



Universidad
Zaragoza

Trabajo Fin de Grado

Título del trabajo:

Métodos estadísticos de valoración del

Autor

Tamara Llorente Martín

Director

Manuel Salvador Figueras

Facultad de Economía y Empresa

2017

Métodos estadísticos de valoración del riesgo de mercado en series financieras (Anexos)

Statistical methods of valuation of market risk in Financial Series

Contenido

Anexo I : Identificación ARMA-GARCH (Método econométrico).....	3
A.I.1. Resultados serie Meliá Hotels.....	4
A.I.2. Resultados serie Nikkei225.....	8
A.I.3 Resultados serie EUR/USD	11
Anexo II: Programa informático.....	14

Anexo I : Identificación ARMA-GARCH (Método econométrico)

En lo que se refiere a la identificación del modelo ARIMA de cada serie, empezaré por un análisis de estacionariedad. Que una serie temporal sea estacionaria significa que su media y su varianza son constantes en el tiempo. Para garantizar la estacionariedad en varianza utilizaré logaritmos y en caso de que no sea estacionaria en media, diferenciaré tantas veces como sea necesario.

En el análisis emplearé como herramientas los correlogramas (ACF y PACF), el contraste individual de autocorrelaciones, el conjunto de Box-Ljung, el contraste aumentado de Dickey-Fuller y el KPSS. El correlograma es la gráfica de las autocorrelaciones muestrales que se emplea para contrastar su independencia, ya que los coeficientes de autocorrelación serán próximos a cero si las observaciones son independientes. El contraste individualizado de autocorrelación comprueba uno por uno que los coeficientes de correlación sean estadísticamente iguales a 0. El test de Box-Ljung consiste en aceptar o rechazar la hipótesis de que todas las autocorrelaciones son 0, es decir, si se trata de un ruido blanco. El contraste de Dickey-Fuller Aumentado tiene como hipótesis nula la no estacionariedad y como hipótesis alternativa la estacionariedad, cuanto más negativo sea su estadístico más rechazaré H_0 (cola por la izquierda). El último test de estacionariedad, el KPSS, presenta la hipótesis nula de que la serie es estacionaria y la hipótesis alternativa de que es un paseo aleatorio.

Una vez escogida la serie estacionaria, identificaré y estimaré el modelo ARIMA con el que se corresponde. De nuevo comenzaré estudiando los correlogramas y luego aplicaré el criterio de selección de modelos BIC. El BIC es una estimación de la variación no explicada en la variable dependiente, por lo tanto el mejor modelo será el que menor BIC tenga.

Segundo, para identificar el modelo ARMA-GARCH y estimarlo tendré en cuenta los distintos tipos de modelos GARCH siempre con el objetivo de hallar el resultado más preciso.

Los modelos GARCH son aquellos que toman volatilidades pasadas para medir la volatilidad. Podemos identificar el modelo a partir de los correlogramas de los

residuos hallados anteriormente, observando los retardos que sobresalen de las bandas de confianza tanto en el AFC como en el PAFC. Lo más probable es que este método no arroje ningún resultado claro así que también usaré el BIC, que ya apareció en la identificación del modelo ARFIMA.

En lo que se refiere al análisis del efecto asimétrico, es fundamental si es que la serie sigue una distribución asimétrica. Los modelos GARCH sirven para modelar series con bloques de volatilidad pero otorgan la misma importancia al efecto de las rentabilidades positivas y negativas en la volatilidad (no ajustan el efecto palanca). Para cubrir esta deficiencia están los modelos EGARCH y GJRARCH.

Los GARCH Exponenciales son un efecto expansivo de los modelos GARCH tradicionales en donde los parámetros deben ser positivos, lo cual lleva a un efecto creciente en la estimación a futuro que produce dificultades en la estimación. Los GJRARCH o GARCH por umbrales, que están comprendidos dentro de los TGARCH, modelan la varianza condicional dividiendo la distribución de los shocks en intervalos disjuntos.

A.I.1. Resultados serie Meliá Hotels

El primer paso va a ser comprobar si la serie original, la de los precios de mercado, es estacionaria. Si se tratase de una serie estacionaria, el ACF debería decaer de forma notable y el PACF mostraría unos primeros retardos altos que caerían poco a poco hasta quedar entre las bandas de confianza del 95%.

Para ello tomo los logaritmos de las cotizaciones y los represento en la Figura 12 para ver si oscilan en torno a una cifra concreta a la vez que dibujo el correlograma y el correlograma parcial.

