

ECONOMETRÍA

APLICADA UTILIZANDO R.

PAPIME PE302513 LIBRO ELECTRÓNICO Y COMPLEMENTOS DIDÁCTICOS EN MEDIOS COMPUTACIONALES, PARA EL FORTALECIMIENTO DE LA ENSEÑANZA DE LA ECONOMETRÍA

Capítulo 12.

Modelos ARCH

Luis Quintana Romero



1. Una aplicación del modelo ARCH en R

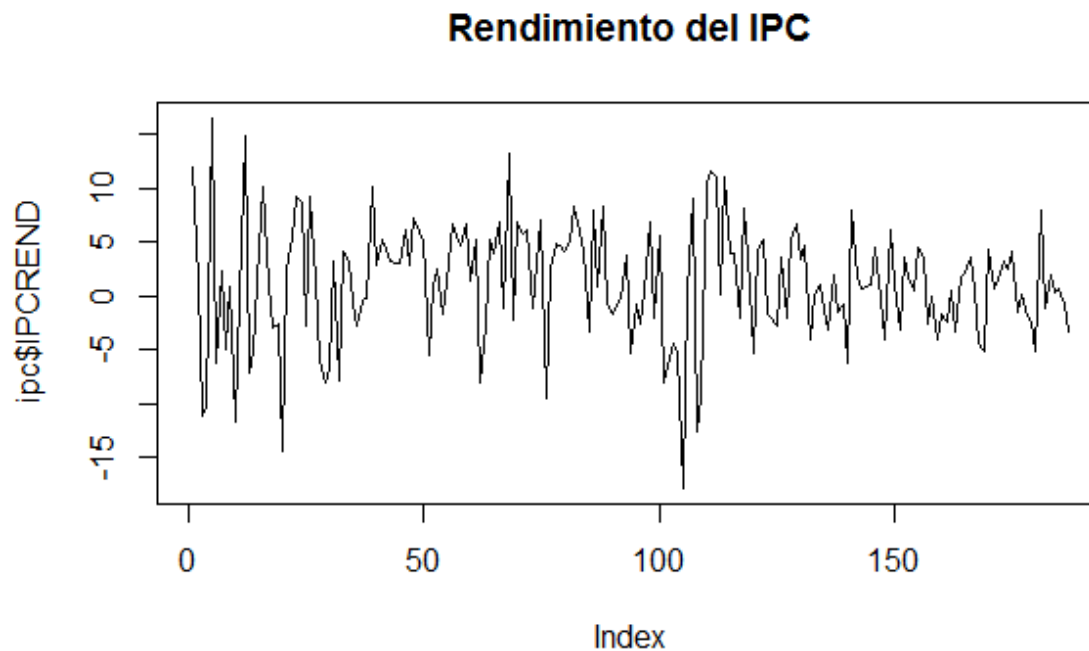
```
## instalar el paquete ##  
  
Install packages ("rugarch")  
  
## llamamos el paquete##  
  
Require(rugarch)  
  
## abrimos el archivo ipc.csv que contiene las observaciones mensuales de los  
rendimientos del IPC de 2000.02 a 2010.08.##  
  
Ipc <- read.table("ipc.csv"header=TRUE, quote="\")
```

En Rstudio es posible abrir el archivo seleccionando en la ventana de Environment la opción Import Dataset y ubicando la localización del archivo ipc.csv en su computadora.



```
## visualizamos la variable de rendimientos en un grafico de linea con la
siguiente sintaxis ##
```


```
Plot(ipc$IPCEND, type='l', main= 'Rendimiento del IPC')
```




```
## Examinamos la serie con los correlogramss para identificar el tipo de proceso  
ARIMA que podria representar a la serie ##
```

```
acf.ipc=acf(ipc$IPCREND,main='ACF IPC',lag.max=100,ylim=c(- 0.5,1))  
pacf.ipc=pacf(ipc$IPCREND,main='PACF IPC',lag.max=100,ylim=c(-0.5,1))
```

PACF IPC



ACF IPC



En ambos gráficos la serie luce estacionaria, aunque con pequeños brincos en los rezagos cuarto, séptimo y treceavo.

```
## Estimamos el proceso mas simple con los resultados obtenidos y es un  
ARMA(2,") ##
```

```
arima22=arima(ipc$IPCREND,order=c(2,0,2))
```

```
## llamamos al objeto ##
```

```
arima22
```

```
## resultados ##
```

```
Call:
```

