

UNA EVALUACIÓN DE LOS MODELOS DE PROYECCIÓN DEL PRECIO DEL COBRE: ¿PODEMOS IR MÁS ALLÁ DE LA AUTORREGRESIÓN?*

Eduardo López E.**
Ercio Muñoz S.***
Víctor Riquelme P.****

I. INTRODUCCIÓN

La proyección del precio del cobre tiene una importancia fundamental en la definición del escenario externo que enfrenta la economía chilena. En consecuencia, los ejercicios de evaluación de diferentes metodologías de proyección son cruciales para obtener el mejor precio proyectado posible para el cobre dentro del horizonte de política del Banco Central. Asimismo, este ejercicio permite establecer las ventajas de cada una de las metodologías, su capacidad de predicción relativa y, en definitiva, balancearlas para que puedan ser utilizadas como referente metodológico predictivo.

Engel y Valdés (2001) comparan la capacidad predictiva de mediano plazo (uno a cinco años) de una variada gama de modelos de series de tiempo para el precio del cobre, basados en el criterio del error cuadrático medio de predicciones fuera de muestra. Los autores presentan evidencia que sugiere que los modelos de series de tiempo entregan mejores predicciones de mediano plazo que los modelos econométricos, y concluyen que los dos modelos con mejor capacidad predictiva son el proceso autorregresivo de primer orden y el camino aleatorio.

Tomando como punto de partida estos resultados, el propósito de esta nota es expandir el análisis de Engel y Valdés para incluir modelos de proyección de forma reducida, los cuales incorporan en su estructura información de otras variables explicativas, además de la historia del precio del cobre. Para ello, se consideran criterios de precisión y eficiencia de los modelos utilizados. La evidencia obtenida es útil, pues nos permite evaluar el horizonte relativo de proyección en que cada metodología reporta su mejor desempeño.

El trabajo se organiza de la siguiente manera. En la sección II se presentan los modelos y proyecciones a evaluar. En este contexto, se consideran en la evaluación, en primer lugar, metodologías de proyección basadas en modelos de series de tiempo univariados¹ (uso exclusivo del precio real del cobre); en segundo lugar, los modelos mixtos de De Gregorio et al. (2005), López et al. (2009), y López y Riquelme (2010); y, en tercer lugar, y en contraposición con las metodologías basadas en modelos econométricos, se considera el uso de la información que proveen los contratos de futuros de cobre. En la sección III, se describen los datos usados para los distintos modelos, se establecen los criterios de evaluación y se analizan los resultados obtenidos. Finalmente, en la sección IV se presentan las principales conclusiones.

* Agradecemos los comentarios y sugerencias de Pablo Pincheira, Sergio Lehmann, y Alfredo Pistelli a versiones preliminares de este trabajo. Cualquier error remanente es de exclusiva responsabilidad de los autores.

** Gerencia de Análisis Internacional, Banco Central de Chile. E-mail: elopez@bcentral.cl

*** Gerencia de Análisis Internacional, Banco Central de Chile. E-mail: emunoz@bcentral.cl

**** A la fecha de la redacción de este documento, Gerencia de Análisis Internacional, Banco Central de Chile. E-mail: vriquelme@bcentral.cl

1. La literatura predictiva en diversos campos de la economía ha hecho uso intensivo de los modelos univariados a la hora de evaluar predictibilidad. En esta línea, por citar un par de ejemplos, Meese y Rogoff (1983) encuentran que para proyectar el tipo de cambio del dólar sobre la libra, yen, marco y ponderado por socios comerciales en horizontes de 1 y 20 meses, un modelo random walk predice de forma similar a los modelos estructurales. Por otra parte, Pincheira (2010), al realizar una evaluación en tiempo real de las proyecciones de crecimiento del producto efectuadas por el Banco Central de Chile encuentra que para el horizonte de un período adelante el modelo random walk supera las proyecciones del BCCh en algunas ventanas, aunque no encuentra un solo modelo de series de tiempo que lo haga mejor en todos los ejercicios.

