission UTC (Best Submission - Last)
1	12 NT	13.82165	16	Fri, 10 Feb 2012 00:02:10 (+4d)
2	1 DuckTale	14.90062	32	Fri, 10 Feb 2012 15:58:28
3	1 woobe	15.59030	24	Sun, 05 Feb 2012 01:42:24
4	- bobo	16.78477	26	Fri, 10 Feb 2012 21:19:10 (-14.8d)

7 11 boder 21.91173

9 12 Forbin	23.09967	4	Thu, 26 Jan 2012 23:56:07 (-19.2d)
10 11 JCW	27.31540	3	Tue, 03 Jan 2012 08:38:39 (-23.3d)
11 11 Dennis Jaheruddin	33.68753	1	Mon, 05 Dec 2011 12:10:16
9 10 Last Observed Value Benchmark	34.39842		
13 11 TT	42.16377	1	Mon, 05 Dec 2011 11:56:40
14 11 J.O	128.83199	1	Mon, 19 Dec 2011 07:48:40
14 new chwolte	128.83499	2	Fri, 10 Feb 2012 15:27:40 (-21.8d)
9 12 All zeros	200.00000		

16 teams as of Fri, 10 Feb 2012 23:59:00

Sólo ajustando 3 parámetros se obtiene un “buen” modelo...

7º puesto

International Competition on Time Series Forecasting ICTSF'2012

SMAPE = 21.91
vs. 13.82 (ganador)
vs. 34.40 (benchmark)



Técnicas de regresión



La predicción (numérica) es...

- Similar a la clasificación:
 - Se construye un modelo a partir de un conjunto de entrenamiento.
 - Se utiliza el modelo para predecir el valor de una variable (continua u ordenada).
- Diferente a la clasificación:
 - El modelo define una función continua.

Método más empleado: **Regresión**



Técnicas de regresión



Las técnicas de regresión modelan la relación entre una o más variables independiente (predictores) y una variable dependiente (variable de respuesta).

Métodos de regresión

- Regresión lineal
- Regresión no lineal
- Árboles de regresión (p.ej. CART)
- ...



Técnicas de regresión



Regresión lineal simple

Una única variable independiente:

$$y = w_0 + w_1 x$$

donde w_0 (desplazamiento) y w_1 (pendiente)
son los coeficientes de regresión.

■ Método de los mínimos cuadrados

(estima la línea recta que mejor se ajusta a los datos):

$$w_0 = \bar{y} - w_1 \bar{x} \quad w_1 = \frac{\sum_{i=1}^{|D|} (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^{|D|} (x_i - \bar{x})^2}$$




Técnicas de regresión



Regresión lineal simple


$$\hat{Y}_i = b_0 + b_1 X_i$$



Técnicas de regresión



Regresión lineal simple




El método de los mínimos cuadrados minimiza la suma de los cuadrados de los residuos ε_i (las diferencias entre las predicciones y los valores observados).



Técnicas de regresión



Regresión lineal simple



iOJO! Al utilizar regresión lineal, la recta $y=f(x)$ que se obtiene es distinta a la que obtenemos si $x=f(y)$.



Técnicas de regresión



Regresión lineal múltiple

Varias variables independientes:

$$y = w_0 + w_1 x_1 + w_2 x_2 + \dots$$

- Resoluble por métodos numéricos de optimización.
- Muchas funciones no lineales pueden transformarse en una expresión lineal.

p.ej. Un modelo de regresión polinomial

$$y = w_0 + w_1 x + w_2 x^2 + w_3 x^3$$

puede transformarse en un modelo lineal definiendo las variables $x_2 = x^2$, $x_3 = x^3$:

$$y = w_0 + w_1 x + w_2 x_2 + w_3 x_3$$



Técnicas de regresión



Regresión lineal

Condiciones necesarias para aplicar regresión lineal:

- Obviamente, la muestra ha de ser aleatoria.
- El tipo de dependencia descrita ha de ser lineal.
- Fijado un valor de la(s) variable(s) independiente(s), la variable dependiente se distribuye según una distribución normal.
- Los errores han de tener la misma varianza (nube de puntos homogénea).




