

ESTIMACIÓN DEL RIESGO BURSÁTIL MEDIANTE REGRESIÓN POR CUANTILES ¹

JULIO EDUARDO FABRIS

Instituto de Investigaciones Económicas (IIE), Universidad de Buenos Aires, Av. Córdoba 2122-1120AAQ Ciudad Autónoma de Buenos Aires República Argentina

jfabris88@yahoo.com.ar

Recibido 10 de agosto de 2015, aceptado 6 de septiembre de 2015

Resumen

El Valor a Riesgo se ha constituido en un estándar para la medición del riesgo de una cartera de activos. Su sencillez y difusión lo han posicionado en un lugar de privilegio cuando de evaluar riesgo de mercado se trata.

Sin embargo el problema de su estimación todavía es un tema debatido. Existe una gran variedad de modelos que producen estimaciones muy diferentes del riesgo de mercado para el mismo portafolio y no hay un consenso establecido en cuanto a la evaluación de los mismos.

En este trabajo se explora un método relativamente novedoso de estimación del VaR, denominado CAViaR (*Conditional Autoregressive Value at Risk*) desarrollado por Engle y Manganelli y se lo compara con el método tradicional desarrollado por J. P. Morgan denominado Riskmetrics™ así como con otros métodos. Para la evaluación comparativa se realiza un tradicional backtesting.

La serie sobre la que se realiza el ejercicio es la del índice Merval del Mercado de Valores de Buenos Aires.

Palabras clave: Riesgo bursátil - Valor a Riesgo - CAViaR

¹ Este trabajo es realizado en el marco del proyecto de investigación UBACyT Código 20020130100529BA del cual el autor es codirector.

ESTIMATING MARKET RISK BY QUANTILE REGRESSION

JULIO EDUARDO FABRIS

Instituto de Investigaciones Económicas (IIE), Universidad de Buenos Aires, Av. Córdoba 2122-1120AAQ Ciudad Autónoma de Buenos Aires República Argentina
jfabris88@yahoo.com.ar

Abstract

The Value at Risk (VaR) has become a standard for measuring the risk of a portfolio of assets. Its simplicity and dissemination have positioned VaR as a privileged measure of market risk.

However the problem of its estimation is still a matter of debate. There are a variety of models that produce very different estimates of market risk for the same portfolio and there is no consensus regarding their evaluation.

In this paper we used a relatively new method for estimating VaR, called CAViaR (Autoregressive Conditional Value at Risk), developed by Engle and Manganelli. The CAViaR method is compared with the traditional method developed by J.P. Morgan called RiskMetrics and with Garch models. For benchmarking we use a traditional backtesting. The series on which the exercise is performed is the Merval index of the Mercado de Valores de Buenos Aires.

Keywords: Market Risk - Value at Risk - CAViaR

1. Introducción

El Valor a Riesgo se ha constituido en un estándar para la medición del riesgo de una cartera de activos. Su sencillez y difusión lo han posicionado en un lugar de privilegio cuando de evaluar riesgo de mercado se trata.

Sin embargo el problema de su estimación todavía es un tema debatido. Existe una gran variedad de modelos que producen estimaciones muy diferentes del riesgo de mercado para el mismo portafolio y no hay tampoco un consenso establecido en cuanto a la evaluación de los mismos.

En esta ponencia se explora un método relativamente novedoso de estimación del VaR, denominado CAViaR (Conditional Autoregressive Value at Risk) desarrollado por Engle y Manganelli² y se lo compara con otras metodologías de uso común, a saber: el método histórico, el popular método desarrollado por J. P. Morgan denominado Riskmetrics™ y uno de los modelos ARCH más conocidos, el GARCH(1,1). Otros autores han realizado trabajos similares para otras series financieras, incluyendo también la metodología CAViaR³.

Para la evaluación comparativa se realiza un tradicional backtesting. La serie sobre la que se realiza el ejercicio es el Índice Merval del Mercado de Valores de Buenos Aires

El Valor a Riesgo (VaR) es una medida resumen del riesgo de mercado de una cartera de activos financieros. Se define como la máxima pérdida esperable, para un valor de confianza p , de una cartera en un periodo determinado.

Por ejemplo, si se dispone de una cartera de valor \$ 1.000.000 y se reporta un VaR al 95 % a 5 días de \$ 70.000, lo que se quiere decir es que dicha suma es la máxima pérdida esperable a 5 días vista, con un nivel de confianza del 95 %.