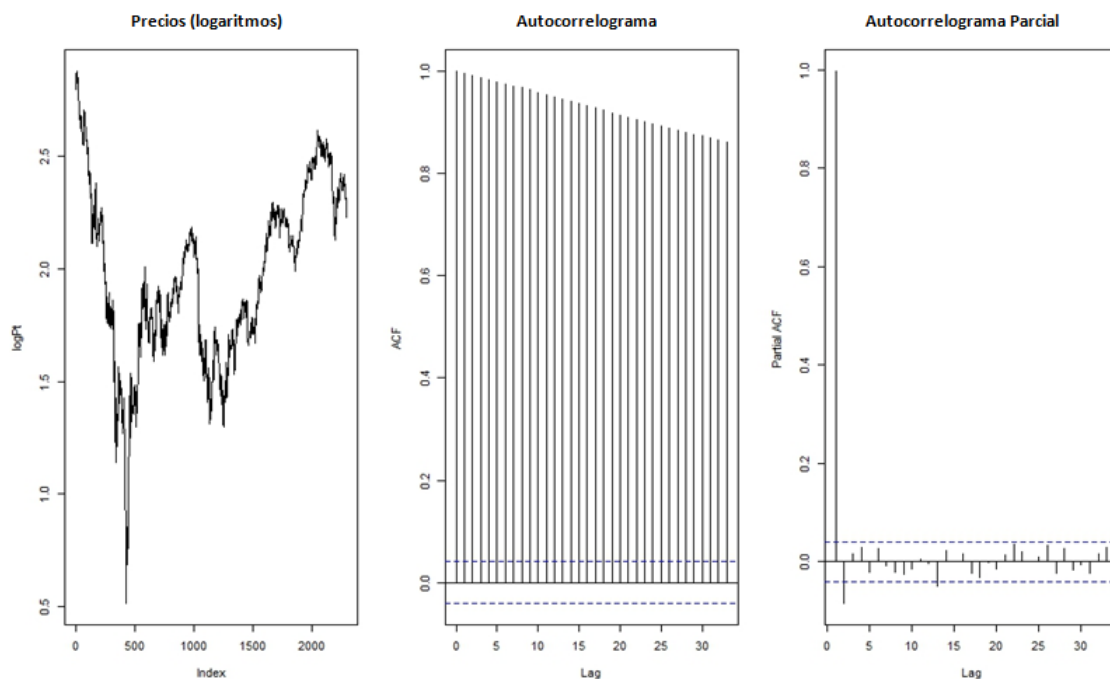


Figura 12: Serie y correlogramas de los precios de Meliá Hotels

En el correlograma parcial destaca especialmente el primer retardo. Otras correlaciones significativas son la 2 y la 13, lo cual significaría que la cotización actual de la divisa depende de la del día anterior y en menor medida de la de hace 2 y 13 días.

El contraste individualizado de autocorrelación comprueba uno por uno que los coeficientes de correlación sean o no estadísticamente iguales a 0. Aquí señala exactamente lo mismo dado que los coeficientes 1,2 y 13 son mayores a 1,96 (el percentil para un nivel de significación del 5%).

Al observarlos en conjunto, los gráficos no cumplen con las premisas de estacionariedad mencionadas anteriormente, no obstante realizaré el contraste de Box-Ljung y los contrastes de raíces unitarias Dickey-Fuller y KPSS para cerciorarlo.

El contraste de Box-Ljung ofrece un pvalor que es prácticamente 0, consecuentemente rechazamos H_0 . De las nueve primeras correlaciones una o varias son distintas de 0, por lo que ya no es necesario ampliar el análisis de Box-Ljung hasta el retardo 12.

Por su parte el contraste aumentado de Dickey-Fuller tanto con constante como sin constante resulta en un pvalor excesivo, 0.29 si es con constante y 0.43 si es sin

constante, lo que llevaría a aceptar la hipótesis nula (aceptamos que no es una serie estacionaria).

El test KPSS se puede hacer con tendencia o sin ella. En este caso lo hacemos sin tendencia porque al observar el dibujo de la serie se ve que no la hay. De nuevo el pvalor es $0.01 < 0.05$ por lo cual rechazo H_0 y obtengo el mismo resultado que con los otros test, que se trata de una serie no estacionaria.

Ante esta situación diferencio la serie una vez tomando la serie de rentabilidades diarias y llevo a cabo el mismo estudio de estacionariedad realizado con la serie de cotizaciones.

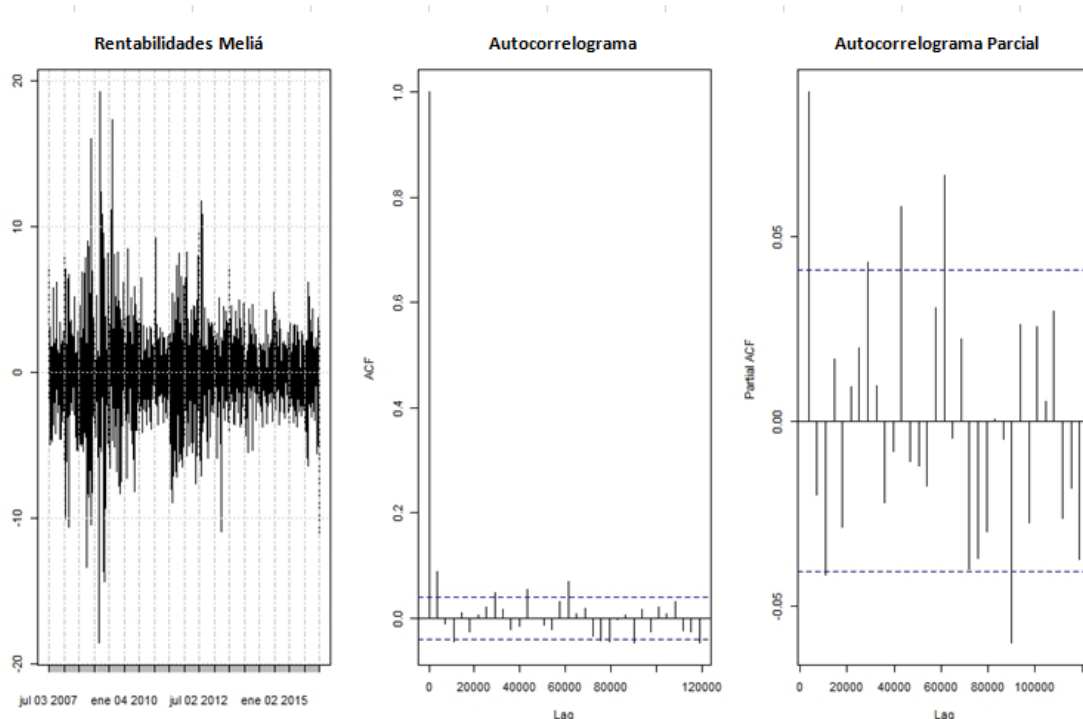


Figura 13: Rentabilidades y correlogramas Meliá Hotels

En esta ocasión la representación de la serie (Figura 13) se muestra más clara en cuanto a media y varianza. El ACF después del primer retardo (siempre va a ser 1) pasa a valores pequeños aunque los coeficientes de correlación 1, 3, 8 y 12 sobrepasan las bandas de significación tal y como vuelve a pasar en el PACF.

El contraste individual de autocorrelación conduce al mismo resultado, coeficientes superiores a 1,96 en las autocorrelaciones y las autocorrelaciones parciales.

El contraste conjunto de autocorrelaciones BL arroja un pvalor menor a 0.01 (0.0001). Rechazo la hipótesis nula de que las primeras 9 correlaciones son 0 y por tanto la serie no es un ruido blanco, no es estacionaria.

