




Prácticas de Series

Práctica 4 de series:


Metodología Box-Jenkins

1. Análisis descriptivo. Se trata de hacer estacionaria la serie, en caso de que no lo sea, mediante diferencias o transformaciones de los datos (logaritmos, Box-Cox, ...)

IBM:



Tiene tendencia. Se toma una diferencia:



La serie con una diferencia es estacionaria. Una serie a la que se le ha tomado una diferencia regular se representa mediante una ∇ . La serie IBM con una diferencia será, por tanto, ∇ IBM.

2. Identificación del modelo ARIMA


la FAS presenta un solo palo positivo significativo. La FAP presenta dos palos. El primero positivo y el segundo negativo. La estructura podría corresponder a la de un modelo MA(1) con $\theta < 0$.

Ajustaremos por tanto un modelo ARIMA(0,1,1). Es decir no tiene parte autorregresiva, hay que tomar una diferencia para que la serie sea estacionaria y, una vez estacionaria, sigue un MA(1).


3. Estimación del modelo

Una vez identificada la serie, es decir, cuando se conoce el modelo ARIMA (p,d,q) que puede seguir, es preciso estimar los parámetros. Esto lo hace el ordenador:

- Vamos a Special-Time Series Analysis-Forecasting.
- Se pone IBM en DATA. Se pincha OK.



- Se aprieta el botón derecho del ratón y se selecciona Analysis Options:
- Se pincha en ARIMA Model.
- Se iluminan algunos recuadros:



- Se selecciona ARIMA MODEL
- Automáticamente se iluminan los recuadros correspondientes al orden del AR, MA y diferencia:

Model Specification Options

Model

☒ A
☐ B
☐ C
☐ D
☐ E

Math

☒ None ☐ Power:
☐ Natural log ☐ Box-Cox
☐ Base 10 log ☐ Square root Power:
☐ Reciprocal Addend:

Inflation

Apply at:
☒ End of Period
☐ Middle of Period
Rate: %

Type

☐ None ☐ Moving Average
☐ Random Walk ☐ Simple Exp. Smoothing
☐ Mean ☐ Brown's Linear Exp. Smoothing
☐ Linear Trend ☐ Holt's Linear Exp. Smoothing
☐ Quadratic Trend ☐ Quadratic Exp. Smoothing
☐ Exponential Trend ☐ Winter's Exp. Smoothing
☐ S-Curve ☒ **ARIMA Model**

Parameters and Terms

Alpha: Order:
Beta: AR: MA:
Gamma: SAR: SMA:
☒ Optimize
☒ Constant

Seasonal

☒ None
☐ Multiplicative
☐ Additive

Differencing

Nonseasonal Order: Seasonal Order:

- Se introducen estos valores, que en el caso de IBM son ARIMA(0,1,1)

- de ahí se obtiene la tabla de resultados:

ARIMA Model Summary				
Parameter	Estimate	Std. Error	t	P-value
MA(1)	-0,270708	0,0908496	-2,97974	0,003509
Mean	1,12023	0,583698	1,91919	0,057396
Constant	1,12023			

Backforecasting: yes
 Estimated white noise variance = 25,9011 with 117 degrees of freedom
 Estimated white noise standard deviation = 5,08931
 Number of iterations: 2

que indica que $\hat{\theta} = -0.27$ con un estadístico $t = -2.98$. Podemos concluir por tanto que el parámetro θ es significativamente distinto de cero, ya que su t es mayor que dos en valor absoluto y su p -valor menor que 0.05.

El modelo equivale a:

$$\nabla \text{IBM}_t = a_t + 0.27 a_{t-1}$$

Std. Error (0.09)
 T (-2.97)

El ajuste indica que θ es significativamente distinta de 0, ya que la t es mayor que 2 en valor absoluto.

Si hubiésemos estimado un MA(2), la ecuación obtenida habría sido:

$$\nabla \text{IBM}_t = a_t + 0.23 a_{t-1} - 0.07 a_{t-2}$$

Std. Error	(0.09)	(0.09)
T	(-2.46)	(0.75)

que indica que θ_2 no es significativa.