Como toda medida resumen, el VaR tiene ventajas y desventajas y existe un trade-off entre su sencillez y su rigurosidad. Entre las ventajas, se puede argumentar que reporta una medida del riesgo de mercado de una cartera que cualquier participante del mismo puede comprender. Por otra parte, se centra en la principal preocupación de los directivos de las empresas financieras, que es la posibilidad de una pérdida ruinoso y además, como medida resumen de riesgo, ha ganado mucho apoyo en distintos centros de decisión (Grupo de los Treinta, Banco de Pagos Internacionales, Unión Europea, entre otros)

Sus desventajas se deben en parte a sus virtudes. Por una parte, si bien informa sobre la máxima pérdida para un dado valor de probabilidad, no informa sobre la pérdida esperada cuando los retornos se ubican sobre las colas de la distribución. En este sentido se ha

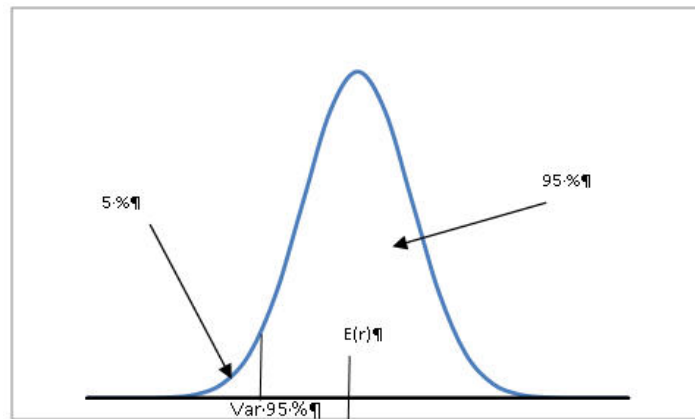
² Engle y Manganelli (2004).

³ Ver Zevallos (2012), Allen y Singh (2010) y Lima y Neri (2006).

propuesto una medida que sí informa sobre este valor y es la llamada “pérdida esperada” (Expected Shortfall), de la que no nos ocuparemos en este trabajo.

Por otra parte, existen distintas formas de calcularlo que producen estimaciones muy diferentes del riesgo de mercado para una mismo portafolio. Existe entonces el riesgo de subestimar la pérdida probable, lo cual haría a la empresa vulnerable al riesgo que se buscaba cubrir. También una sobreestimación sería problemática, porque conduciría a asignaciones de capital subóptimas.

Gráfico 1. Distribución del retorno de una cartera y VaR 95 % de la misma



Fuente: Elaboración propia.

2. Metodología

En este trabajo comparamos las metodologías para estimar el valor a riesgo de una cartera (en este caso representada por el índice Merval) con base en sus valores pasados. Las técnicas elegidas para la comparación son cuatro. El método histórico, el popular método desarrollado por J. P. Morgan denominado Riskmetrics™, uno de los modelos ARCH más conocidos, el GARCH(1,1) y la relativamente novedosa metodología denominada CAViaR (Conditional Autoregressive Value at Risk) desarrollada por Engle y Manganelli. En particular se intentará explorar las ventajas de esta última respecto de las otras, más tradicionales metodologías.

La serie elegida para nuestra comparación será el Índice Merval. Se estimarán los Valores a Riesgo de una cartera hipotética de \$ 1, compuesta en forma idéntica a dicho Índice, que se integra con los principales activos que cotizan en la Bolsa de Valores en proporciones que coinciden con el volumen de sus transacciones en el mercado accionario.

Se estimarán dos medidas de riesgo, VaR_{95%} y VaR_{99%} con horizonte temporal de 1 día. Es decir que los valores reportados estimarán la máxima pérdida por peso de valuación de la cartera, a 1 día vista, con un nivel de confianza del 95 % y el 99 % respectivamente.

Respecto del horizonte temporal considerado, en general éste puede o no coincidir con el período de los retornos. En nuestro caso, los datos son retornos diarios y el VaR se calcula también a un día, por lo que el problema de la no coincidencia de la temporalidad del VaR y de los datos no será abordado.

Además del tema de la periodicidad debe tomarse una decisión sobre el intervalo de la muestra que se utiliza como base para la estimación. Ambas decisiones están relacionadas, porque si la periodicidad es diaria y el intervalo de la muestra es un año, tendremos aproximadamente 250 observaciones, lo cual es suficiente para una estimación razonablemente precisa, mientras que si los datos son semanales, se dispondrá de solamente 50 observaciones, lo que hace mucho más impreciso el cálculo.