II. MODELOS PARA EL PRECIO DEL COBRE

En esta sección describimos los modelos que serán evaluados. Con ese fin, hemos definido una taxonomía que se sustenta, en un primer nivel, en proyecciones basadas en el uso de modelos econométricos *vis-à-vis* proyecciones de carácter no econométrico. En un segundo nivel, y principalmente en el caso de los modelos econométricos, distinguimos según la incorporación de información superior a la que brinda la propia dinámica del precio.

Una primera familia de modelos considerada en nuestro análisis es aquella cuyas proyecciones se derivan de la información proveniente exclusivamente de las propiedades estadísticas del comportamiento de la serie del precio real del cobre. Para estos efectos, y de acuerdo con Engel y Valdés (2001) consideramos distintas especificaciones de procesos autorregresivos de orden p ($AR(p)$) con y sin tendencia, de entre los cuales se escogerá el mejor como *benchmark*, en base a los criterios de precisión que expondremos adelante (ver subsección III.2).

Una segunda familia de modelos considerada en este análisis es la generada a partir de ecuaciones reducidas para el precio del cobre que incorporan una especificación dinámica compleja, como la inclusión de los fundamentos de largo plazo, así como de variables que explican los movimientos de corto plazo. Un primer modelo de este tipo es el expuesto en De Gregorio et al. (2005) (en adelante, DGJ), en donde se estima un modelo en niveles y primeras diferencias en los términos de Pesaran y Shin (1999), para el retorno del precio real en función del rezago del precio real (p), el valor del dólar multilateral (e), y la razón de producción industrial (y) a inventarios en bolsa (inv), y rezagos del retorno del precio:

$$DGJ: \Delta p_t = a_0 + a_1 \times \frac{y_{t-1}}{inv_{t-1}} + a_2 \times e_{t-1} + a_3 \times p_{t-1} + a_4 \times \Delta p_{t-1}$$

Un segundo modelo es el documentado en López et al. (2009), (en adelante, LMR) que plantea un modelo estilizado, estimado mediante un enfoque de corrección de errores para el precio real del cobre. El modelo controla por la evolución de los inventarios en bolsa como porcentaje de la demanda global ($rinv$), el valor real del dólar multilateral (e), el retorno sobre un portafolio de inversiones alternativas (R), el apetito por riesgo (AR), la proyección del desbalance esperado para el año siguiente (1) entre el consumo y la producción globales, ($E_t(C_1^w - S_1^w)$), y el precio de otros metales (P^{MET})

$$LMR: \Delta p_t = \delta_1 \Delta R_{t-1} + \phi_0 \Delta AR_t + \varphi_0 \Delta P_{t-1}^{MET} \\ + \alpha_0 (p_{t-1} - \lambda_0 - \lambda_2 \cdot rinv_{t-1} - \lambda_3 \cdot e_{t-1} - \lambda_4 \cdot E_t(C_1^w - S_1^w)) + \omega_t$$

Además de estos modelos, se considera el presentado en López y Riquelme (2010) (en adelante, LR), el cual se basa en la metodología de estimación expuesta en Pesaran et al. (2001), y cuyos determinantes son la razón de inventarios en bolsa a demanda ($rinv$), los costos de producción (x), el valor real del dólar multilateral (e), la producción industrial de los principales consumidores (y), las tasas de interés de los bonos del Tesoro (r), y el índice de aversión al riesgo (AR).

$$LR: \Delta p_t = \beta_0 + \beta_1 (p_{t-1} - \alpha_2 y_{t-1} - \alpha_3 e_{t-1} - \alpha_4 x_{t-1} - \alpha_5 r_{t-1} - \alpha_6 rinv_{t-1}) \\ + \theta_1 \Delta e_t + \theta_2 \Delta y_t + \theta_3 \Delta x_t + \theta_4 \Delta r_t + \theta_5 \Delta AR_t + \nu_t$$

Finalmente, consideramos en nuestra evaluación la información contenida en los precios de los contratos futuros de cobre, de modo de considerar el precio futuro como indicador de las expectativas del mercado para diferentes horizontes de tiempo.