Sin embargo, esta vez el contraste de Dickey-Fuller Aumentado con constante y sin constante nos da las mismas cifras. El estadístico es -20.87 en ambos casos y el pvalor 0.01. Rechazo H_0 , que la serie no sea estacionaria.

Por último, el contraste KPSS sin tendencia ofrece un pvalor elevado (0.1) que impide rechazar H_0 apuntando que la serie de rentabilidades diarias es estacionaria.

Dados estos resultados, a partir de este punto voy a trabajar con la serie opuesta de rentabilidades continuas, ya que si la serie de rentabilidades normales es estacionaria la opuesta también lo será.

Pruebo con el criterio BIC en distintos tipos de distribuciones (Normal, normal asimétrica, t Student y t Student asimétrica) incluyendo o no constante para ver cuál es la más adecuada y la conclusión es que la t Student sin constante es la que mejor ajusta la serie tal y como muestra la Tabla 18.

$$r_t = 0.03519\varepsilon_{t-1} + \varepsilon_t$$

Tabla 18: Modelos ARMA y sus BIC según el tipo de distribución

Distribución	Con media		Sin media	
	Modelo	BIC	Modelo	BIC
Normal	ARIMA(0,0,1)	4.7678	ARIMA(0,0,1)	4.7647
Normal asimétrica	ARIMA(0,0,1)	4.7709	ARIMA(0,0,1)	4.7678
t Student	ARIMA(0,0,0)	4.5664	ARIMA(0,0,1)	4.565
t Student asimétrica	ARIMA(0,0,0)	4.5687	ARIMA(0,0,1)	4.5675

Continúo con la identificación del modelo GARCH. Voy a utilizar el GARCH(1,1) porque es el más robusto en series financieras. Comparando los BIC, la Tabla 19 señala que el más exacto es el EGARCH(1,1). Tiene sentido porque, al contrario que los modelos GARCH, los EGARCH son capaces de explicar la covarianza entre ε_{t-j} y ε_t^2 expresando la varianza condicional como una función asimétrica de los residuos ε_{t-j} .

Tabla 19: Modelos ARMA-GARCHy sus BIC correspondientes

Modelo	BIC
ARMA(0,1)-GARCH(1,1)	4.4098
ARMA(0,1)-GJR(1,1)	4.4028
ARMA(0,1)-EGARCH(1,1)	4.3968

La ecuación del modelo ARMA(0,1)-GARCH(1,1) es:

$$r_t = 0.0191\varepsilon_{t-1} + \varepsilon_t$$

$$z_t = \sqrt{\sigma_t^2} \varepsilon_t \sim std(0, 1, 6.1984)$$

$$\ln(\sigma_t^2) = 0.0143 + 0.0646z_{t-1}^2 + 0.1157(|z_t| + E(|z_t|)) + 0.9907\ln(\sigma_{t-1}^2)$$

Donde $0.0646z_{t-1}^2 + 0.1157(|z_t| + E(|z_t|))$ es la función de respuesta asimétrica. Dependiendo del signo de z_t será una función lineal con tendencia $0.0646+0.1157(z_t \text{ positiva})$ o una función lineal con tendencia $0.0646-0.1157 (z_t \text{ negativa})$.

A.I.2. Resultados serie Nikkei225

Los correlogramas de los precios del Nikkei225 en la Figura 14 muestran claramente que no es una serie estacionaria, al igual que los contrastes individualizados de autocorrelación. Por consiguiente suponemos que los test tendrán la misma contundencia.

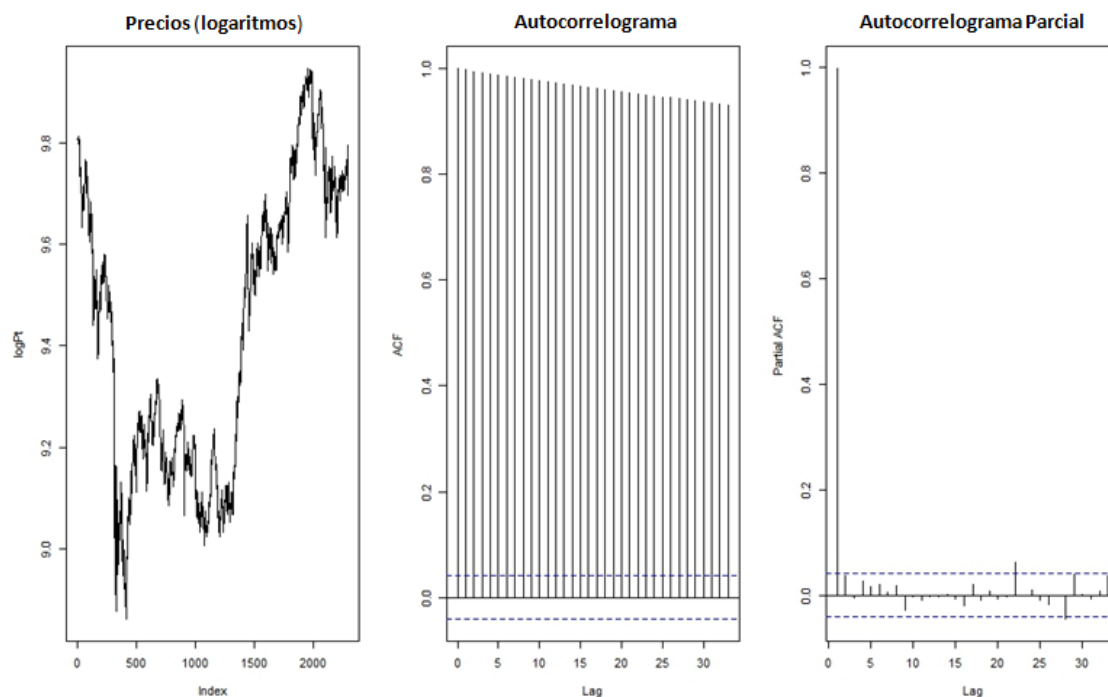


Figura 14: Serie y correlogramas de las cotizaciones del Nikkei225

El contraste de Box-Ljung tiene pvalor 0, rechazo la hipótesis nula de que todas las autocorrelaciones son 0.