Técnicas de regresión



Regresión lineal simple

1. Mediante un diagrama de dispersión, comprobamos visualmente si existe una relación lineal entre las variables X (predictor) e Y (respuesta):



Técnicas de regresión



Regresión lineal simple

2. Cuantificamos la relación construyendo la recta que resume la dependencia y damos una medida de cómo se ajusta la recta a los datos (correlación):

$$r = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2 \sum_{i=1}^n (Y_i - \bar{Y})^2}} \in [-1, 1]$$



Técnicas de regresión



Coeficiente de correlación

$$r = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2 \sum_{i=1}^n (Y_i - \bar{Y})^2}} \in [-1, 1]$$

r=+1

Dependencia lineal total en sentido positivo
(cuanto mayor es X, mayor es Y).

r=-1

Dependencia lineal total en sentido negativo
(cuanto mayor es X, menor es Y).



Técnicas de regresión



Coeficiente de correlación

$$r = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2 \sum_{i=1}^n (Y_i - \bar{Y})^2}} \in [-1, 1]$$

- r > 0** Existe una dependencia positiva.
Cuanto más se acerque a 1, mayor es ésta.
- r < 0** Existe una dependencia negativa.
Cuanto más se acerque a -1, mayor será.
- r = 0** No podemos afirmar nada.




42

Técnicas de regresión



Coeficiente de correlación







43

Técnicas de regresión



Coeficiente de correlación







44

Técnicas de regresión



Coeficiente de correlación



El cuarteto de Anscombe

(4 conjuntos de datos con el mismo coeficiente de correlación)



45

Técnicas de regresión



Coeficiente de correlación

Ventaja de r

- No depende de las unidades usadas en la medición.

Limitaciones de r

- Sólo mide dependencia lineal entre las variables.

iOJO! La correlación no implica causalidad...




46

Técnicas de regresión



Coeficiente de correlación



"Correlation is not causation but it sure is a hint."

-- Edward Tufte



47

Función de autocorrelación




$$c(k) = \frac{\sum_{i=1}^{N-k} (x_i - \mu)(x_{i+k} - \mu)}{\sum_{i=1}^N (x_i - \mu)^2} \quad \text{con} \quad \mu = \frac{1}{N} \sum_{i=1}^N x_i$$



48

Función de autocorrelación




Autocorrelación para la salida de gas de una caldera



49

Función de autocorrelación



Autocorrelación en las llamadas a un call-center




Caso práctico



Conjunto de datos

Mediciones de CO₂ en Mauna Loa (Hawaii)




Adaptado de Philipp K. Jannert:
"Intermezzo: A Data Analysis Session" [capítulo 6]



Caso práctico




A partir de las mediciones mensuales (1959-1991), eliminamos las fechas del eje X y hacemos que la serie empiece de cero:



Caso práctico



Tendencia: Apreciamos una tendencia no lineal:
Intentamos ajustarla con una función de la forma x^k
Nota: Todas las curvas de ese tipo pasan por $(0,0)$ y $(1,1)$




Con $k=2$, tenemos $35*(x/350)^2$, pero parece que nos hemos pasado...



Caso práctico



Afinamos un poco más y usamos un valor menor:



OK!

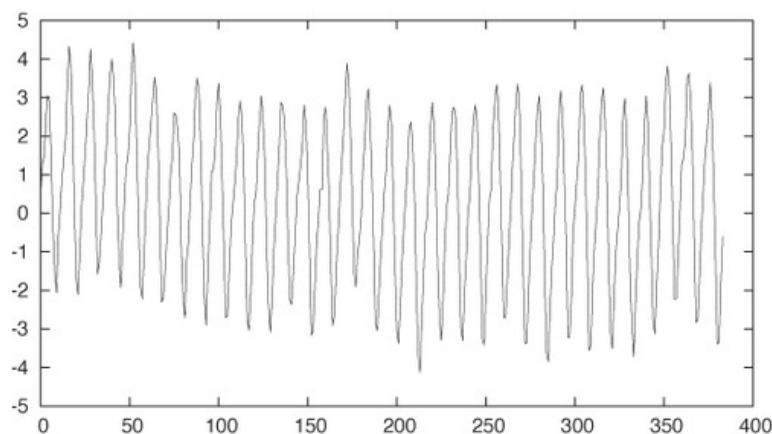
$$k=1.35$$

$$\text{Ajuste de la función } f(x) = 35*(x/350)^{1.35}$$



Caso práctico

Para comprobar que no vamos mal,
calculamos los residuos (valor original – aproximación):




$$\text{Residuos del ajuste } f(x) = 35*(x/350)^{1.35}$$



Caso práctico



Si nuestro ajuste de la tendencia es correcto, los residuos no deben exhibir tendencia alguna (deberían aparecer balanceados en torno a $y=0$):



Suavizamos los residuos para comprobar si aún existe algún tipo de tendencia en los residuos...