III. METODOLOGÍA DE EVALUACIÓN

1. Los Datos

Algunas fuentes de diferenciación entre los modelos considerados en el análisis son el período muestral utilizado y la medición de algunas variables comunes (por ejemplo, la producción industrial, los ratios de inventarios y la medición del índice del dólar). Así, con el fin de hacer competir los modelos bajo las mismas condiciones, se optó por evaluar todos los modelos con una base de datos común para todos. En las estimaciones se utilizaron datos trimestrales que cubren desde el primer trimestre del 2000 al cuarto del 2010.²

La serie nominal de precios de cobre se obtuvo a partir de información de la Bolsa de Metales de Londres. Se ha utilizado como deflactor el índice de precios al productor (IPP) de Estados Unidos. Para la ventana de proyección relevante de análisis, esto es, desde el tercer trimestre del 2006 y hasta el cuarto trimestre del 2010, la serie presenta una media de US\$c307/lb, destacando su alta desviación estándar (US\$c66/lb), 38 centavos mayor si se compara con el período 1986.I-2005.IV, por ejemplo (cuando la desviación estándar fue de US\$c28/lb).³

La variable utilizada para capturar el efecto del dólar real multilateral es un indicador de tipo de cambio real de EE.UU. versus las principales monedas del mundo. El indicador de demanda global es medido como el promedio ponderado del índice de producción industrial desestacionalizado de los cinco bloques principales⁴ en el consumo global de cobre, y donde los ponderadores se calculan en base a la información de la demanda anual de los principales consumidores para los años respectivos. La serie de inventarios corresponde a la suma desestacionalizada de los inventarios en las bolsas de Nueva York (COMEX), Shanghai (SHX), y Londres (BML). Los costos de producción corresponden a una extrapolación de datos anuales provistos por Cochilco.

Para captar el efecto de los factores financieros, tal como lo incluyen LMR y LR, se considera un indicador de rendimiento de activos alternativos (r_f) que se construyó considerando un portafolio balanceado compuesto de índices bursátiles de bolsas desarrolladas (S&P500), bolsas emergentes (MSCI), bonos de renta fija globales de países desarrollados (GBI) y de economías emergentes (EMBIG). Otra variable de carácter financiero, relevante para el precio de las materias primas, es la percepción de riesgo por parte de los inversionistas (AR). Su inclusión se justifica en que comúnmente se postula que los movimientos de corto plazo del precio guardan relación con el carácter de activo financiero del cobre. Para aproximar esta variable se utilizó el índice VIX, que mide la volatilidad esperada sobre el índice accionario S&P y, desde este punto de vista, es una *proxy* del grado de aversión al riesgo prevaleciente en el mercado; se espera que dicha variable afecte negativamente al precio de la materia prima.

Para la aproximación del término prospectivo (*forward-looking*) que incluyen LMR y LR se consideró, respectivamente, la proyección para el consumo y la producción global, y sus revisiones intraanuales reportadas por Cochilco y CRU; en tanto que para LR, se consideraron las proyecciones de precios para el promedio del año siguiente reportadas por CRU.

2. Evaluación

La capacidad predictiva de los distintos modelos se evalúa considerando los criterios de precisión y eficiencia de las proyecciones. Con respecto a la precisión, se usan medidas de la raíz del error de proyección cuadrático medio (REPCM) y de la media del error absoluto de proyección (MEAP). En cuanto a la eficiencia, se utilizan las medidas de Sesgo y Autocorrelación de los errores.

2. Esta elección se debe a que solamente existe disponibilidad de datos para algunas series desde este período hacia adelante. En el caso de los modelos de series de tiempo, no obstante se usan datos desde 1986t1, lo cual puede constituir una condición más favorable para estos modelos, en la medida que se ha considerado una historia más larga para el precio del cobre y el precio del petróleo.

3. En el Apéndice B se discute las implicancias de esta muestra con respecto a su tamaño y comportamiento.

4. Estos bloques son: Eurozona, Estados Unidos, China, Japón y Asia Emergente excluyendo China.

Nuestro ejercicio de capacidad predictiva es realizado fuera de la muestra. Ello se justifica por las críticas habituales que recibe la evaluación “dentro de muestra” principalmente asociadas al sobreajuste inducido por una búsqueda de significancia estadística sobre una misma muestra, comúnmente llamado “*data mining-induced overfitting*” (ver Abarca et al. 2007). No obstante, debemos precisar que éstos ejercicios son “pseudo” fuera de la muestra,⁵ debido a que son realizados con datos revisados y con algunas variables explicativas desestacionalizadas, usando la serie completa, incluido los valores que corresponden a la ventana de proyección, lo que genera condiciones de certidumbre que hacen diferir el ejercicio de un experimento en tiempo real (Pincheira y Calani, 2010).