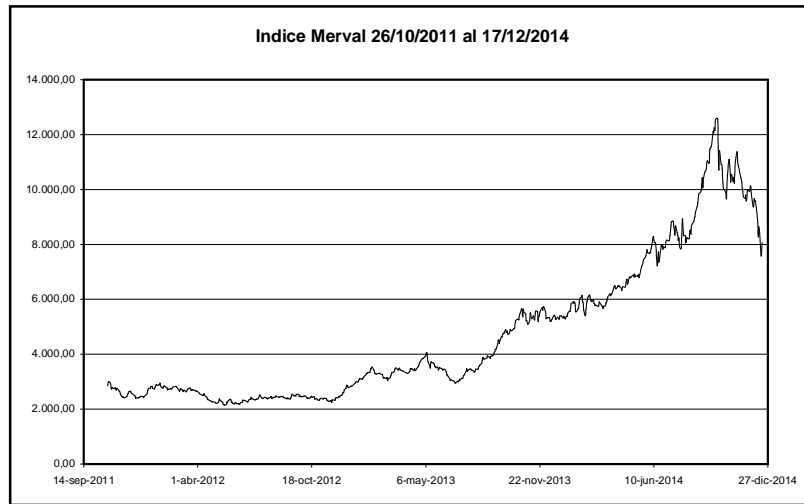
Por otra parte debe considerarse que en escenarios muy cambiantes como lo es típicamente la economía argentina, al tomar una muestra de varios años podríamos estar reuniendo en una misma muestra intervalos en los que el funcionamiento del mercado bursátil tiene diferentes lógicas y distintos comportamientos.

En este dilema planteado, la decisión metodológica ha sido utilizar para la estimación 250 observaciones de retornos diarios (intervalo de aproximadamente 1 año). Además las muestras utilizadas serán del tipo circulante (rolling sample).

Para el análisis se calcularán los retornos logarítmicos del índice Merval publicado por el Mercado de Valores de Buenos Aires S.A.⁴ para el período que va del 26/10/2011 al 17/12/2014 (750 observaciones). Los primeros 250 valores (26/10/2011 al 12/11/2012) se utilizarán para estimar el VaR correspondiente al período 251 y luego se irá corriendo la muestra, incorporando la observación 251 y descartando la nro. 1, de modo tal de contar en todos los casos con 250 observaciones.

⁴ Es decir $rlog = \log(p_t) - \log(p_{t-1})$, siendo p_t el valor (precio) del índice.

Figura 1. Índice Merval



Fuente: Elaboración propia.

Finalmente se tendrán estimaciones de $VaR_{95\%}$ y $VaR_{99\%}$ para los últimos 500 días (13/11/2012 al 17/12/2014) y se computarán para cada método las llamadas “excepciones”, o sea las ocasiones en que el retorno es menor que el VaR estimado. Estas serían las ocasiones en que el método “falla”. Por definición la proporción de excepciones debería aproximar el valor de 0,05 para el caso del VaR al 95 % y 0,01 para el caso del VaR al 99 %. En nuestro caso, al tener 500 observaciones, dichas proporciones se corresponden con 25 y 5 excepciones respectivamente.

2.1 Método histórico

El método histórico consiste en estimar el percentil de interés con base en los retornos pasados (Para el VaR 95 % se estima el percentil 5, por ejemplo).

