

# MODELACIÓN DE LA INCERTIDUMBRE EN ACTIVOS FINANCIEROS: APLICACIONES DE LOS MODELOS AUTORREGRESIVOS DE HETEROSCEDASTICIDAD CONDICIONAL

*Renè Leticia Lozano Cortés<sup>1</sup>*  
*Luis Fernando Cabrera Castellanos*

## Presentación

**E**L PRESENTE TRABAJO EJEMPLIFICA LA MODELIZACIÓN DE INCERTIDUMBRE MEDIANTE LOS MODELOS DE HETEROSCEDASTICIDAD CONDICIONAL para el pronóstico de activos financieros. Se divide en dos partes; en la primera se realiza una breve descripción de los modelos ARCH-GARCH, así como algunas de sus variantes (IGARCH, TARCH y GARCH-M), señalando sus especificaciones, debilidades y pruebas. En la segunda parte se presentan los resultados de tres aplicaciones, con los datos de rendimientos de las acciones de Bimbo, del NASDAQ y de las CPO de TV-Azteca, en los que se encontraron que dichas series se podían representar adecuadamente mediante un modelo GARCH, TARCH y GARCH-M, respectivamente.

## Modelos Autorregresivos de Heteroscedasticidad Condicional (ARCH)

Los modelos ARCH pretenden analizar la media y varianza condicional, considerando además que la media y varianza no condicional son en realidad un ARMA, que adicionalmente proponen un mecanismo que confronta la evolución de los errores (varianza condicional) para incorporar el hecho de que la volatilidad tiene altas y bajas, lo cual puede medirse por la desviación estándar (Ludlow, 1997).

Los modelos ARCH fueron generados por Robert Engle en 1982, denominados modelos autorregresivos de heteroscedasticidad condicional, cuando el término error está dado por:

$$a_t = v_t \sqrt{\alpha_0 + \alpha_1 a_{t-1}^2}$$

<sup>1</sup> Profesores-investigadores de la Universidad de Quintana Roo. E-mail: renlozan@correo.uqroo.mx y luicabre@correo.uqroo.mx

donde:

$V_t$  = es un proceso de ruido blanco con varianza 1.

$a_t$  y  $v_t$  son independientes,  $\alpha_0 > 0$ ,  $0 < \alpha_1 < 1$ ; con estas condiciones y usando  $E[xw] = E[x]E[w]$  son independientes se concluye que:

1.  $E[a_t] = 0$  ya que  $E[V_t] = 0$  y además  $\{a_t\}$  y  $\{V_t\}$  son independientes
2.  $E\{a_t a_s\} = 0$  ya que  $E\{a_t a_s\} = 0$  ya que  $E[V_t V_s]$
3. La varianza constante o sea no condicional está dada por:  $E[a^2_t] = E[v^2_t] E[\alpha_0 + \alpha_1 a^2_{t-1}] = 1 [\alpha_0 + \alpha_1 E(a^2_{t-1})] E[a^2_t] = \alpha_0 / 1 - \alpha_1$
4. La media condicional es cero  $E[\alpha_t / w_t] = 0$ , ya que  $V_t$  tiene media cero.
5. La varianza condicional está dada por:  $E[a^2_t | \Omega_t] = \alpha_0 + \alpha_1 a^2_{t-1}$

La anterior relación nos dice que los errores están bajo un proceso AR (1) condicional; de ahí su nombre ARCH.

La condición  $\alpha_0 > 0$  corresponde a la mínima varianza condicional a ser observada, mientras que la condición  $0 < \alpha_1 < 1$  espera que sea un proceso estable, es decir, que  $\alpha_1 < 0$  no es posible porque la varianza no puede ser negativa y si se hace la prueba de hipótesis  $\alpha_1 = 0$  de aceptar  $H_0$  quiere decir que no hay efecto ARCH.

Si  $\alpha_1$  se acerca a 1, tenemos algo semejante a una caminata aleatoria en la varianza; si se acerca a cero el efecto ARCH es poco probable.

### Debilidades del modelo ARCH

1. El modelo asume que los choques positivos y negativos tienen el mismo efecto sobre la volatilidad, dado que éstos dependen de los cuadrados de choques previos. En la práctica es bien conocido que el precio de un activo financiero responde de manera diferente a choques positivos que a negativos.
2. El modelo ARCH es más restrictivo.
3. Los modelos ARCH no arrojan buenos resultados para entender las

fuentes de variación de las series de tiempo financieras. Solamente proporcionan una forma mecánica para describir la conducta de la varianza condicional.