El test de Dickey-Fuller, al igual que en Meliá Hotels, cuenta con unos pvalores extremadamente altos tanto si se aplica suponiendo la presencia de una constante como si no. Los pvalores son 0.57 y 0.59 respectivamente. De acuerdo a lo anterior, la serie no es estacionaria.

Finalmente, el test de KPSS apunta a que se trata de un paseo aleatorio (pvalor 0.01).

El siguiente paso es hallar las rentabilidades continuas. Esta vez sus correlogramas son mucho más favorables al supuesto de estacionariedad.

Tanto en la Figura 15 como en el contraste individualizado de autocorrelación el primer retardo es significativo. En principio la rentabilidad del Nikkei de un día para otro depende de la del día anterior.

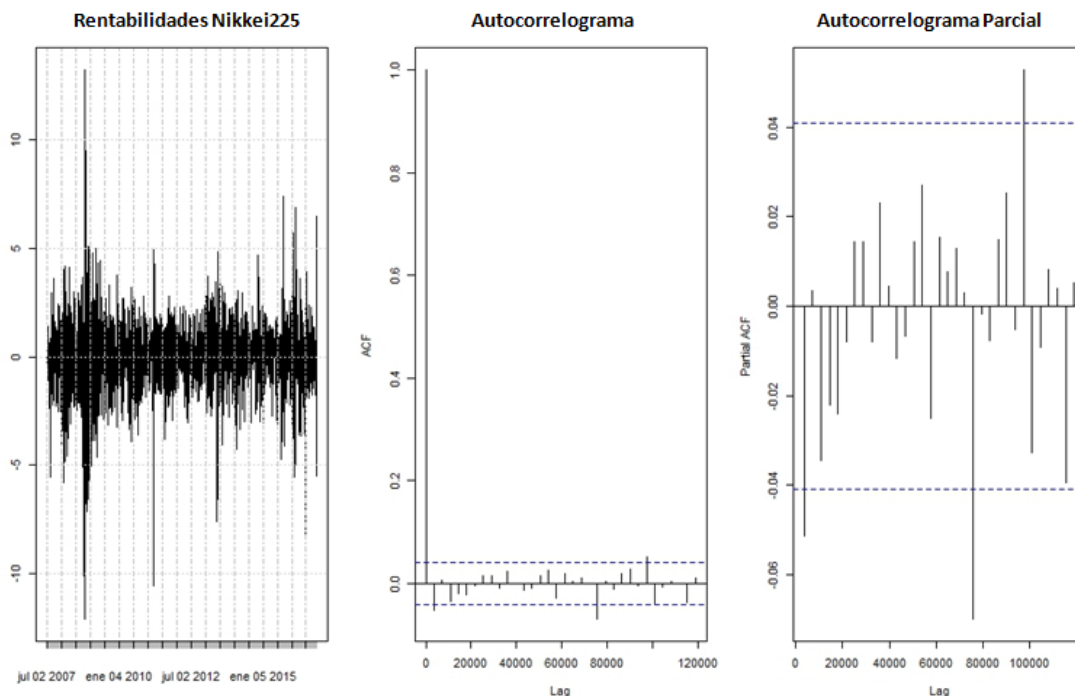


Figura 15: Rentabilidades diarias y correlogramas del Nikkei225

El contraste de BL indica que, al menos, las 9 primeras autocorrelaciones son distintas de 0 (pvalor 0.20).

El pvalor de DF en los dos supuestos es 0.01. Rechazamos H_0 , o lo que es lo mismo, la serie es estacionaria.

El test KPSS sin tendencia refuerza los anteriores con un pvalor de 0.07 que obliga a aceptar H_0 .

El hecho de que sólo haya un retardo significativo en los correlogramas parece indicar que el modelo ARMA vaya a ser un AR(1) o MA(1). Para averiguarlo utilizo el BIC y la respuesta es un AR(1) sin media que sigue una distribución t Student asimétrica (Tabla 20).

$$r_t = -0.0545r_{t-1} + \varepsilon_t$$

Tabla 20: Modelos ARMA y sus BIC según el tipo de distribución

Distribución	Con media		Sin media	
	Modelo	BIC	Modelo	BIC
Normal	ARIMA(0,0,0)	3.8355	ARIMA(1,0,0)	3.8331
Normal asimétrica	ARIMA(0,0,1)	3.8299	ARIMA(0,0,1)	3.8269
t Student	ARIMA(0,0,0)	3.6370	ARIMA(1,0,0)	3.6365
t Student asimétrica	ARIMA(0,0,0)	3.638	ARIMA(0,0,1)	3.6350

De nuevo aplico el BIC a los tres tipos de modelos GARCH estudiados y el mejor vuelve a ser el EGARCH(1,1) de acuerdo a la Tabla 21.

Tabla 21: Modelos ARMA-GARCHy sus BIC correspondientes

Modelo	BIC
ARMA(0,1)-GARCH(1,1)	3.4909
ARMA(0,1)-GJRGARCH(1,1)	3.4726
ARMA(0,1)-EGARCH(1,1)	3.4633

La fórmula con la cual realizaré las predicciones viene expresada de la siguiente manera:

$$r_t = -0.0278\varepsilon_{t-1} + \varepsilon_t$$

$$z_t = \sqrt{\sigma^2 \varepsilon_t} z_t \sim std(0, 1, 1.1308, 9.4732)$$

$$\ln(\sigma_t^2) = 0.0244 + 0.1226z_{t-1}^2 + 0.1858(|z_t| + E(|z_t|)) + 0.9635\ln(\sigma_{t-1}^2)$$

A.I.3 Resultados serie EUR/USD

Los autocorrelogramas de los logaritmos de los precios son muy similares a los de las otras dos series con la particularidad de que en el autocorrelograma parcial sólo hay un retardo que sobrepasa los límites. Ver Figura 16.