Los resultados de la evaluación de capacidad predictiva para los diferentes modelos de obtienen de proyecciones hacia delante a diferentes horizontes (uno, cuatro y ocho trimestres), considerando 18 trimestres que van desde el tercero del año 2006 hasta el cuarto del 2010.⁶

Precisión

La evaluación se realiza mediante el cálculo de la raíz del error de proyección cuadrático medio,⁷ que se define como:

$$REPCM = \sqrt{\sum_{i=1}^n \frac{\left(\frac{p_i - \hat{p}_i}{p_i} * 100 \right)^2}{n}}$$

donde p corresponde al precio efectivo a un horizonte dado, y \hat{p}_i es el valor proyectado al mismo horizonte. Para ello, se divide la muestra de T observaciones en dos partes: una es la ventana de estimación correspondiente a $T - n$, y la otra es la ventana de proyección de tamaño n . Mediante un proceso de MCO recursivos,⁸ se estiman los coeficientes de la primera ventana de datos —es decir, información hasta $T - n$ — y proyectamos los valores desde $T - n + 1$ hasta $T - n + 8$. Luego se amplía la ventana de estimación en un dato hasta $T - n + 1$ para recalcular los coeficientes y proyectar $T - n + 2$ hasta $T - n + 9$. Este proceso continúa hasta que la ventana de estimación usa la muestra completa (T datos).

Una medida alternativa de la precisión de las proyecciones corresponde a la media del error absoluto de proyección, cuya diferencia radica en que penaliza los errores grandes de una forma menor que el REPCM, y se define de la siguiente manera:

$$MEAP = \sum_{i=1}^n \left(\frac{\left| \frac{p_i - \hat{p}_i}{p_i} * 100 \right|}{n} \right)$$

5. No obstante estas correcciones, el análisis fuera de la muestra también presenta algunas desventajas asociadas principalmente a la necesidad de dividir las muestras en dos ventanas llamadas de predicción y estimación. Esto, según se explica en Inoue y Kilian (2006) y Abarca et al. (2007), se debe a una pérdida de potencia en los test en relación al ejercicio “dentro de muestra” a causa de la reducción del número de observaciones para realizar la estimación.

6. Se escogió esta ventana debido a que ciertas series de algunos modelos estructurales están disponibles solo desde el año 2003.

7. El error está expresado en términos porcentuales.

8. El método de MCO recursivos agrega una observación en la ventana de estimación para cada período adicional a proyectar. Por ejemplo, si la primera proyección se basa en R observaciones, entonces la segunda proyección se basa en $R + 1$ observaciones, etc. En contraste, el método Rolling OLS preserva el tamaño de la ventana de estimación original, de forma que, si la primera proyección usa desde 1 hasta R observaciones, la segunda se basa en las observaciones desde la 2 a la $R + 1$, y así sucesivamente. (Rogoff y Stavrakeva, 2008)

El cuadro 1 presenta el REPCM y el MEAP para distintos modelos autorregresivos, con el fin de escoger un *benchmark* adecuado.⁹

CUADRO 1						
Raíz del Error de Proyección Cuadrático Medio y Media del Error Absoluto de Proyección para Modelos Autorregresivos Estudiados (porcentaje)						
AR(p)	REPCM			MEAP		
	1	4	8	1	4	8
AR(1)	24.34	50.60	57.70	15.32	37.74	49.71
AR(1) c/tend.	23.81	46.48	48.76	14.85	33.02	40.77
AR(2)	23.99	51.38	54.15	15.65	39.18	47.79
AR(2) c/tend.	23.13	46.60	45.63	14.55	33.57	39.22
AR(3)	22.51	51.44	56.67	14.26	38.89	50.07
AR(3) c/tend.	21.85	46.64	47.13	13.44	33.78	40.62
AR(4)	22.82	52.07	59.76	14.85	39.82	52.50
AR(4) c/tend.	22.18	47.06	48.88	14.00	34.75	42.20

Fuente: Cálculos de los autores.
En negrita, valores mínimos.