El proceso de estimación consiste en encontrar los valores numéricos para los parámetros que mejor se ajusten a nuestros datos. En nuestro caso vemos que ∇IBM sigue un modelo MA(1). Al probar el MA(2) el valor de θ_2 no sale significativo. Esto equivale a pensar que θ_2 vale realmente cero: $\theta_2=0$.


4. Diagnóstico del modelo

El ajuste de un modelo ARIMA (p,d,q) implica cumplir satisfactoriamente la etapa de identificación del modelo. Si una serie está bien identificada, y se le ajusta el modelo correcto, los residuos de la serie deben carecer completamente de estructura.


Como se ha visto anteriormente, una serie sin estructura de dependencia es, precisamente, el ruido blanco

La diagnosis de modelos ARIMA se base en este hecho: Si la serie está bien ajustada, sus residuos deben ser ruido blanco. Así, tras ajustar un modelo y comprobar la significatividad de los coeficientes realizaremos la diagnosis del mismo basada en:


1. FAS y FAP de los residuos. Si la serie está bien ajustada, la FAS y la FAP de los residuos debe ser nula. En la práctica debemos comprobar que los palos de las funciones no son significativos.
 2. Test de no significatividad de los palos de la FAS y la FAP. El test de Box-Pierce proporciona información sobre si los primeros palos de la función de autocorrelación simple de los residuos son cero o no
 3. Test de rachas y estructuras extrañas en los residuos.
- Cuando se obtienen los resultados de la estimación se pincha en el icono de gráficos:




- Se obtiene un menú y se seleccionan FA y FAP de los residuos:




- Se obtiene:



- Clikeando sobre cualquier e los gráficos se puede agrandar. Así podemos comprobar si nuestro modelo es adecuado.
- Test de Box Pierce: se pincha en el icono amarillo de Tabular Options




- Se obtiene el menú de Tabular Options y se selecciona Residual Test for Randomness:



El resultado es una sucesión de tests sobre los residuos, que tratan de comprobar que sean ruido blanco. La interpretación del test de Box-Pierce es más favorable al ruido blanco cuanto mayor sea el p-valor. Si se utiliza el nivel de confianza habitual del 95%, pensaremos que los residuos son ruido blanco siempre que el p-valor sea superior a 0.05.

En nuestro caso se ha obtenido:

FAS y la FAP de los residuos del modelo ARIMA(0,1,1) para IBM. En ellas puede apreciarse que los palos no son significativos, por lo que podemos aceptar que los residuos son ruido blanco.




El test de Box-Pierce aplicado a los 24 primeros palos de las FAS de los residuos da un valor de 18.63 con un p-valor de 0.72. Este resultado debe interpretarse como que no hay evidencia para rechazar que los residuos sean ruido blanco. El test de Box-Pierce indica problemas cuando el p-valor se hace menor de 0.05. Cuanto mayor sea, hay más evidencia a favor de que los residuos son ruido blanco.

Finalmente los test de rachas no indican nada anormal en los residuos. Podemos por tanto asumir que el modelo ARIMA (0, 1, 1) es adecuado para modelizar los datos de IBM.


5. Predicciones

La predicción en Statgraphics es muy sencilla.

En el input panel hay que introducir el número de predicciones que se desean:




- Una vez que tenemos el resultado, en el menú de Tabular Options (Icono Amarillo) se elige Forecast Table



El resultado es una tabla en la que:

- Para las observaciones pasadas de la serie proporciona la predicción que se hubiera obtenido si la serie se hubiera terminado allí.
- Para las observaciones futuras, muestra esa predicción y los límites de confianza. Los límites de confianza indican la zona en la razonablemente estará la futura observación. Estos límites se van haciendo más anchos a medida que hacemos predicciones más alejadas en el tiempo.

Se obtiene además un gráfico con las predicciones:



Ejercicio a entregar:

El fichero de datos que se va a usar es ***practica 4 de series.sf3*** Analizar todas las series y ajustar los modelos correspondientes. Entregar una lista con los modelos adecuados para las 7 series simuladas (Col1-Col7) y para el indice Nikkei de la bolsa de Tokio, Los nacidos en España y el indicador de liderazgo.