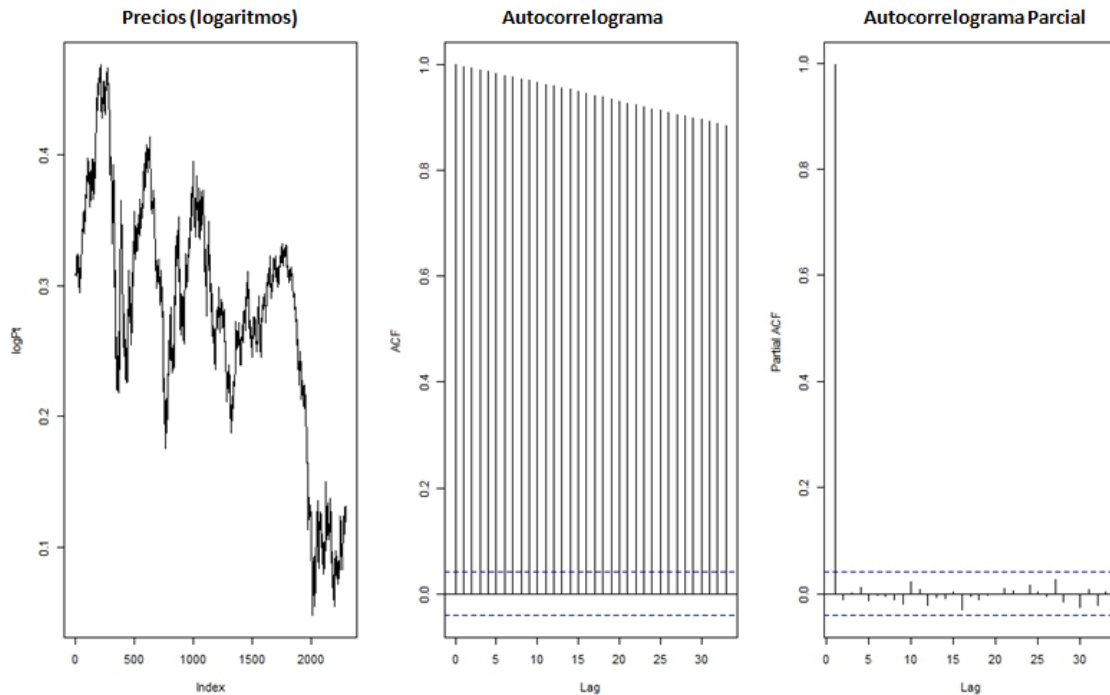


Figura 16: Serie y correlogramas de las cotizaciones del EUR/USD

Los tres contrastes de estacionariedad dicen que el EUR/USD no es estacionario. Box-Ljung ofrece un pvalor de 0 por lo cual rechazo H_0 , DickeyFuller con y sin constante lleva a aceptar H_0 (pvalor 0.54 y 0.30 respectivamente), y el pvalor de KPSS es 0.01 por lo que no puedo aceptar el supuesto de estacionariedad.

Por tanto paso a trabajar con la serie de variaciones diarias del EUR/USD.

La Figura 17 y los contrastes individualizados de autocorrelaciones muestran que muy posiblemente es un proceso ARMA estacionario de orden (0,0) porque ningún retardo sobrepasa las bandas de confianza ni hay coeficientes de autocorrelación que superen 1.96.

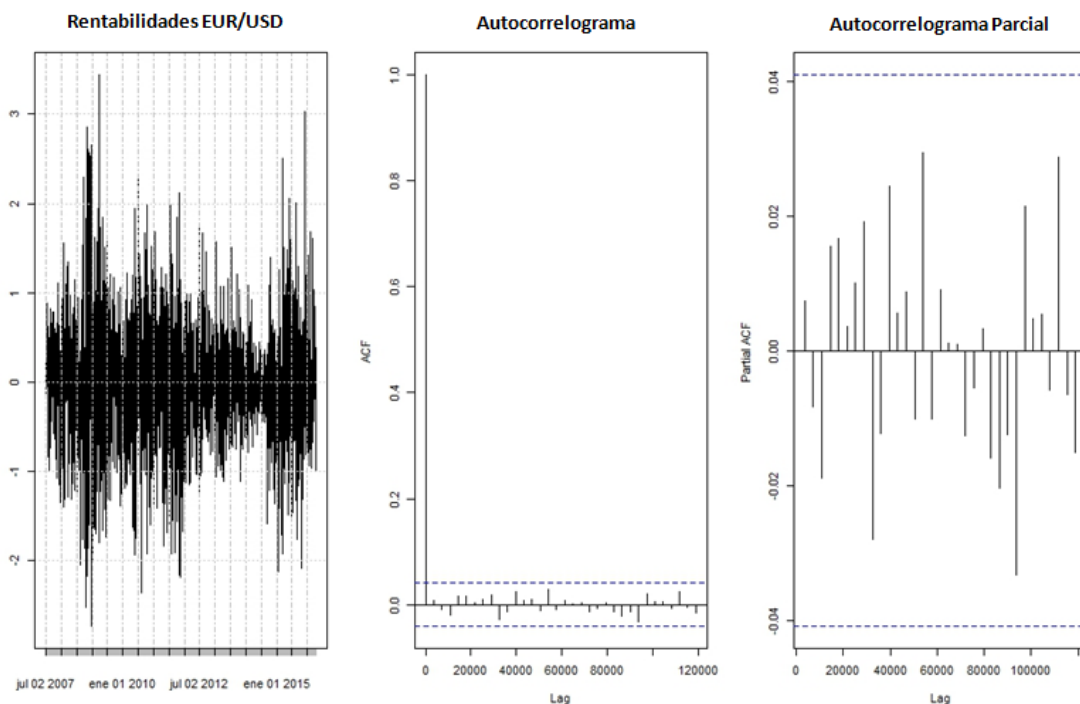


Figura 17: Rentabilidades diarias y correlogramas del EUR/USD

En esta ocasión, los tres test coinciden en que sí es una serie estacionaria. Por un lado, BL y KPSS conducen a aceptar H_0 con pvalores de 0.82 y 0.1, y por otro lado, DF rechaza totalmente H_0 ya que su pvalor en las dos variantes es 0.01.