4. Se dice que los modelos ARCH más probablemente sobreestimen la predicción de la volatilidad, dado que responden lentamente a grandes choques aislados de las series de rendimientos.

### Construcción de un modelo ARCH

1. Construir un modelo econométrico (por ejemplo, un modelo ARMA) para las series de rendimientos a fin de eliminar cualquier dependencia lineal en los datos y usar la serie de los residuos del modelo para probar los efectos ARCH;
2. Especificar el orden ARCH y realizar la estimación;
3. Checar el modelo ARCH estimado cuidadosamente y mejorarlo si es necesario.

### Pruebas para identificar el efecto de la media

1. Se construye un modelo ARMA para la serie de tiempo observada a fin de eliminar cualquier correlación serial de los datos. Para la mayoría de las series de rendimientos de activos, este paso implica eliminar la media de la muestra de los datos, si ésta es significativamente diferente de cero. Para algunas series de rendimientos diarios un simple modelo AR puede ser suficiente.
2. La serie de los errores al cuadrado  $a^2_t$  es usada para checar heteroscedasticidad condicional, donde  $a^2_t = r_t - \mu_t$  es el residuo del modelo ARMA. Al respecto existen dos pruebas disponibles:
  - a) La primera es checar el estadístico usual Ljung-Box de  $a^2_t$ ;
  - b) la segunda prueba de la heteroscedasticidad condicional es la prueba

del multiplicador de Lagrange de Engle; esta prueba es equivalente al estadístico F usual para probar de manera conjunta  $a_i = 0$  ( $i = 1, \dots, m$ ) en la regresión lineal:

$$a_t^2 = \alpha_0 + \alpha_1 a_{t-1}^2 + \dots + \alpha_m a_{t-m}^2 + e_t, \quad t = m + 1, \dots, T$$

donde  $e_t$  denota el término de error,  $m$  es una constante predeterminada y  $T$  es el tamaño de la muestra.

### Determinación del orden

Si el estadístico F es significativo, la heteroscedasticidad condicional de  $a_t^2$  es detectada y podemos usar el PACF de  $a_t^2$  para determinar el orden ARCH, dado:  $\sigma_t^2 = \alpha_0 + \alpha_1 a_{t-1}^2 + \dots + \alpha_m a_{t-m}^2 + e_t$ ,  $t = m + 1, \dots, T$ . Para una muestra dada,  $a_t^2$  es un estimador insesgado de  $\sigma_t^2$  donde  $a_t^2$  se esperara que esté linealmente relacionado con  $a_{t-1}^2, \dots, a_{t-m}^2$ , de manera similar a un modelo autorregresivo de orden  $m$ .

### Pronóstico

Los pronósticos del modelo ARCH pueden obtenerse recursivamente como los modelos AR. A partir de un modelo ARCH ( $m$ ), el pronóstico de un paso hacia adelante de  $\sigma_{h+1}^2$  es:

$$\sigma_h^2(1) = \alpha_0 + \alpha_1 a_h^2 + \dots + \alpha_m a_{h+1-m}^2$$

### Modelo generalizado de heteroscedasticidad condicional (GARCH)

Frecuentemente los modelos ARCH requieren muchos parámetros que describan adecuadamente los procesos de volatilidad de los activos. Una alternativa a estos modelos fue encontrada por Bollerslev (1986), quien propone el uso de una extensión conocida como ARCH generalizado, conocido también como modelos GARCH.

Este tipo de modelos reproduce periodos de volatilidad con periodos tranquilos; son modelos que requieren menos parámetros, por lo que son más preferidos. Igual que antes, el proceso  $\{a_t\}$  tiene media cero y varianza condicional  $E[a_t^2 | \Omega_t] = \sigma_t^2$  (Ludlow, 1997).

Un modelo GARCH (1, 1) está definido como:

$$a_t = v_t \sqrt{\sigma_t^2} \\ \sigma_t^2 = \alpha_0 + \alpha_1 a_{t-1}^2 + \dots + \beta \sigma_{t-1}^2$$

Donde  $v_t$  es un proceso de ruido blanco con varianza uno; además  $a_t$  y  $v_t$  son independientes,  $\alpha_0 > 0$ ;  $0 < \alpha_1 < 1$ ;  $\beta_1 < 1$ .