Los resultados de la comparación entre modelos autorregresivos (ver cuadro 1), entregan como *benchmark* (basado en el REPCM) para el horizonte 1 y 8 los procesos AR(3) con tendencia y AR(1) con tendencia para el horizonte 4.¹⁰

En el cuadro 2 se presentan los REPCM y MEAP, respectivamente, para todos los modelos comparados a los diferentes horizontes (panel 1), y los resultados del test de Diebold y Mariano (panel 2), los cuales permiten evaluar la diferencia estadística entre los distintos errores de proyección. Este primer ejercicio se realiza proyectando de forma “pseudo” fuera de muestra para todos los modelos en el horizonte 1, mientras desde el horizonte de 2 períodos adelante se realiza una estimación dinámica (para la variable independiente se usan valores previamente proyectados). En el caso de los modelos de series de tiempo, las proyecciones no econométricas no usan información dinámica ni efectiva, ya que se realizaron en tiempo real, mientras que los modelos de forma reducida usan información efectiva rezagada para las variables independientes (supuesto de *perfect foresight*, o perfecta capacidad predictiva), excepto para la dependiente rezagada que corresponde a su proyección mediante predicción dinámica.

Un primer resultado que vale la pena destacar, son los altos niveles de error de proyección presentes en todos los métodos, lo cual era esperable dada la alta volatilidad de la serie dentro de la ventana de proyección. Como se observa en el panel 1, a un horizonte de 1 período adelante ambas medidas de precisión correspondientes al modelo AR(3) con tendencia son las menores; sin embargo, de acuerdo al test de Diebold y Mariano, se observa que para dicho horizonte de proyección los errores no son estadísticamente distintos en ninguno de los modelos utilizados.

9. En el cuerpo del documento se presenta un resumen de los errores de predicción. Una representación gráfica de los ejercicios desarrollados se reporta en el Apéndice A.

10. Engel y Valdés (2001) encuentran un resultado similar, aunque su ventana de estimación es anterior a la nuestra.

CUADRO 2

**A. Raíz del Error de Proyección Cuadrático Medio,
y Media del Error Absoluto de Proyección para Modelos Analizados
(porcentaje)**

	Precisión de modelos alternativos					
	REPCM			MEAP		
	1	4	8	1	4	8
Modelo de Series de tiempo						
AR(3) c/tend.	21.85	46.64	47.13	13.44	33.78	40.62
AR(1) c/tend.	23.81	46.48	48.76	14.85	33.02	40.77
Modelo de forma reducida						
LMR	28.24	78.84	193.99	17.11	62.20	131.54
LR	22.20	40.79	40.37	13.71	29.16	35.34
DGJ	22.40	44.51	42.80	15.26	36.57	36.97
Proyección no econométrica						
Futuros	24.89	47.92	45.88	15.26	37.11	38.90

B. Test de Diebold y Mariano

	Período 1			
	AR (1)	AR (3)	DGJ	LMR
AR (3)	-1.536			
DGJ	-0.601	0.325		
LMR	1.438	1.718	1.328	
LR	-0.705	0.191	-0.149	-1.693
Período 4				
AR (3)	0.192			
DGJ	-0.397	-0.395		
LMR	2.832**	2.926**	2.358**	
LR	-1.227	-1.167	-0.739	-2.701**
Período 8				
AR (3)	-1.010			
DGJ	-0.686	-0.558		
LMR	1.797*	1.798*	1.773*	
LR	-2.135**	-1.929*	-0.361	-1.811*

Fuente: Cálculos de los autores.

En negrita, valores mínimos.

* significativo al 10%; ** significativo al 5%

En segundo lugar, destaca el hecho de que para los horizontes 4 y 8 el modelo LMR presenta peor desempeño y sus errores son estadísticamente distintos. Finalmente, para el último horizonte de proyección, el modelo LR reporta errores menores y estadísticamente distintos a los modelos de serie de tiempo; sin embargo, para este horizonte y el 4, no tiene errores estadísticamente distintos a DGJ.