Tras probar el BIC, la Tabla 22 indica que el resultado es que la mejor opción es un ARMA(0,1) que sigue una distribución t Student asimétrica.

$$r_t = -0.0244\varepsilon_t + \varepsilon_t$$

Tabla 22: Modelos ARMA y sus BIC según el tipo de distribución

Distribución	Con media		Sin media	
	Modelo	BIC	Modelo	BIC
Normal	ARIMA(0,0,0)	1.9582	ARIMA(0,0,1)	1.9583
Normal asimétrica	ARIMA(0,0,0)	1.9641	ARIMA(0,0,1)	1.9612
t Student	ARIMA(0,0,0)	1.8887	ARIMA(0,0,1)	1.8882
t Student asimétrica	ARIMA(0,0,0)	1.891	ARIMA(0,0,1)	1.8907

Según los resultados de la Tabla 23 el mejor valor BIC se corresponde a un EGARCH(1,1) de forma:

$$r_t = -0.0199r_{t-1} + \varepsilon_t$$

$$z_t = \sqrt{\sigma^2} \varepsilon_t z_t \sim std(0, 1, 8.0784)$$

$$\ln(\sigma_t^2) = -0.0039 + 0.0276z_{t-1}^2 + 0.0778(|z_t| + E(|z_t|)) + 0.9963\ln(\sigma_{t-1}^2)$$

Tabla 23: Modelos ARMA-GARCHy sus BIC correspondientes

Modelo	BIC
ARMA(0,1)-GARCH(1,1)	1.7636
ARMA(0,1)-GJRARCH(1,1)	1.7623
ARMA(0,1)-EGARCH(1,1)	1.7621

Anexo II: Programa informático

En este Anexo se muestran los listados de los programas utilizados en el trabajo.
El paquete estadístico utilizado ha sido R 3.3.3.

Me he servido de Maldonado (2017), Stephenson, McNeil y Pfaff (2012), Stephenson, McNeil y Wuertz (2013), Alonso y Semaán(2009).

Por evitar las repeticiones aparecerá únicamente el ejemplo de Meliá Hotels.

A.II.1 Lectura de datos

```
library(quantmod)
library(readxl)
library(timeSeries)
library(PerformanceAnalytics)
library(evir)
library(BSDA)
library(car)
library(fBasics)
#MELIÁ
Accion =read_excel("Accion.xlsx",col_names=TRUE)
ohlcv<- function(ttime,tprice) {
  ttime.int <- format(ttime)
  data.frame(
    Melia = tapply(tprice,ttime.int,function(x) {head(x,1)}))
  }
  Datos=ohlcv(Accion$Fecha,as.numeric(Accion$Melia))
  Pt=Datos$Melia
  rt.melia=100*periodReturn(Pt,period="daily",type="log")
  xt=-rt.melia
#NIKKEI225
Indice =read_excel("Indice.xlsx",col_names=TRUE)
ohlcv<- function(ttime,tprice) {
  ttime.int <- format(ttime)
  data.frame(
    Nikkei225 = tapply(tprice,ttime.int,function(x) {head(x,1)}))
```

```
}  
Datos=ohlc(Indice$Fecha,as.numeric(Indice$Nikkei225))  
Pt=Datos$Nikkei225  
rt.nikkei=100*periodReturn(Pt,period="daily",type="log")  
xt=-rt.nikkei  
#USD/EUR  
Tipodecambio =read_excel("Tipodecambio.xlsx",col_names=TRUE)  
ohlc<- function(ttime,tprice) {  
  ttime.int <- format(ttime)  
  data.frame(  
    EURUSD = tapply(tprice,ttime.int,function(x) {head(x,1)}))  
  }  
  Datos=ohlc(Tipodecambio$Fecha,as.numeric(Tipodecambio$EURUSD))  
  Pt=Datos$EURUSD  
  rt.usd=100*periodReturn(Pt,period="daily",type="log")  
  xt=-rt.usd
```

A.II.2. Estudio descriptivo básico (igual para todos los activos)

```
m=as.numeric(xt$daily.returns)  
mean(rt.melia)  
var(rt.melia)  
stdev(rt.melia)  
min(rt.melia)  
max(rt.melia)  
quantile(rt.melia,prob=0.5,na.rm=TRUE)  
quantile(rt.melia,prob=0.25,na.rm=TRUE)  
quantile(rt.melia,prob=0.75,na.rm=TRUE)  
skewness(rt.melia)  
kurtosis(rt.melia)  
max(Pt)  
min(Pt)
```

A.II.3. Método histórico (Ejemplo Meliá)

```
# nest: tamaño de muestra de estimacion
# nval: tamaño de la muestra de validacion
# n0: periodo inicial del periodo de validacion
# VaRhistorico: Valor de riesgo historico
# VaRHill: VaR con el estimador de Hill
# VaRReg: VaR con el método de regresión descrito en Ruppert en la sección 11.2.4
```

```
nval = 252*2
n0 = length(m)-nval
alfa = 0.05
VaRhistorico=numeric(nval)
EShistorico= VaRhistorico
redinf= VaRhistorico
redsup= VaRhistorico
# Cálculo del VaR Histórico y de la ES
for(j in n0:(n0+nval-1)){
  serie=m[1:j]
  VaRhistorico[j-n0+1]=quantile(serie, probs = 1-alfa)
  sxt=sort(serie)
  redinf[j-n0+1]=round(((1-alfa)*length(serie))
  redsup[j-n0+1]=round(((1-alfa)*length(serie))+1)
  EShistorico[j-n0+1]=sum(sxt[redsup[j-n0+1]:length(serie)]/(length(serie)-
  redinf[j-n0+1]))
}
```