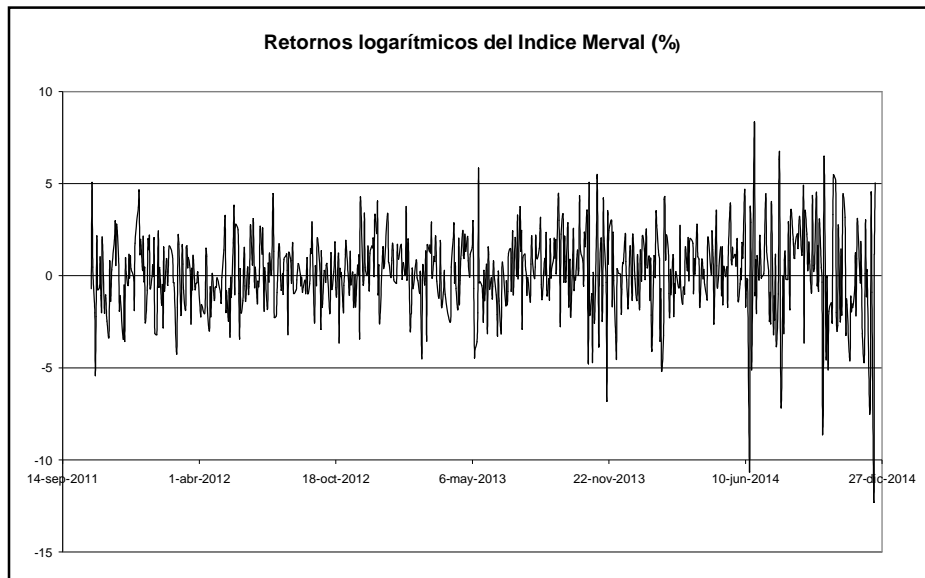
La ventaja principal del método histórico es que se trata de un método no paramétrico que puede adaptarse a cualquier forma de la distribución de los retornos. En este sentido, debe recordarse que los retornos de los activos financieros tienen características específicas que los apartan de la distribución normal. Por una parte son leptocúrticos, esto es tienen una curtosis superior a la de la distribución normal, lo que implica la existencia de “colas pesadas”, o sea probabilidades no insignificantes de eventos catastróficos.

Por otra parte, tienen cierto grado de asimetría, en general negativa, es decir que los retornos negativos tienen mayor peso (medidos por el coeficiente de asimetría) que los positivos, mientras que la distribución normal es simétrica.

Finalmente, la volatilidad de los retornos se presenta en la línea de tiempo en forma de “clusters” o agrupamientos de volatilidad baja y volatilidad alta.


De las 3 características mencionadas, las primeras dos son tomadas en cuenta por el método, ya que el cuantil estimado toma como base la distribución empírica de los retornos. Sin embargo la tercer característica no es modelada, ya que el cuantil no toma en cuenta el ordenamiento de los retornos sino sólo su frecuencia. Esto hace que la predicción del cuantil sea incondicional, esto es sin tener en cuenta en forma diferencial los últimos valores observados de los retornos y no permite hacer pronósticos que tengan en cuenta si se está, en el momento de interés, en un mercado tranquilo o agitado.

Figura 2. Retornos logarítmicos del Índice Merval



Fuente: Elaboración propia.

Figura 3 - Distribución de los retornos logarítmicos del Índice Merval



Fuente: Elaboración propia.

2.2 Metodología Riskmetrics

El segundo método aplicado es el método Riskmetrics, desarrollado por J. P. Morgan en 1992. Este método se ideó con la finalidad de ser una metodología abierta y disponible públicamente. La metodología ha ido cambiando con el tiempo⁵.

En la actualidad, Riskmetrics se basa en un modelo de la familia ARCH (Heterocedasticidad Condicional Autorregresiva)⁶. Los modelos de dicha familia estiman la varianza para el momento actual (t) mediante los valores de la misma y de la perturbación para el período anterior (t-1). Específicamente se trata del modelo GARCH(1,1) integrado, con media cero y con volatilidad incondicional cero.

Las fórmulas genéricas del modelo GARCH(a,b) son⁷ :

$$r_t = \delta + \sum_{i=1}^p \phi_i r_{t-i} + \sum_{j=1}^q \theta_j v_{t-j} + v_t \quad (1)$$

$$v_t = \sigma_t \varepsilon_t \quad \text{con } \varepsilon_t \sim N(0,1)$$

$$\sigma_t^2 = \omega + \sum_{i=1}^a \beta_i \sigma_{t-i}^2 + \sum_{j=1}^b \alpha_j v_{t-j}^2 \quad (2)$$

Donde la media de los retornos r_t se estima por medio de un modelo ARMA (p,q) con perturbación v_t determinada por una innovación ε_t distribuida como Normal (0,1).

⁵ Ver Zangari y Longerstaeey (1996), Mina y Xiao (2001) y Zumbach (2007).

⁶ Ver Bollerslev, Engle y Nelson (1994).

⁷ Ver Bollerslev (1986).

Dicha perturbación v_t queda determinada por el producto de la innovación ε_t y la volatilidad condicional σ_t , la cual se modela en forma similar a un modelo ARMA (a,b), pero referido a los valores pasados de la perturbación y la volatilidad condicional. Esta especificación es la que hace depender a la varianza condicional de hoy de la varianza condicional de ayer y del valor de ayer de la perturbación.