Esta expresión corresponde a un GARCH (p, q):

$$a_t = \sqrt{t} \sqrt{\sigma_t^2} \\ \sigma_t^2 = \alpha_0 + \alpha_1 a_{t-1}^2 + \dots + \alpha_p a_{t-p}^2 + \beta_1 \sigma_{t-1}^2 + \dots + \beta_q \sigma_{t-q}^2$$

Las restricciones para los parámetros son:

$$\alpha_0 > 0; \alpha_j \geq 0; \beta_j \geq 0 \\ \alpha_1 + \dots + \alpha_p + \beta_1 + \dots + \beta_q < 1$$

Por lo que la varianza no condicional está dada por:

$$\text{Var. E}[a_t] = \alpha_0 / (1 - \alpha_1 + \dots + \alpha_p + \beta_1 + \dots + \beta_q)$$

Sin embargo, si se llega al límite de romper con la condición de estacionalidad imponiendo:  $\alpha_0 > 0$ ;  $\alpha_1 \geq 0$ ;  $\beta_1 \geq 0$ , por lo que  $\alpha_1 + \beta_1 = 1$ , tendremos otro tipo de modelo denominado IGARCH (1, 1), el cual se puede describir por:

$$a_t = v_t \sqrt{s_t^2} \\ \sigma_t^2 = \alpha_0 + \alpha_1 a_{t-1}^2 + (1 - \alpha_1) \sigma_{t-1}^2$$

El modelo IGARCH (1,1) es una serie que posee una raíz unitaria, en la varianza condicional, por lo que la línea de evaluación volátil es probabilística (Engle y Bollerslev, 1986).

$$a_t^2 = \alpha_0 + a_{t-1}^2 + w_t - \beta w_{t-1}$$

Aún más, es una caminata al azar con desplazamientos  $\alpha_0$  y un choque tiene efectos permanentes, por lo que la evolución de la volatilidad queda para siempre alterada por la perturbación.

Otro tipo de modelo son los denominados GARCH-M, en los que la varianza condicional aparece como un regresor (Engle, Lilién y

Robins, 1987). Con estos modelos la media condicional depende de la varianza condicional.

Dentro de estos también tenemos los TARCH; son capaces de captar efectos asimétricos en la volatilidad y dependen de un umbral por medio del cual definen su reacción:

$$a_t = v_t * v s_t^2$$

$$\sigma_t^2 = \alpha_0 + (\alpha_1 + (\alpha_1 + \delta d_{t-1}) a_{t-1}^2 + \beta_1 \sigma_{t-1}^2$$

$$\alpha_0 > 0; \beta_1 \alpha_1 > 0; \beta_1 \alpha_1 + \beta_1 + \delta / 2 < 1$$

$$d_{t-1} = 1 \text{ si } a_{t-1} < 0 \text{ y } d_{t-1} = 0 \text{ si } a_{t-1} > 0$$

Si la innovación es negativa, el umbral está prendido, por lo que el efecto sobre la varianza condicional es mayor por una contribución d' mientras que si la innovación es positiva el umbral está apagado y no hay contribución a la varianza condicional. Por lo que d mide el peso que tienen las noticias si  $\delta = 0$  no hay efecto asimétrico; la prueba se hace con el estadístico t.

### Debilidades de los modelos GARCH

Si partimos de un modelo GARCH (1, 1)  $\sigma_t^2 = \alpha_0 + \alpha_1 a_{t-1}^2 + \beta_1 \sigma_{t-1}^2$ ,  $0 \leq \alpha_1, \beta_1 \leq 1$ ,  $(\alpha_1 + \beta_1) < 1$ , se presentan las siguientes debilidades:

1. Una gran parte de  $a_{t-1}^2$  o  $\sigma_{t-1}^2$  dan crecimientos grandes de  $\sigma_t^2$ . La mayoría de los  $a_{t-1}^2$  tienden a ser seguidos por otros  $a_t^2$  generando el bien conocido comportamiento *clustering volatility*, en series de tiempo financieras.
2. De la misma forma que los modelos ARCH, la distribución de la cola de un

modelo GARCH (1, 1) tiene un peso importante en la distribución normal.

3. El modelo provee una simple función paramétrica que puede ser usada para describir la evolución de la volatilidad.

Los procedimientos para modelar un modelo ARCH pueden también ser usados para construir un modelo GARCH; sin embargo, determinar el orden de un modelo GARCH no es fácil, aunque los modelos más usados en muchas aplicaciones son GARCH de bajo orden, como: GARCH (1, 1), GARCH (2, 1) y GARCH (1, 2).