A.II.4. Estimador de Hill

```
source("E:\\Análisis estadístico\\TFG\\Acción\\Hill.R")
psi = numeric(nval)
psi1 = psi
for(i in 1:nval){
  # Estimacion del parámetro psi mediante Hill
  psi[i] = Hill(m[1:(n0+i-1)],bloque)$est
}
```



```
# Cálculo del VaR de Hill
alfahill=1/psi
multiplo= (1-alfa/alfahill)^psi
VaRHill=multiplo*VaRhistorico
```

A.II.5 Block Maxima Method

```
VaRBMM=numeric(nval)
n = 21
bloque = round((length(m)-nval)/n)
parametros_BMM = matrix(0,nval,3)
for(i in 1:nval){
  # Estimación de los parámetros del método BOM
  serie = m[1:(n0+i-1)]
  aux = gev(serie,n)
  parametros_BMM[i,] = t(as.vector(aux$par.ests))
}

# Cálculo del VaR por el método BMM
xi= parametros_BMM[,1]
sigma = parametros_BMM[,2]
mu = parametros_BMM[,3]
VaRBMM = mu-(sigma/xi)*(1-(-n*log(1-alfa))^-xi))
```

En el caso de bloques de 42 días sólo hay que cambiar $n=21$ por $n=42$.

A.II.6. Método Peak Over Threshold

```
VaRPOT=numeric(nval)
ESPOT=numeric(nval)
threshold = 2;
parametros_POT = matrix(0,nval,4)
for(i in 1:nval){
```

```
# Estimación del los parámetros del método POT
aux = pot(serie,threshold)
parametros_POT[i,] = t(as.vector(aux$par.ests))
# Cálculo del VaR por el método POT
aux = riskmeasures(aux,1-alfa)
VaRPOT[i] = aux[1,2]
ESPOT[i] = aux[1,3]
}
```

Para hacer las estimaciones de los otros umbrales se cambia el número donde pone *threshold*.

A.II.7.Regresión cuantil

```
VaRRC=numeric(nval)
constante=VaRRC
serie1=VaRRC
serie2=VaRRC
coef = matrix(0,nval,3)
for(i in 1:nval){
  rentabilidades = m[1:(n0+i-1)]
  ibex=n[1:(n0+i-1)]
  volatil=vdax[1:(n0+i-1)]
  # Estimación de los parámetros del método de Regresión Cuantil
  mm=rq(rentabilidades~ibex+volatil,tau=0.95,data=Datos)
  summary(mm)
  coef[i,]=coef(mm)

  # Cálculo del VaR por el método Regresión Cuantil
  constante[i]=coef[,1]
  serie1[i]=coef[,2]
  serie2[i]=coef[,3]
```

```
VaRRC[i]=constante+serie1*n[n0+i]+serie2*v dax[n0+i]  
}
```

A.II.8. Método econométrico

```
m=as.numeric(xt$daily.returns)  
serie=m[1:2297]  
precios=Pt[1:2297]  
logPt=log(precios)  
library(tseries)  
library(rugarch)  
library(fUnitRoots)  
rent=rt.melia[1:2297]  
par(mfrow=c(1,3))  
plot(rent,type="l")  
autocorr=acf(rent)  
autocorr.parcial=pacf(rent)  
autocorr=cbind(autocorr$acf,autocorr.parcial$acf)  
colnames(autocorr) = c("Autocorrelaciones","Autocorrelaciones Parciales")  
autocorr  
abs(autocorr[,1]*sqrt(length(rent)))  
abs(autocorr[,2]*sqrt(length(rent)))  
#Contraste ADF  
# Con constante  
a=adfTest(rent,lags=5,type="c")  
a@test  
# Sin constante  
a=adfTest(rent,lags=5,type="nc")  
a@test  
#Contraste KPSS  
# Constraste sin tendencia  
kpss.test(rent,lshort=F)  
#Box-Ljung  
Box.test(rent,lag=round(log(length(rt.diario)))+1,type="Ljung")
```

```
Box.test(rent,lag=round(log(length(rent)))+1,type="Ljung")
```

```
#Normal:
```

```
modelo.seleccion =  
autoarfima(serie,ar.max=4,ma.max=4,method="partial",criterion="BIC",include.mean=  
TRUE)
```

```
modelo.seleccion
```

```
#Normal asimétrica:
```

```
modelo.seleccion =  
autoarfima(serie,ar.max=4,ma.max=4,method="partial",criterion="BIC",distribution.mo  
del = "snorm",include.mean=TRUE)
```

```
modelo.seleccion
```

```
#T de student
```

```
modelo.seleccion =  
autoarfima(serie,ar.max=4,ma.max=4,method="partial",criterion="BIC",distribution.mo  
del = "std",include.mean=TRUE)
```

```
modelo.seleccion
```

```
#T Asimetrica:
```

```
modelo.seleccion =  
autoarfima(serie,ar.max=4,ma.max=4,method="partial",criterion="BIC",distribution.mo  
del = "sstd",include.mean=TRUE)
```

```
modelo.seleccion
```

```
#Normal:
```

```
modelo.seleccion =  
autoarfima(serie,ar.max=5,ma.max=5,method="partial",criterion="BIC",include.mean=  
FALSE)
```

```
modelo.seleccion
```

```
#Normal asimétrica:
```

```
modelo.seleccion =  
autoarfima(serie,ar.max=4,ma.max=4,method="partial",criterion="BIC",distribution.mo  
del = "snorm",include.mean=FALSE)
```

```
modelo.seleccion
```

```
#T de student
```

```
modelo.seleccion =  
autoarfima(serie,ar.max=4,ma.max=4,method="partial",criterion="BIC",distribution.mo  
del = "std",include.mean=FALSE)
```

```
modelo.seleccion
```

```
#T Asimetrica:
```

```
modelo.seleccion =  
autoarfima(serie,ar.max=4,ma.max=4,method="partial",criterion="BIC",distribution.mo  
del = "sstd",include.mean=FALSE)
```

```
modelo.seleccion
```

```
#T de student
```

```
modelo.seleccion =  
autoarfima(serie,ar.max=4,ma.max=4,method="partial",criterion="BIC",distribution.mo  
del = "std",include.mean=FALSE)
```

```
modelo.seleccion
```

```
# Estimación de modelos ARMA(nar,nma)-GARCH(p,q)
```

```
nar=0;nma=1;
```

```
incluye.media = FALSE;
```

```
p=1;q=1;
```

```
media = list(armaOrder=c(nar,nma),include.mean=incluye.media)
```

```
varianza = list(model='sGARCH',garchOrder=c(p,q))
```

```
distribucion = "std"
```

```
spec =
```

```
ugarchspec(mean.model=media,variance.model=varianza,distribution.model=distribuci  
on)
```

```
modelo.estim = ugarchfit(spec,serie)
```

```
modelo.estim
```

```
# Estimación de modelos ARMA(nar,nma)-GJR GARCH(p,q)
```

```
nar=0;nma=1;
```

```
incluye.media = FALSE;
```

```
p=1;q=1;
```

```
media = list(armaOrder=c(nar,nma),include.mean=incluye.media)
```

```
varianza = list(model='gjrGARCH',garchOrder=c(p,q))
```

```
distribucion = "std"
```

```
spec =
```

```
ugarchspec(mean.model=media,variance.model=varianza,distribution.model=distribuci  
on)
```

```
modelo.estim = ugarchfit(spec,serie)
```

```
modelo.estim
```

```
# Estimación de modelos ARMA(nar,nma)-EGARCH(p,q)
serie=m
nar=0;nma=1;
incluye.media = FALSE;
p=1;q=1;
media = list(armaOrder=c(nar,nma),include.mean=incluye.media)
varianza = list(model='eGARCH',garchOrder=c(p,q))
distribucion = "std"
spec
ugarchspec(mean.model=media,variance.model=varianza,distribution.model=distribucion)
modelo.estim = ugarchfit(spec,serie)
modelo.estim

# Predicciones
modelo.rolling=ugarchroll(spec,serie,forecast.length=nval,refit.every=1,refit.window="recursive")
resultados = as.data.frame(modelo.rolling)
serie1 = as.timeSeries(resultados[, 'Realized'])
rownames(serie1) = rownames(tail(serie,nval))
prediccion = as.timeSeries(resultados[, 'Mu'])
rownames(prediccion) = rownames(serie1)
sigmas = as.timeSeries(resultados[, 'Sigma'])
sk = as.timeSeries(resultados[, 'Skew'])
df = as.timeSeries(resultados[, 'Shape'])
VaRGARCH = prediccion + qdist(distribucion,0.95,sigma=sigmas,shape=df,skew=sk)
```