Caso práctico



Estacionalidad:

Apreciamos una periodicidad anual (cada 12 valores)




Ajustamos con una función senoidal $3\sin(2\pi x/12)$



Caso práctico




Calculamos los residuos tras nuestras aproximaciones
(valor original – tendencia – estacionalidad)



Caso práctico



En la figura anterior no se ve mucho... hacemos zoom:




Se sigue apreciando cierta periodicidad, por lo que usamos un segundo armónico $-0.75 \cdot \sin(2\pi x/6)$



Caso práctico




Residuos tras eliminar la tendencia y los dos primeros armónicos correspondientes a la estacionalidad:



Caso práctico



Añadimos líneas que nos ayuden a ver si los residuos están sesgados:




Parece sesgado hacia arriba,
por lo que añadimos un desplazamiento de +0.1



Caso práctico



Los residuos de nuestra aproximación final:




$$\begin{aligned} f(x) = & 315 + 35*(x/350)^{**1.35} \\ & + 3*\sin(2*\pi*x/12) - 0.75*\sin(2*\pi*x/6) \\ & + 0.1 \end{aligned}$$



Caso práctico




El ajuste que hemos realizado (1959-1990):



Caso práctico



Nuestra predicción del futuro (1991-2010)



Predicción de series temporales



Predicción de series temporales



Forecasting

<http://en.wikipedia.org/wiki/Forecasting>



Modelos estadísticos



Modelos autorregresivos

AR(p)

Modelo autorregresivo de orden p:

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

- AR(0): Sin parámetros, sólo error
- AR(1): Un único parámetro φ_1 (positivo)
- AR(2): Dos parámetros φ_1 (positivo) y φ_2



Modelos estadísticos



Medias móviles

MA(q)

Modelo de medias móviles de orden q:

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



Modelos estadísticos



Autorregresión (AR) + Medias móviles (MA)

ARMA(p,q)

Con p términos autorregresivos y q medias móviles:

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

Peter Whittle: "Hypothesis testing in time series analysis,"
Ph.D. thesis, Uppsala, Sweden, 1951



Modelos estadísticos



Cuando la media no es estacionaria...

ARIMA(p,d,q)

autoregressive integrated moving average

Se añaden d pasos de diferenciación ("integración") para eliminar la tendencia de la serie (media no estacionaria):

- d=0: $X_t^* = X_t$
- d=1: $X_t^* = X_t - X_{t-1}$
- d=2: $X_t^* = (X_t - X_{t-1}) - (X_{t-1} - X_{t-2})$

Y se aplica un modelo ARMA sobre X_t^* ...



Modelos estadísticos



Cuando la media no es estacionaria...

ARIMA(p,d,q)

autoregressive integrated moving average

$$X_t = -(\Delta^d X_t - X_t) + \varphi_0 + \sum_{i=1}^p \varphi_i \Delta^d X_{t-i} - \sum_{i=1}^q \theta_i \varepsilon_{t-i} + \varepsilon_t$$

donde

$$\Delta X_t = X_t - X_{t-1}$$

George E.P. Box & Gwilym Jenkins: "Time Series Analysis: Forecasting and Control," 2nd ed., Holden-Day, 1976



Modelos estadísticos



Cuando la media no es estacionaria...

ARIMA(p,d,q)

autoregressive integrated moving average

- ARIMA(1,0,0) = AR(1)
- ARIMA(0,1,0) = I(1) = Random walk (paseo aleatorio)
- ARIMA(0,0,1) = MA(1)
- ARIMA(0,1,2) = Damped Holt's model
- ARIMA(0,1,1) = Suavizado exponencial básico
- ARIMA(0,2,2) = Suavizado exponencial doble,
a.k.a. Método lineal de Holt con errores aditivos.