### Aplicaciones

#### Caso 1

Tomamos la serie del precio de las acciones de Bimbo con datos diarios entre el 23 de diciembre de 1999 y el 26 de marzo de 2004 (1 092 datos). Los gráficos 1.1 y 1.2 presentan la serie original y en primeras diferencias, respectivamente. Del análisis del correlograma de las funciones de autocorrelación (ACF) y autocorrelación parcial (ACPF) que no se reportan aquí, identificamos un modelo ARMA (1, 1) para la serie en primeras diferencias.

El gráfico 1.2 también permite apreciar la existencia de volatilidad en la serie, la que se expresa en los picos, sobre todo en la parte media de la muestra.

Una vez identificado el modelo ARMA, se realizó la estimación del modelo ARCH y encontramos que el mejor modelo correspondió a un GARCH (1, 1), cuyos resultados presentamos a continuación en el cuadro 1.1:

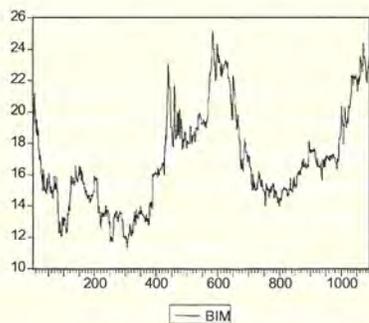


Gráfico 1.1

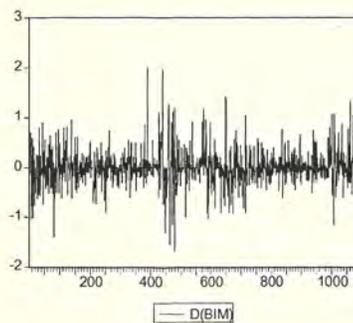


Gráfico 1.2

Dependent Variable: D(BIM)  
 Method: ML - ARCH  
 Date: 07/23/04 Time: 21:07  
 Sample(adjusted): 3 1092  
 Included observations: 1090 after adjusting endpoints  
 Convergence achieved after 23 iterations  
 Backcast: 2

	Coefficient	Std. Error	z-Statistic	Prob.
C	0.006592	0.009369	0.703567	0.4817
AR(1)	-0.945277	0.048903	-19.32953	0.0000
MA(1)	0.962926	0.039767	24.21421	0.0000
Variance Equation				
C	0.005392	0.001164	4.632492	0.0000
ARCH(1)	0.089841	0.013231	6.789966	0.0000
GARCH(1)	0.867145	0.019366	44.77661	0.0000
R-squared	0.006121	Mean dependent var	0.003413	
Adjusted R-squared	0.001537	S.D. dependent var	0.351587	
S.E. of regression	0.351317	Akaike info criterion	0.620999	
Sum squared resid	133.7909	Schwarz criterion	0.648489	
Log likelihood	-332.4447	F-statistic	1.335236	
Durbin-Watson stat	1.850717	Prob(F-statistic)	0.246778	

Cuadro 1.1

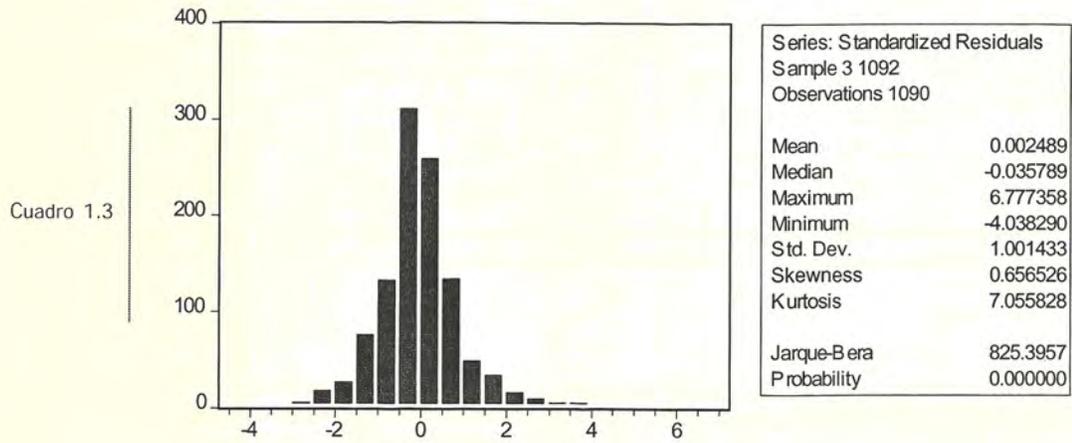
Podemos ver que la suma de los coeficientes  $\alpha$  y  $\beta$  es bastante cercano a la unidad, expresando que el efecto de los choques es permanente. A fin de corroborar la especificación correcta del modelo que planteamos, realizamos las pruebas convencionales. En primer lugar, el correlograma de autocorrelación y autocorrelación parcial de los residuos al cua-

drado, el cual presentamos en el cuadro 1.2. Como puede observarse, los estadísticos Q no resultan significativos en ningún caso, lo que apunta a que no existen ARCH remanentes en el modelo. Igual conclusión podemos obtener con el histograma de los residuos estandarizados, en que el estadístico Jarque-Bera rechaza fuertemente la hipótesis de distribución normal.