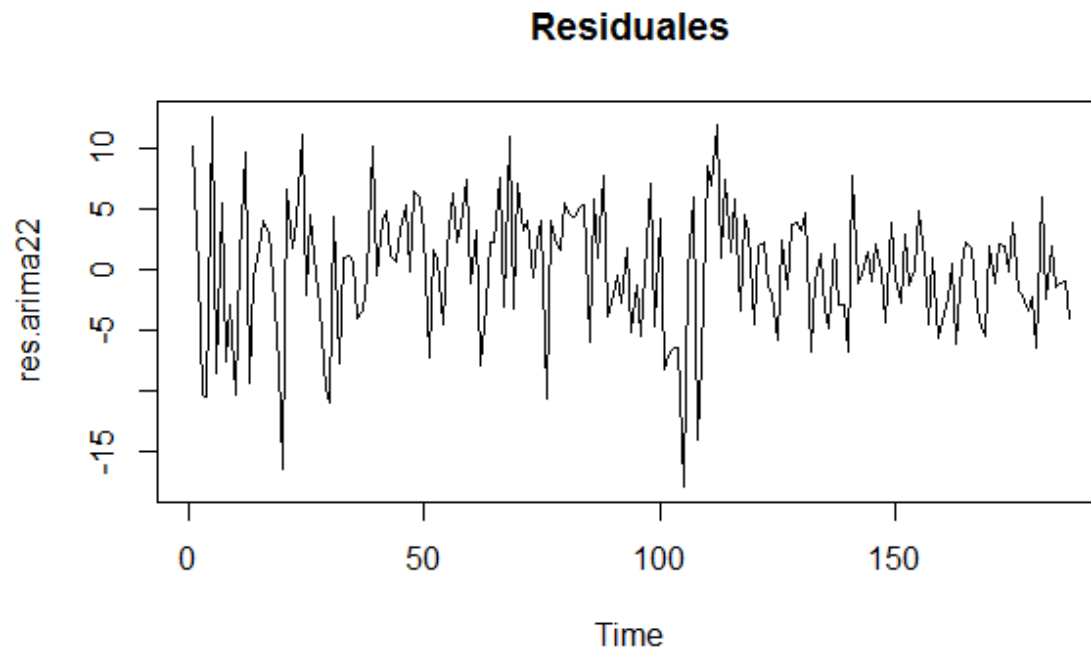
```
arima(x = ipc$IPCREND, order = c(2, 0, 2))
```

```
Coefficients:
```

	ar1	ar2	ma1	ma2	intercept
	-0.3970	-0.9680	0.4712	0.9382	1.1560
s.e.	0.0332	0.0473	0.0382	0.0850	0.3942


```
sigma^2 estimated as 27.98: log likelihood = -577.53, aic = 1167.07
```

```
## generamos los residuales del modelo ##  
  
res.arima22=arima22$res  
  
## los graficamos ##  
  
plot(res.arima22,type='l',main='Residuales')
```




```
## obtenemos el correlograma d los residuales ##  
  
acf.res=acf(res.arima22,main='ACF Residuales',lag.max=100,ylim=c(- 0.5,1))  
  
pacf.res=pacf(res.arima22,main='PACF Residuales',lag.max=100,ylim=c(-0.5,1))
```