A.II.9. Validación

```
serie1 = as.timeSeries(tail(m,nval))

VaR = VaRhistorico

# Cálculo del test LR_uc
n0 = length(m)-nval
```

```
serie1 = m[(n0+1):(n0+nval)]  
  
n = length(serie1)  
  
It= VaR<serie1  
  
n0 = sum(It)  
  
n1 = n-n0  
  
alfa_tilde = n0/n  
  
LR_uc = n1*log(1-alfa)+n0*log(alfa)  
  
if((n1<n)&(n1>0))  
  
LR_uc = LR_uc-(n1*log(1-alfa_tilde)+n0*log(alfa_tilde))  
  
LR_uc = -2*LR_uc  
  
pvalor_uc = 1-pchisq(LR_uc,1)  
  
pvalor_uc  
  
  
# Cálculo del test de independencia  
  
It1 = as.numeric(head(It,length(It)-1))  
  
It = as.numeric(tail(It,length(It)-1))  
  
n00= sum(It*It1)  
  
n10 =sum((1-It1)*It)  
  
n01 = sum(It1*(1-It))  
  
n11 = sum((1-It1)*(1-It))  
  
p01 = 0  
  
if(n00+n01>0)  
  
    p01 = n01/(n00+n01)  
  
p11=0  
  
if(n11+n10>0)  
  
    p11 = n11/(n11+n10)  
  
  
LR_ind = 0
```

```

if((n1<n)&(n1>0))
  LR_ind = (n1*log(1-alfa_tilde)+n0*log(alfa_tilde))
if(LR_ind!=0){
  if((p01<1)&(p01>0))
    LR_ind = LR_ind - (n00*log(1-p01)+n01*log(p01))
  if((p11<1)&(p11>0))
    LR_ind = LR_ind - (n11*log(p11)+n10*log(1-p11))
}
LR_ind = -2*LR_ind
pvalor_ind = 1-pchisq(LR_ind,1)
pvalor_ind

# Cálculo del test LR_cc
LR_cc = LR_uc+LR_ind
pvalor_cc = 1-pchisq(LR_cc,2)
pvalor_cc

# Cálculo de la pérdida LOSS-GR
loss_gnr= LOSS_GNR(serie1,VaR)
loss_gnre=cbind(loss_gnr)
apply(loss_gnre,2,FUN=mean)

```

Este es el ejemplo del VaR histórico, para el resto de los VaR se hace lo mismo sustituyendo VaRhitorio por el que se quiera.

A.II.10. Dibujo de los VaR

```

serie1 = m[(n0+1):(n0+nval)]
plot(serie1,type='l',col=1,lty=1,ylab='Rentabilidad',ylim=c(-6,7))
lines(VaRhistorico,col=2,lty=1)

```



```
lines(EShistorico,col=2,lty=2)
lines(VaRHill,col=3,lty=1)
lines(VaRBOM,col=6,lty=1)
lines(VaRPOT,col=5,lty=1)
lines(ESPOT,col=5,lty=2)
lines(VaRGARCH,col=8,lty=1)
lines(VaRRC,col=7,lty=1)
lines(VaRBOM42,col=4,lty=1)

legend("bottomright",c('Rentabilidades reales','VaR Histórico','ES Histórico','VaR Hill','VaR
BMM n=21','VaR POT','ES POT','VaR GARCH','VaR Regresión Cuantil','VaR BMM
n=42'),col=c(1,2,2,3,6,5,5,8,7,4),lty=c(1,1,2,1,1,1,2,1,1,1),ncol=2)

title("Serie de rentabilidades, VaRs y ESs")
```