Date: 07/23/04 Time: 21:17  
 Sample: 3 1092  
 Included observations: 1090  
 Q-statistic probabilities adjusted for 2 ARMA term(s)

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
.   .	.   .	1 0.018	0.018	0.3549	
.   .	.   .	2 -0.051	-0.051	3.1764	
.   .	.   .	3 -0.020	-0.018	3.6057	0.058
.   .	.   .	4 0.009	0.007	3.6978	0.157
.   .	.   .	5 -0.020	-0.022	4.1297	0.248
.   .	.   .	6 -0.016	-0.015	4.4048	0.354
.   .	.   .	7 -0.011	-0.012	4.5308	0.476
.   .	.   .	8 0.012	0.010	4.6771	0.586
.   .	.   .	9 0.028	0.026	5.5122	0.598
.   .	.   .	10 0.035	0.035	6.8628	0.552
.   .	.   .	11 -0.017	-0.016	7.1981	0.617

Cuadro 1.2



Finalmente, realizamos la prueba del multiplicador de Lagrange (cuadro 1.4) para determinar si los residuos obtenidos aún exhiben ARCH adicional. El cuadro 1.4 permite ver que, hasta para siete rezagos, aceptamos la

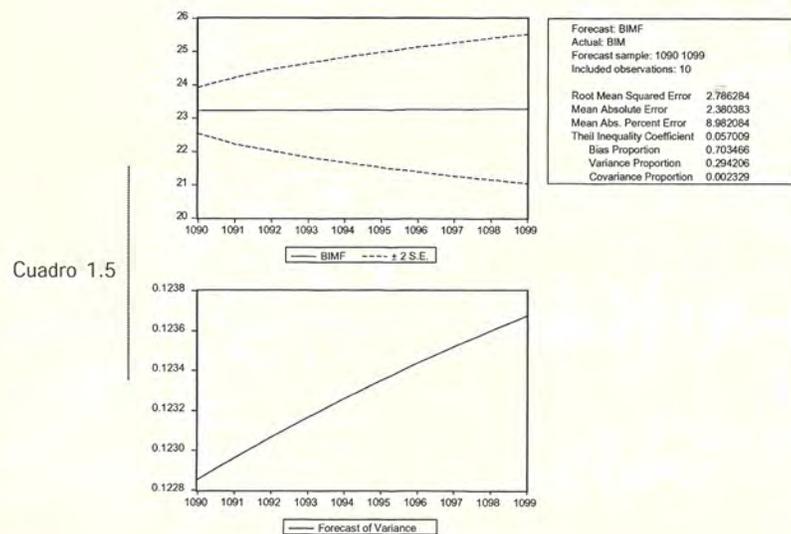
hipótesis de no significatividad conjunta de los parámetros, por lo que concluimos que no hemos dejado efecto ARCH en los residuos, corroborando que la ecuación de la varianza fue correctamente especificada.

Cuadro 1.4

ARCH Test:			
F-statistic	0.640467	Probability	0.722602
Obs*R-squared	4.497872	Probability	0.720973

Finalmente realizamos un pronóstico dinámico del precio de las acciones. Podemos ver en el cuadro 1.5 los resultados: un valor de la media aproximadamente constante y el pronóstico de la varianza condicional conver-

giendo lentamente al estado estable, dado que al estar cercano a uno la suma de los términos ARCH y GARCH (el  $\alpha + \beta$ ), los choques en la volatilidad son persistentes.



### Caso 2

En este caso tomamos la serie del NASDAQ de EU con datos del 28 de enero de 1998 al 26 de marzo de 2004 (1 486 observaciones). Los gráficos 2.1 y 2.2 muestran la serie original y en primeras diferencias. Encontramos que la serie posee raíz unitaria  $ADF = -1.78$  con valor

crítico al 5% de  $-3.4153$ . Al tomar las primeras diferencias (que expresan el rendimiento de las inversiones en esta bolsa) podemos ver que existe estacionariedad en media, pero no en varianza ( $ADF = -17.55$ ); sin embargo, no recurrimos a la transformación logarítmica a fin de efectuar el análisis del efecto ARCH.