En el caso del modelo adoptado por Riskmetrics, los valores de δ , ϕ_1 y θ_j son todos nulos, por lo que el retorno es directamente igual a la perturbación. Además la varianza incondicional ω es cero, mientras que los únicos valores β_1 y α_j no nulos son los de primer orden β_1 y α_1 y estos están restringidos a sumar 1, es decir $\beta_1 + \alpha_1 = 1$. Dejando de lado los subíndices y adoptando la letra λ para el coeficiente β_1 , el modelo quedaría :

$$r_t = \sigma_t \varepsilon_t \quad \text{con} \quad \varepsilon_t \sim N(0,1) \quad (3)$$

$$\sigma_t^2 = \lambda \sigma_{t-1}^2 + (1-\lambda) r_{t-1}^2 \quad 0 < \lambda < 1 \quad (4)$$

Además el coeficiente λ suele fijarse en lugar de estimarlo. El valor usual es $\lambda = 0,94$.

Este método equivale a lo que en estadística se denomina "suavizado exponencial", dado que si se reemplaza en las fórmulas anteriores σ_t por sus valores pasados σ_{t-i} se obtiene dicha varianza condicional σ_t como un valor promedio ponderado en forma exponencialmente decreciente de los retornos pasados:

$$\begin{aligned} \sigma_{t-1}^2 &= \lambda \sigma_{t-2}^2 + (1-\lambda) r_{t-2}^2 \\ \sigma_t^2 &= \lambda \sigma_{t-1}^2 + (1-\lambda) r_{t-1}^2 = \lambda^2 \sigma_{t-2}^2 + \lambda(1-\lambda) r_{t-2}^2 + (1-\lambda) r_{t-1}^2 \\ &\dots\dots\dots \\ \sigma_t^2 &= \lambda^k \sigma_{t-k}^2 + \sum_{j=1}^k \lambda^{j-1} (1-\lambda) r_{t-j}^2 \\ \sigma_t^2 &= \sum_{j=1}^{\infty} \lambda^{j-1} (1-\lambda) r_{t-j}^2 \end{aligned} \quad (5)$$

Con este modelo se calcula para cada período la varianza condicional σ_t y con ella el VaR como:

$$VaR(p) = \left| z_p \sigma_t \right| \quad (6)$$

donde z_p toma el valor -1,645 para $p = 95 \%$ y el valor -2,326 para $p = 99 \%$ (valores correspondientes a la normal estándar).

Si bien la elección del modelo IGARCH(1,1) (en el cual la I, de “integrado”, corresponde a la restricción de que la suma de los coeficientes sea igual a 1) ha demostrado ser adecuada para los casos de volatilidad persistente⁸, las simplificaciones asumidas parecen exageradas.

Por una parte la exigencia de que la media de los retornos sea nula choca con los valores empíricos positivos en el caso de los índices nominales en países con inflación. Por otra parte la rigidez de los coeficientes fijos (e incluso predeterminados por el método) impide su actualización cuando los mercados cambian su estructura, lo que le impide flexibilidad en la especificación. Finalmente, el método asume una distribución normal, lo que es claramente inadecuado para la estimación de retornos financieros, típicamente leptocúrticos.

Sin embargo, su simplicidad, el hecho de que sea muy difundido y popular, brinda un lenguaje común para la medición del riesgo.

2.3 Modelo GARCH(1,1)

Dado que la especificación del método Riskmetrics resulta un poco rígida (aunque simple, que es su objetivo principal), también se experimentará con un modelo GARCH(1,1) con media modelada mediante un proceso AR(1). En el mismo se estimarán los parámetros cada día con la información pasada disponible. Se utilizará una muestra móvil de 250 observaciones.

$$r_t = \delta + \phi_1 r_{t-1} + v_t \quad (7)$$

$$v_t = \sigma_t \varepsilon_t \quad \text{con } \varepsilon_t \sim N(0,1)$$

$$\sigma_t^2 = \omega + \beta \sigma_{t-1}^2 + \alpha v_{t-1}^2 \quad (8)$$

Con este modelo se calcula para cada período la estimación de la varianza condicional y la media estimada y con esto el VaR de interés

$$VaR(p) = \left| r_t + z_p \sigma_t \right| \quad (9)$$

donde z_p toma el valor -1,645 para $p = 95 \%$ y el valor -2,326 para $p = 99 \%$

Las ventajas de esta especificación consisten en su flexibilidad (La media de los retornos no necesariamente es nula, la volatilidad condicional tampoco y no hay una restricción sobre los valores de α y β) y la posibilidad de estimar los parámetros día por día, para reflejar los cambios del proceso subyacente (muestra variable ó rolling sample).