Como se sabe, los modelos de series de tiempo tienen la ventaja de incorporar solo la información proveniente de la historia de la propia serie de tiempo, lo cual simplifica la tarea de proyección. Los modelos de forma reducida, por su parte, requieren la proyección de las variables explicativas para efectuar la evaluación. En este sentido, en los ejercicios anteriores el supuesto de perfecta capacidad predictiva empleado desde el horizonte 2 en adelante podría resultar en una ventaja espuria para los modelos de forma reducida, principalmente porque existe una dificultad extra para proyectar los valores de las variables independientes que se usan como *inputs*, lo que en algunos casos puede incrementar el error propio del modelo. Para analizar este punto realizamos un segundo ejercicio, consistente en proyectar las variables independientes mediante un proceso AR(1) (excepto la dependiente rezagada, la cual se proyecta automáticamente mediante proyección dinámica). Los resultados de este ejercicio se reportan en el cuadro 3.

CUADRO 3				
A. Precisión de modelos de forma reducida con incertidumbre en proyección de variables explicativas				
	REPCM		MEAP	
	4	8	4	8
LMR	134.78	474.82	79.92	314.10
LR	63.40	68.18	43.68	61.63
DGJ	44.53	40.97	36.34	34.12
B. Test de Diebold y Mariano				
Período 4				
	DGJ	LMR		
LMR	1.921*			
LR	1.479	-1.978*		
Período 8				
LMR	2.619*			
LR	2.601**	-2.613*		

Fuente: Cálculos de los autores.
 En negrita, valores mínimos.
 * significativo al 10%; ** significativo al 5%.

Un resultado que se mantiene bajo estas condiciones de incertidumbre es que el modelo LMR presenta peor desempeño en ambos horizontes, y su error es estadísticamente distinto al de los modelos alternativos. Sin embargo, a diferencia del caso anterior, bajo estas condiciones el modelo DGJ presenta mejor desempeño en cuatro trimestres hacia adelante, aunque los errores no son estadísticamente distintos a LR, tal como muestra el panel 2. Para el horizonte de mayor longitud (ocho trimestres), el modelo DGJ entrega mayor precisión según ambas medidas y esta diferencia es significativa con respecto a los dos modelos alternativos. Una posible explicación de este mejor desempeño de DGJ en condiciones de incertidumbre puede estar asociada a su mayor simplicidad y su limitado número de variables explicativas. Por último, en la ventana de proyección, DGJ arroja errores menores con incertidumbre debido principalmente a un problema de muestra finita y un quiebre importante en la serie de precios que es mejor capturado de manera puntual con los regresores proyectados mediante un proceso AR(1). Para chequear esto, estimamos el modelo

DGJ ampliando la ventana de proyección a 50 trimestres, lo cual da como resultado un patrón de errores coherente con el aumento de error que debe presentar la proyección cuando se agrega incertidumbre, versus el ejercicio de capacidad predictiva perfecta.¹¹

Eficiencia

La tercera medida de habilidad predictiva es el sesgo, el cual corresponde al error de proyección (valor efectivo menos valor proyectado en términos porcentuales) promedio. Esta medida está relacionada con la eficiencia de la proyección y se define de la siguiente forma:

$$SESGO = \sum_{i=1}^n \left(\frac{p_i - \hat{p}_i * 100}{p_i} \right) / n$$

El cuadro 4 entrega resultados del análisis de sesgo en distintos horizontes basado en el primer ejercicio con supuesto de predicción perfecta. Primero, los modelos de series de tiempo en promedio sobrestiman el precio en todos los horizontes analizados pero dicho valor no resulta estadísticamente distinto de cero. Por otro lado, la proyección del modelo LMR sobrestima el precio en todos los horizontes de manera estadísticamente significativa, el modelo DGJ subestima el precio proyectado a dos años, siendo este sesgo estadísticamente significativo y, por último, la proyección mediante los Futuros subestima el precio a dos años de manera significativa al 90%.