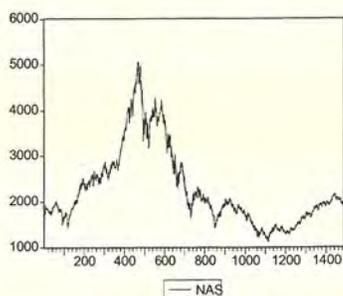


Gráfico 2.1

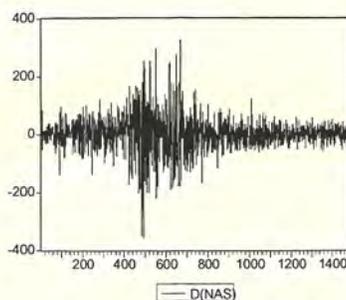


Gráfico 2.2

Con base en el análisis del correlograma, identificamos un modelo únicamente con media. A partir de esta especificación y habiendo detectado efecto ARCH mediante la prueba LM, procedimos a indagar el mejor modelo

para capturar estos efectos. Los criterios de selección de modelos finalmente nos dieron un TARCH (2, 1) cuyos resultados se presentan en el cuadro 2.1.

Dependent Variable: DNAS

Method: ML - ARCH

Date: 07/24/04 Time: 11:11

Sample(adjusted): 2 1486

Included observations: 1485 after adjusting endpoints

Convergence achieved after 35 iterations

	Coefficient	Std. Error	z-Statistic	Prob.
C	0.941433	0.853498	1.103029	0.2700
Variance Equation				
C	13.16511	5.660375	2.325838	0.0200
ARCH(1)	-0.017998	0.014111	-1.275459	0.2021
ARCH(2)	0.090830	0.020706	4.386730	0.0000
(RESID < 0)*	0.061439	0.018422	3.335054	0.0009
ARCH(1)				
GARCH(1)	0.893661	0.014700	60.79489	0.0000
R-squared	0.006121	Mean dependent var	0.003413	
R-squared	-0.000144	Mean dependent var	0.235145	
Adjusted R-squared	-0.003525	S.D. dependent var	58.93924	
S.E. of regression	59.04302	Akaike info criterion	10.36129	
Sum squared resid	5155910	Schwarz criterion	10.38272	
Log likelihood	-7687.258	Durbin-Watson stat	2.011645	

Cuadro 2.1

El efecto TARCH encontrado indica una asimetría en la volatilidad, lo que expresa de manera más realista el comportamiento de los instrumentos financieros y supera una de las debilidades señaladas al inicio de este trabajo sobre los modelos ARCH, que suponen la varianza condicional constante. En este caso vemos que efectivamente el coeficiente  $\gamma$  (0.0614) es significativo y, al ser además positivo, podemos decir que existe efecto "apalancamiento" (*leverage effect*). Las buenas noticias tienen un impacto en este caso expresado por  $\alpha_1$  y  $\alpha_2$ , mientras que las malas noticias tienen el impacto de  $\alpha_1 + \alpha_2 + \gamma$ .

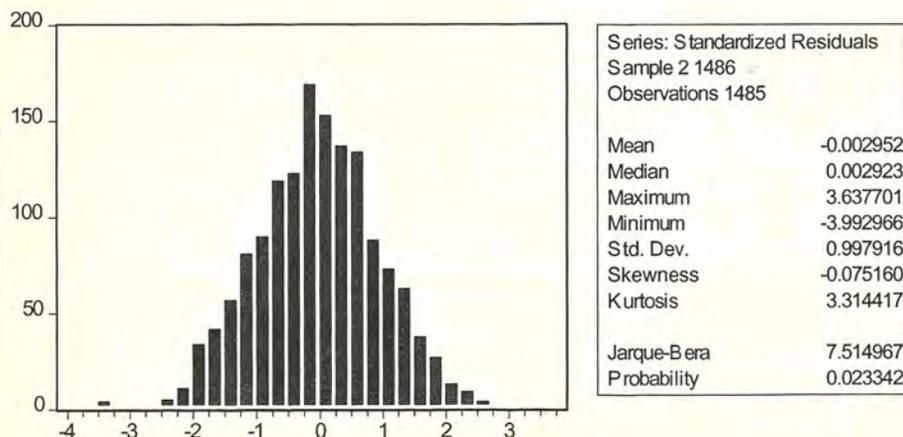
Para corroborar si no dejamos restantes efectos ARCH en nuestro modelo, realizamos las pruebas convencionales. En primer lugar, revisamos el correlograma de los residuos al cuadrado pudiendo observar que, a favor de nuestro modelo, ninguno de los valores de las FAC y PFAC resultan significativos (cuadro 2.2). En el mismo sentido, encontramos que el estadístico Jarque-Bera permite rechazar la hipótesis de normalidad de los errores (cuadro 2.3).