⁸ Ver Engle y Bollerslev (1986).

Como desventaja se señala que el modelo asume una perturbación normal, lo que es claramente inadecuado para la estimación de retornos financieros, típicamente leptocúrticos y asimétricos. Esto podría mejorarse permitiendo que la distribución fuera una distribución t, con grados de libertad estimados, y también agregando un término en el modelo que diera cuenta de la asimetría en la respuesta a retornos negativos y positivos.

Por tanto se ha estimado también un modelo Garch(1,1) con distribución t de Student⁹. En este caso la distribución de la perturbación ε_t se distribuye como una distribución t de Student con ν grados de libertad. El parámetro ν se estima para cada período por el método de máxima verosimilitud.

También se ha probado incorporar a la ecuación de la volatilidad condicional un término de asimetría, que en este caso pondera la diferente respuesta de la misma a retornos negativos y positivos. El modelo se denomina TGarch(1,1) y en un primer intento se modela con ε_t distribuido como normal estándar.

$$\sigma_t^2 = \omega + \beta \sigma_{t-1}^2 + \alpha v_{t-1}^2 + \delta I_{t-1} v_{t-1}^2 \quad (10)$$

Donde I_t es una variable indicadora que vale $I_t = 1$ si $v_t < 1$

Finalmente se ha estimado un modelo TGarch(1,1) con distribución t. Como en el caso del Garch(1,1) con distribución t, el parámetro ν se estima para cada período por el método de máxima verosimilitud.

Por lo tanto para esta metodología estimaremos 4 modelos, a saber:

- Garch(1,1) simétrico con distribución normal de las perturbaciones
- Garch(1,1) simétrico con distribución t de Student de las perturbaciones
- Garch(1,1) asimétrico con distribución normal de las perturbaciones
- Garch(1,1) asimétrico con distribución t de Student de las perturbaciones

2.4 Metodología CAViaR

Finalmente, estos métodos que podrían considerarse tradicionales se compararán con el método CAViaR (Valor a Riesgo Condicional Autorregresivo) propuesto por Engle y Manganelli. En este caso, la metodología consiste en evaluar directamente el cuantil de interés, condicional en variables que lo determinan. Este método se basa

⁹ Esta distribución se adopta por el solo hecho de ser leptocúrtica, lo cual permite ajustar mejor los valores empíricos. No se está implicando aquí una normalidad de base en la perturbación. También se estila ajustar los retornos con otras distribuciones, por ejemplo la Distribución Generalizada del Error (GED) que permite distintos grados de leptocurtosis.

en la relativamente reciente metodología de estimación por cuantiles, desarrollada por Koenker y Bassett ¹⁰. La motivación es que la estimación directa del cuantil permitirá obtener valores más precisos para el mismo.

Engle y Manganelli proponen cuatro modelos alternativos para su metodología, de los cuales hemos seleccionado 3, con base en pruebas preliminares:

Modelo 1) Modelo de valor absoluto, simétrico

$$Q_t(p) = \beta_1 + \beta_2 Q_{t-1}(p) + \beta_3 |r_{t-1}| \quad (11)$$

En este caso el cuantil de interés se modela con base en el valor del cuantil del período anterior, lo cual le da al modelo la inercia característica de los modelos autorregresivos, y se incluye el retorno del período anterior en valor absoluto, lo cual permite un término más dinámico que refiere a la innovación.

2) Modelo de valor absoluto, asimétrico

$$Q_t(p) = \beta_1 + \beta_2 Q_{t-1}(p) + \beta_3 r_{t-1}^+ + \beta_4 r_{t-1}^- \quad (12)$$

En este caso el cuantil de interés se modela con base en el valor del cuantil del período anterior, y se incluyen dos términos separados para retornos positivos y negativos, permitiendo así una respuesta diferenciada.

3) Modelo Garch(1,1), indirecto

$$Q_t^\theta = \sqrt{\beta_1 + \beta_2 (Q_{t-1}^\theta)^2 + \beta_3 r_{t-1}^2} \quad (13)$$

Este modelo adopta su nombre del parecido de su especificación con el modelo Garch(1,1), aunque en este caso lo que se estima es el cuantil y no la volatilidad.