ACF Residuales



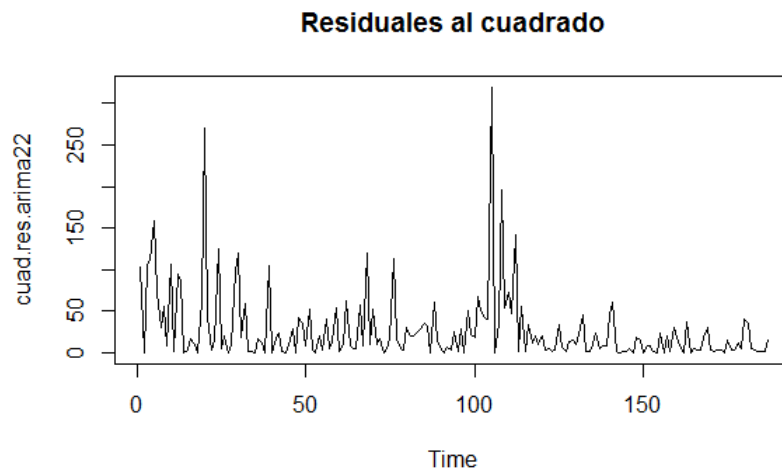
PACF Residuales



Los correlogramas de los residuales no indican ningún patrón discernible al existir rezagos significativos, por lo que podríamos considerar que el proceso que sigue es estacionario. Sin embargo, la grafica de residuales muestra procesos de volatilidad que deben ser examinados.

```
## examinamos los residuales elevados al cuadrado con el fin de examinar su
varianza ##
```

```
cuad.res.arima22=res.arima22^2
par(mfcol=c(3,1))
plot(cuad.res.arima22,main='Residuales al cuadrado')
```




La grafica muestra claramente procesos agrupados de volatilidad, siendo el mas intenso el que aparece después de la observación 100.


```
## Los correlogramas de los residuales al cuadrado son evidencia de la
heterocedasticidad presente en la varianza, así que obtenemos los correlogramas ##


acf.res2=acf(cuad.res.arima22,main='ACF Residuales al
cuadrado',lag.max=100,ylim=c(- 0.5,1))

pacf.res2=pacf(cuad.res.arima22,main='PACF Residuales al
cuadrado',lag.max=100,ylim=c(-0.5,1))
```

ACF Residuales al cuadrado



PACF Residuales al cuadrado



Ambas graficas confirman que en efecto los residuales al cuadrado no son ruido blanco y tienen rezagos significativos, los cuales son indicadores de procesos de volatilidad.

Para modelar la volatilidad utilizamos ARCH, utilizamos el modelo mas simple un GARCH(1,1)

```
## utilizamos los comandos ugarchspec y ugarchfit, que son rutinas para generar un
modelo GARCH(1,1) con una especificación ARMA(1,1) en la media ##
```

```
spec = ugarchspec()
fit = ugarchfit(data = ipc[,1], spec = spec)
Fit
```

```
*-----*
*          GARCH Model Fit          *
*-----*

Conditional Variance Dynamics
-----
GARCH Model      : sGARCH(1,1)
Mean Model       : ARFIMA(1,0,1)
Distribution      : norm

Optimal Parameters
-----
mu      Estimate  Std. Error  t value  Pr(>|t|)
ar1     0.63859   0.435840   1.4652   0.142871
ma1     -0.58482   0.461279   -1.2678  0.204861
omega   1.24751   0.948943   1.3146   0.188636
alpha1  0.14582     0.056392   2.5859   0.009713
beta1   0.80585   0.064351  12.5227  0.000000

Robust Standard Errors:
Estimate  Std. Error  t value  Pr(>|t|)
mu      1.11947   0.385841   2.9014   0.003715
ar1     0.63859   0.249164   2.5629   0.010380
ma1     -0.58482   0.259069   -2.2574  0.023984
omega   1.24751   0.696806   1.7903   0.073403
alpha1  0.14582     0.052389   2.7835   0.005378
beta1   0.80585   0.050089  16.0884  0.000000

LogLikelihood : -568.9842

Information Criteria
-----
Akaike      6.1496
Bayes      6.2532
Shibata    6.1476
Hannan-Quinn 6.1916

Weighted Ljung-Box Test on Standardized Residuals
```

De los resultados se obtiene que los residuales no representan autocorrelación serial y tampoco hay proceso ARCH en los residuales elevados al cuadrado, por lo que se puede plantear que la modelación fue adecuada.

```
-----
                    statistic p-value
Lag[1]                0.1014  0.7501
Lag[2*(p+q)+(p+q)-1][5] 1.0955  1.0000
Lag[4*(p+q)+(p+q)-1][9] 4.9090  0.4744
d.o.f=2
H0 : No serial correlation
```

Weighted Ljung-Box Test on Standardized Squared Residuals

```
-----
                    statistic p-value
Lag[1]                0.5519  0.4576
Lag[2*(p+q)+(p+q)-1][5] 1.2246  0.8071
Lag[4*(p+q)+(p+q)-1][9] 2.9572  0.7660
d.o.f=2
```