Modelos estadísticos



ARIMA estacional

SARIMA(p,d,q)(P,D,Q)m

Seasonal autoregressive integrated moving average

- (p,d,q) Parte no estacional
- (P,D,Q) Parte estacional
 - P términos AR estacionales
 - D diferencias estacionales
 - Q términos MA estacionales
- m Observaciones por año

p.ej.

$$\text{SARIMA}(1,0,1)(2,1,0)12 \quad y_t - y_{t-12} = W_t$$

$$W_t = \mu + \phi_1 W_{t-1} + \phi_2 W_{t-12} + \phi_3 W_{t-24} + \theta_1 \varepsilon_{t-1} + \varepsilon_t$$



Modelos estadísticos



Con variables exógenas

SARIMAX

**Seasonal Autoregressive Integrated Moving-Average
with eXogenous regressors**

Time series									
1	2	3	4	5	6	7	8	9	10
Exogenous variable									
a	b	c	d	e	f	g	h	i	j

X	y
1	6
2	7
3	8
4	9
5	10
f	
g	
h	
i	
j	

<https://cienciadedatos.net/>

<https://doi.org/10.5281/zenodo.8382788>



Modelos estadísticos



Extensiones vectoriales,
para predecir series temporales multivariable
(i.e. múltiples series temporales relacionadas):

- VAR [Vector AutoRegressive]
- VMA [Vector Moving Average]
- VARMA [Vector ARMA]
- VARIMA [Vector ARIMA]
- ...

p.ej. Econometría



Modelos estadísticos



Cuando la varianza del error no es estacionaria pero se asume que sigue un modelo autorregresivo (AR):

ARCH(q)

AutoRegressive Conditional Heteroskedasticity

$$\varepsilon_t = \sigma_t z_t$$

$$\sigma_t^2 = \omega + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{i=1}^p \beta_i \sigma_{t-i}^2$$

Robert F. Engle: "Autoregressive Conditional Heteroscedasticity with Estimates of Variance of United Kingdom Inflation,"
Econometrica, 50(4):987–1007, 1982



Modelos estadísticos



Cuando la varianza del error no es estacionaria pero se asume que sigue un modelo ARMA:

GARCH(p,q)
Generalized ARCH

$$\sigma_t^2 = \omega + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{i=1}^p \beta_i \sigma_{t-i}^2$$

Tim Bollerslev: "Generalized Autoregressive Conditional Heteroskedasticity," Journal of Econometrics 31(3): 307–327, 1986



Modelos estadísticos



Los modelos ARCH/GARCH proporcionan una buena descripción de dos características de las series temporales en finanzas:

- Volatilidad cambiante en el tiempo
- Distribuciones leptocúrticas
(colas más gruesas que en una distribución normal)

Sin embargo, la descripción de la varianza en términos de cuadrados no tiene en cuenta el signo de los cambios, cuando se ha observado que existen asimetrías en la correlación entre la volatilidad actual y los valores pasados de una serie (shocks positivos/negativos), p.ej. en los retornos de activos financieros.



Modelos estadísticos



Variantes que rompen la simetría de GARCH:

- **EGARCH** [Exponential GARCH]

Daniel B. Nelson: "Conditional Heteroskedasticity in Asset Returns: A New Approach," *Econometrica*, 59(2):347–370, 1991

- **QGARCH** [Quadratic GARCH]

Enrique Sentana: "Quadratic ARCH Models," *Review of Economic Studies*, 62(4):639-661, 1995

- **TGARCH** [Threshold GARCH]

Jean-Michel Zakoian: "Threshold heteroskedastic models," *Journal of Economic Dynamics and Control*, 18(5):931-955, 1994


- ...




Bibliografía



- Philipp K. Janert:
**Data Analysis
with Open Source Tools**
O'Reilly, 2010.
ISBN 0596802358
Part I - Graphics: Looking at Data



- Jiawei Han
& Micheline Kamber:
**Data Mining:
Concepts and Techniques**
2nd edition, Morgan Kaufmann, 2006.
ISBN 1558609016
8.2 Mining Time-Series Data



Bibliografía



- Kenneth J. Winston:
**Quantitative Risk and
Portfolio Management:
Theory and Practice**
Cambridge University Press, 2023
ISBN 1009209043
<https://doi.org/10.1017/9781009209090>