En los tres casos el vector de parámetros β , el cual incluye los parámetros β_j de cada modelo, es estimado minimizando la siguiente expresión:

$$\min \frac{1}{T} \left[\sum_{r_t \geq x_t' \beta} \theta |r_t - x_t' \beta| + \sum_{r_t < x_t' \beta} (1-\theta) |r_t - x_t' \beta| \right] \quad (14)$$

O sea que la regresión por cuantiles, tal como la diseñaron Koenker y Bassett consiste en la minimización de una expresión que no es la suma de los residuos al cuadrado sino una suma

¹⁰ Koenker y Bassett (1978).

ponderada de los valores absolutos de los residuos. Por ejemplo para encontrar el cuantil 0,5 (la mediana) se plantea la minimización de los valores absolutos de los residuos. En este, el caso más simple, la ponderación es la misma para todos los residuos.

Dado que se está modelando directamente los cuantiles, en teoría, el método *CAViaR* sería más robusto a especificaciones del proceso de retornos, especialmente a cambios de régimen que pudieran ocurrir.

3. Resultados obtenidos

Se trabajó con la serie de retornos logarítmicos del índice Merval, para el período que va del 26/10/2011 al 17/12/2014 (750 observaciones). Se determinaron los VaR a un día, con valores de confianza del 95 % y del 99 %. A estos valores les corresponden los percentiles 5 y 1 respectivamente. (Cuando se refieren como cuantiles, estos son los cuantiles 0,05 y 0,01).

Los primeros 250 valores (correspondientes aproximadamente a un año calendario) se utilizaron para estimar el VaR correspondiente al período 251 y luego se fue corriendo la muestra, incorporando la observación 251 y descartando la nro. 1, de modo tal de contar en todos los casos con 250 observaciones (rolling sample).

Con este esquema se implementó el método histórico consistente en la estimación directa del cuantil, lo cual se realizó con una hoja de cálculo Excel.

En forma similar, y también con la planilla Excel se estimaron los VaR del método Riskmetrics. Aquí no se necesitó estimar parámetros para calcular los valores de la Varianza Condicional, ya que estos son fijos.

Luego se implementó el modelo GARCH(1,1). Utilizando una muestra móvil de 250 observaciones fue estimando diariamente los parámetros del modelo y pronosticando los valores de la volatilidad. Con estos datos se calcularon los VaR día por día en los 500 últimos días hábiles. Esto se implementó con el software econométrico Eviews, con una programación ad hoc.

Finalmente se implementaron los 2 modelos *CAViaR*, el absoluto simétrico y el absoluto asimétrico. Para ello se utilizó una versión modificada del software diseñado por Engle y Manganelli, quienes gentilmente lo han puesto a disposición pública. Este programa corre en Matlab y parte de sus rutinas se han implementado en el programa C.

Se computaron para cada método las llamadas “excepciones”, o sea las ocasiones en que el retorno fue menor que el VaR estimado. Estas serían las ocasiones en que el método “falla”. Por definición la proporción de excepciones debería aproximar el valor de 0,05 para el caso del VaR al 95 % y 0,01 para el caso del VaR al 99 %. En nuestro caso, al tener 500 observaciones, dichas proporciones se corresponden con 25 y 5 excepciones respectivamente.

Los resultados obtenidos fueron los siguientes:

Cuadro 1. Proporción de excepciones para los modelos ensayados

Var 95	Histórico	Riskmetrics	Garch(1,1) Normal Simétrico	Garch(1,1) Dist. T Simétrico	Garch(1,1) Normal Asimétrico	Garch(1,1) Dist. T Asimétrico	CAViaR Simétrico	CAViaR Asimétrico	CAViaR Garch Indirecto
Var 95 %	0,070	<u>0,056</u>	0,068	0,052	0,075	<u>0,056</u>	0,072	0,058	<u>0,056</u>
Var 99 %	0,030	0,026	0,026	0,018	0,030	0,022	<u>0,016</u>	0,018	0,012

Fuente: Elaboración propia.

En el cuadro aparecen en negrita los mejores valores de las excepciones, los que corresponden al modelo Garch(1,1) simétrico con distribución t para el caso del VaR al 95 % y al modelo CAViaR tipo Garch indirecto para el caso del VaR al 99 %. También se han señalado con itálica y subrayado los modelos que ocupan una segunda posición. Para el VaR al 99 % el modelo segundo mejor es el CAViaR simétrico. Para el VaR al 95 %, por su parte, ocupan la segunda posición los modelos Riskmetrics, Garch(1,1) asimétrico con distribución t y el CAViaR tipo Garch indirecto.