Cuadro 2.2

Date: 07/24/04 Time: 21:00  
 Sample: 2 1486  
 Included observations: 1485

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 -0.010	-0.010	0.1516	0.697
		2 0.028	0.028	1.3122	0.519
		3 -0.005	-0.004	1.3431	0.719
		4 0.037	0.036	3.3956	0.494
		5 -0.018	-0.017	3.8627	0.569
		6 -0.026	-0.028	4.8494	0.563
		7 0.000	0.001	4.8497	0.678
		8 -0.009	-0.009	4.9805	0.760
		9 -0.037	-0.036	6.9923	0.638
		10 0.009	0.011	7.1267	0.713
		11 -0.028	-0.028	8.3431	0.682
		12 -0.022	-0.024	9.0736	0.697
		13 0.007	0.010	9.1375	0.762
		14 -0.014	-0.015	9.4260	0.803
		15 0.003	0.003	9.4408	0.853
		16 -0.013	-0.010	9.6770	0.883

Cuadro 2.3



Para corroborar si no hemos dejado aún algún efecto ARCH sin considerar, realizamos la prueba ARCH LM considerando hasta cuatro rezagos. Como podemos observar en el cuadro 2.4, aceptamos la hipótesis de no

significancia conjunta de los cuatro rezagos, por lo que podemos afirmar que el modelo TARCH seleccionado puede ser empleado para fines de predicción. El pronóstico hasta los 1 500 datos se presenta en el gráfico 2.3.

ARCH Test:			
F-statistic	0.823945	Probability	0.509831
Obs*R-squared	3.299575	Probability	0.509000

Cuadro 2.4

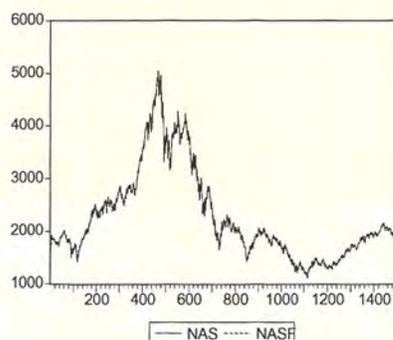


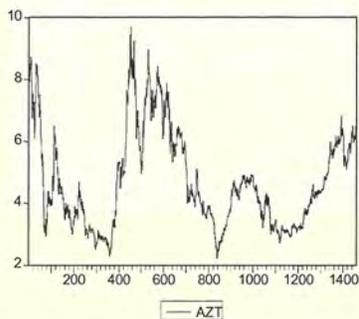
Gráfico 2.2

### Caso 3

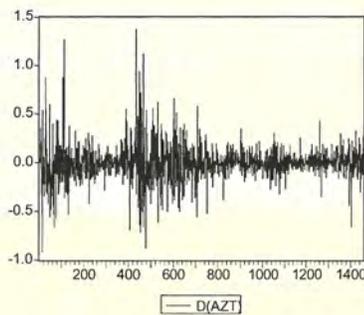
En este caso tomamos los rendimientos de los CPO de TV Azteca con datos diarios del 6 de enero de 1998 al 26 de marzo de 2004 (1 458 datos). La serie original y la de las primeras

diferencias se presentan en las gráficas 3.1 y 3.2. Podemos ver que, como en las anteriores, existe volatilidad en esta serie.

Identificamos un modelo AR(1) para esta serie. Para capturar el efecto ARCH, optamos por un GARCH(1,1)-M, que, de acuerdo con



Gráfica 3.1



Gráfica 3.2

los criterios de selección de modelos y las pruebas sobre efecto ARCH restantes en la serie, nos dio la mejor estimación. Los resultados se presentan en el cuadro 3.1.

En este modelo el coeficiente de la desviación estándar en la ecuación de la media (-0.125) es el denominado parámetro de premio sobre el riesgo (*risk premium parameter*) y, al ser negativo, indica que los rendimientos están negativamente correlacionados con la volatilidad del pasado. Por su parte, los valores convencionales de  $\alpha + \beta$  dan la unidad ( $0.099 + 0.901 = 1$ ) expresando la completa persistencia de los choques de volatilidad.