Weighted ARCH LM Tests

```
-----
                    Statistic Shape Scale P-Value
ARCH Lag[3]         0.0317 0.500 2.000 0.8587
ARCH Lag[5]         1.6030 1.440 1.667 0.5656
ARCH Lag[7]         2.8148 2.315 1.543 0.5492
```

Nyblom stability test

```
-----
Joint Statistic: 1.2262
Individual Statistics:
mu      0.38545
ar1     0.05193
ma1     0.05096
omega   0.26879
alpha1  0.18367
beta1   0.27108
```

```
-----
Asymptotic Critical values (10% 5% 1%)
Joint Statistic:      1.49 1.68 2.12
Individual Statistic: 0.35 0.47 0.75
```

Sign Bias Test

```
-----
                    t-value  prob sig
Sign Bias          1.1184 0.2649
Negative Sign Bias 0.5020 0.6162
Positive Sign Bias 0.4211 0.6742
Joint Effect       3.5976 0.3083
```

Adjusted Pearson Goodness-of-Fit Test:

```
-----
group statistic p-value(g-1)
1      20      25.73      0.1380
2      30      35.51      0.1882
3      40      43.37      0.2902
4      50      41.61      0.7641
```

```
## Con el modelo estimado es posible realizar una predicción de los rendimientos para los siguientes diez períodos, para lo cual utilizamos el comando fit ##
```

```
fit = ugarchfit(data = ipc[,1], spec = spec,out.sample=10)  
> forc=ugarchforecast(fit, n.ahead=10)
```

```
## Gráficamos nuestros resultados con el comando plot y se abren las siguientes opciones de gráficas ##
```

```
plot(forc)
```

```
## Make a plot selection (or 0 to exit)##
```

- 1: Time Series Prediction (unconditional)
- 2: Time Series Prediction (rolling)
- 3: Sigma Prediction (unconditional)
- 4: Sigma Prediction (rolling)

```
## la primera opción y la cuarta con la predicción no condicional, nos permiten obtener el rendimiento futuro.
```

En caso de buscar especificaciones diferentes para el modelo GARCH debemos de utilizar las opciones del comando `ugarchspec`. Por ejemplo, probamos una especificación en la media para un modelo ARMA(2,2) que se corresponde con el que identificamos en el proceso previamente llevado a cabo con la metodología Box-Jenkins.

```
spec2=ugarchspec(variance.model = list(model = "sGARCH", garchOrder = c(1, 1),
submodel = NULL, external.regressors = NULL, variance.targeting = FALSE),
mean.model = list(armaOrder = c(2, 2), include.mean = TRUE, archm = FALSE,
archpow = 1, arfima = FALSE, external.regressors = NULL, archex = FALSE),
distribution.model = "norm", start.pars = list(), fixed.pars = list())

## generamos un objeto ##

fit = ugarchfit(data = ipc[,1], spec = spec2)

## llamamos al objeto##
fit
```

En la salida de los resultados podemos ver que el ajuste del modelo es mejor que los coeficientes son significativos.

El modelo obtenido para la media tiene los siguientes coeficientes y son significativos:

- Constante= $\mu=1.129$
- Términos AR: AR(1)= -0.422 , AR(2)= -0.914
- Términos MA: MA(1)= 0.471, MA(2)= 0.887

Mientras que para el modelo de la varianza tenemos:

- Constante= $\omega=1.003$
- Término ARCH= $\alpha_1=0.132$
- Término GARCH= $\beta_1=0.827$

Si necesitamos estimar otras especificaciones de la familia de modelos GARCH simplemente modificamos la opción de la lista de modelos en la varianza: `model="Tipo de modelo"`, los modelos que acepta son:

`"sGARCH"`, `"fGARCH"`, `"eGARCH"`, `"gjrGARCH"`, `"apARCH"`, `"iGARCH"` y `"csGARCH"`.

Cuando utilizamos el tipo de modelos `fGARCH` tenemos la opción de estimar los siguientes submodelos:

`"GARCH"`, `"TGARCH"`, `"AVGARCH"`, `"NGARCH"`, `"NAGARCH"`, `"APARCH"`, `"GJRGARCH"` y `"ALLGARCH"`.