4. Conclusiones

El método Garch(1,1) con distribución t aparece como el modelo más adecuado para la modelización del VaR al 95 %, así como tiene un desempeño relativamente bueno en el caso del VaR al 99 %.

El método CAViaR aparece como un modelo interesante, especialmente para el caso de los VaR con altos niveles de confianza, caso en el que los otros métodos son menos eficientes.

La superioridad del desempeño de los modelos simétricos sobre los modelos asimétricos en la mayoría de los casos parece indicar la poca importancia, para el caso de los retornos del índice Merval, de considerar la distinta respuesta de la volatilidad a los retornos positivos y negativos.

El buen desempeño del modelo Riskmetrics para el VaR al 95 % es llamativa, sobre todo su superioridad respecto del modelo GARCH(1,1) Normal Simétrico, con quien comparte supuestos de distribución. Dada la flexibilidad de este último (los parámetros se estiman período a período) hubiera sido esperable del mismo un comportamiento al menos tan bueno como el de Riskmetrics.

5. Temas pendientes a investigar a futuro

Si bien en este trabajo hemos testado varios modelos, quedan muchos temas a indagar. Uno de ellos es el desempeño de las distintas especificaciones para el caso de VaR a varios días de plazo. En este caso, el uso de retornos diarios para las estimaciones se justifica por la mayor

precisión de las mismas para el mismo intervalo de datos. Sin embargo, la forma de deducir el VaR a 5 días por ejemplo, utilizando datos diarios varía de modelo a modelo.

Otro de los temas que deberían abordarse es el de otros modelos disponibles de regresión por cuantiles, aplicables a la estimación del VaR, por ejemplo el modelo QAR de Koenker y Xiao (2006).

Sería útil también Incorporar otras metodologías de comparación alternativas al Backtesting, como por ejemplo el método del “percentil dinámico” propuesto como estadístico comparativo por los diseñadores del método CAViaR.

También es posible ampliar el período de análisis para verificar si existen diferentes desempeños de los modelos dependiendo de las alternativas del proceso económico, distinguiendo períodos calmos de períodos turbulentos.

Finalmente, en este trabajo se ha optado por fijar la muestra para las estimaciones en 250 observaciones (1 año) por consideraciones teóricas. Sin embargo puede ser posible que cada modelo tenga una longitud de muestra óptima para el caso de nuestro mercado financiero. Este es otro de los análisis que será interesante abordar en futuras investigaciones.

Referencias bibliográficas

- Allen, D. y Singh, A. (2010) CAViaR and the Australian stock markets: An appetiser. Available at SSRN : <http://ssrn.com/abstract=1601654>.
- Bollerslev, T. (1986). Generalized autoregressive conditional heteroskedasticity. *Journal of Econometrics* 31: 307–327.
- Bollerslev, T., Engle, R. y Nelson, D. (1994). *ARCH models*. Handbook of econometrics, 4, 2959-3038.
- Engle, R. (1982). Autoregressive conditional heteroscedasticity with estimates of the variance of United Kingdom inflation. *Econometrica* 50, 4: 987–1007.
- Engle, R. y Bollerslev, T. (1986). Modelling the persistence of conditional variances. *Econometric Reviews*, 5(1), 1-50.
- Engle, R. y Manganelli, S. (2004) CAViaR: Conditional autoregressive value at risk by regression quantiles. *Journal of Business & Economic Statistics*, vol. 22, no 4, p. 367-381.
- Koenker, R. y Bassett, G (1978) Regression quantiles. *Econometrica: Journal of the Econometric Society*, p. 33-50.
- Koenker, R. y Xiao, Z. (2006) Quantile autoregression. *Journal of the American Statistical Association*, vol. 101, no 475, p. 980-990.

Lima, L. y Neri, B. (2006) *Comparing value-at-risk methodologies*. Methodologies (No. 629). FGV/EPGE Escola Brasileira de Economia e Finanças, Getulio Vargas Foundation (Brazil)

Mina, J. y Xiao, J. (2001) Return to RiskMetrics. The Evolution of a Standard. *RiskMetrics Group, New York (www.riskmetrics.com)*

Zangari, P. y Longestaey, J. (1996) Riskmetrics technical document. *New York: Morgan Guaranty Trust Company*

Zevallos, M. (2012) Estimación del riesgo bursátil peruano. *Economía* vol. 31, no 62, p. 109-126.

Zumbach, G. (2007) A gentle introduction to the RM 2006 methodology, *RiskMetrics Working Paper*.