El correlograma de los residuos al cuadrado nos indica que ni las autocorrelaciones ni las autocorrelaciones parciales resultan significativas mediante el estadístico Ljung-Box, lo que nos indica que el modelo ha capturado los efectos ARCH y es válida la especificación de la ecuación de la varianza (cuadro 3.2). La prueba ARCH LM que hemos corrido para hasta cuatro rezagos, nos indica que no se han dejado fuera efectos ARCH (cuadro 3.3).

El modelo empleado se usó para elaborar el pronóstico, el cual se presenta en la gráfica 3.3.

Cuadro 3.1

Dependent Variable: D(AZT)				
Method: ML - ARCH				
Date: 07/25/04 Time: 08:58				
Sample(adjusted): 3 1458				
Included observations: 1456 after adjusting endpoints				
Convergence achieved after 32 iterations				
	Coefficient	Std. Error	z-Statistic	Prob.
SQR(GARCH)	-0.125124	0.063463	-1.971594	0.0487
C	0.015549	0.007602	2.045340	0.0408
AR(1)	0.066988	0.024919	2.688227	0.0072
Variance Equation				
C	0.000192	3.52E-05	5.467051	0.0000
ARCH(1)	0.099168	0.008227	12.05360	0.0000
GARCH(1)	0.901053	0.006971	129.2620	0.0000
R-squared	0.008646	Mean dependent var	-0.000962	
Adjusted R-squared	0.005227	S.D. dependent var	0.181932	
S.E. of regression	0.181456	Akaike info criterion	-1.051485	
Sum squared resid	47.74287	Schwarz criterion	-1.029713	
Log likelihood	771.4811	F-statistic	2.529193	
Durbin-Watson stat	1.956692	Prob(F-statistic)	0.027385	
Inverted AR Roots	.07			

Date: 07/25/04 Time: 09:09  
 Sample: 3 1458  
 Included observations: 1456  
 Q-statistic probabilities adjusted for 1 ARMA term(s)

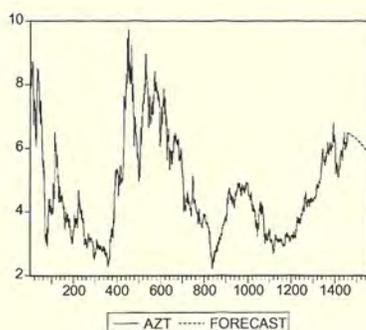
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 0.027	0.027	1.0395	
		2 -0.026	-0.027	2.0327	0.154
		3 0.018	0.019	2.4877	0.288
		4 -0.023	-0.024	3.2309	0.357
		5 -0.015	-0.013	3.5582	0.469
		6 0.031	0.030	4.9251	0.425
		7 -0.001	-0.003	4.9277	0.553
		8 -0.030	-0.028	6.2068	0.516
		9 -0.011	-0.012	6.3959	0.603
		10 -0.025	-0.025	7.3115	0.605
		11 -0.025	-0.022	8.1959	0.610
		12 -0.016	-0.018	8.5846	0.660
		13 0.006	0.005	8.6341	0.734
		14 -0.007	-0.007	8.6988	0.795
		15 0.015	0.015	9.0218	0.830
		16 -0.014	-0.016	9.3163	0.860
		17 -0.025	-0.023	10.272	0.852
		18 -0.001	-0.001	10.273	0.892
		19 -0.005	-0.007	10.307	0.921
		20 0.034	0.033	11.993	0.886
		21 0.017	0.011	12.409	0.901
		22 0.003	0.003	12.422	0.928
		23 0.006	0.007	12.474	0.947
		24 -0.029	-0.029	13.700	0.935
		25 0.026	0.029	14.695	0.929
		26 -0.027	-0.033	15.749	0.922

Cuadro 3.2

ARCH Test:

F-statistic	0.867425	Probability	0.482770
Obs*R-squared	3.473362	Probability	0.481940

Cuadro 3.3



Gráfica 3.3

## BIBLIOGRAFÍA

BROCKWELL, Peter J. y Richard A. Davis (1991), "Springer Series in Statistics", Springer, 1991.

*Eviews 3 User's Guide*, 1994-1998.

LUDLOW, Wiechers, Jorge (1997), *Modelos, pronósticos y volatilidad de las series de tiempo generadas en la Bolsa Mexicana de Valores*, Biblioteca de Ciencias Sociales y Humanidades, Serie Economía.