CUADRO 4			
Análisis de Sesgo			
	1	4	8
Modelo de Series de tiempo			
AR(3) c/tend.	-2.71	-6.33	-3.16
AR(1) c/tend.	-2.65	-4.97	-2.73
Modelo de forma reducida			
LMR	-11.38*	-49.70***	-127.95***
LR	-1.68	-2.43	-3.86
DGJ	1.43	10.86	27.23***
Proyección No econométricas			
Futuros	-1.50	3.19	18.59*

Fuente: Cálculos de los autores.
***Estadísticamente distinto de cero al 1%, ** al 5% y * al 10%.

11. En la ventana de proyección de 50 trimestres para el horizonte 4 trimestres adelante el RECMF es 33,8 versus 34,4 con predicción perfecta e incertidumbre. Para el horizonte de ocho trimestres adelante es 34,4 y 42,5 respectivamente.

El análisis de autocorrelación de los errores permite saber la probabilidad de cometer un error en la misma dirección de un período a otro. Para esto se realizan las siguientes regresiones, donde α es el parámetro de interés para cada horizonte.

Horizonte de 1 período adelante: $Error_t = \alpha * Error_{t-1} + \varepsilon_t$.

Horizonte de 4 períodos adelante: $Error_t = \alpha * Error_{t-4} + \varepsilon_t$.

Horizonte de 8 períodos adelante: $Error_t = \alpha * Error_{t-8} + \varepsilon_t$.

CUADRO 5						
Análisis de Autocorrelación de los Errores de Proyección						
	Modelos de series de tiempo		Modelos de forma reducida			Proyecciones no econométricas
	AR(3) c/tend.	AR(1) c/tend.	LRM	LR	DGJ	Futuros
Coefficiente	0.05	0.23	0.27	0.06	0.09	0.19
Error est.	0.25	0.24	0.24	0.25	0.25	0.24
Valor p	0.82	0.35	0.28	0.79	0.72	0.44
Coefficiente	-0.30	-0.33	0.14	-0.31	-0.43	-0.40
Error est.	0.26	0.26	0.27	0.26	0.26	0.25
Valor p	0.27	0.23	0.62	0.26	0.11	0.13
Coefficiente	-0.83	-0.84	1.80	-1.04	-0.25	-0.43
Error est.	0.23	0.24	1.00	0.33	0.17	0.15
Valor p	0.01	0.01	0.11	0.01	0.16	0.02

Fuente: Cálculos de los autores.
En negrita, valores significativamente distintos de 0 al 5%..

El cuadro 5 recopila los resultados del análisis de autocorrelación de los errores de proyección en el horizonte de uno, cuatro y ocho trimestres adelante. La primera conclusión de este ejercicio en cuanto a la eficiencia de los errores es que no existe autocorrelación en los horizontes uno y cuatro trimestres adelante, mientras que para el horizonte de ocho trimestres adelante existe una autocorrelación estadísticamente significativa, por lo que estas proyecciones podrían ser mejoradas incorporando este componente.

IV. CONCLUSIONES

Las principales conclusiones que se extraen de este trabajo son las siguientes:

- Al comparar las distintas metodologías se observan altos niveles de error de proyección para todos los horizontes considerados.
- Los análisis de series de tiempo indican que las representaciones AR(3) con tendencia y un AR(1) con tendencia predicen con mayor precisión la trayectoria del precio del cobre para los distintos horizontes evaluados. La significancia estadística de las diferencias entre los errores de proyección de cada modelo no permite discriminar entre ellos para proyectar el precio a un horizonte de un trimestre. Sin embargo, los errores cuadráticos medios del modelo AR(3) son los menores para este horizonte.
- Bajo condiciones de certidumbre respecto de las variables explicativas, LMR presenta errores mayores y estadísticamente distintos al resto de los modelos en los horizontes cuatro y ocho trimestres adelante.

En tanto, DGJ tiene mayor precisión en los horizontes cuatro y ocho trimestres adelante, pero su diferencia con LR es significativa estadísticamente solo para el mayor horizonte. Sin embargo, bajo condiciones de incertidumbre, el modelo DGJ presenta un mejor desempeño cuatro trimestres en adelante, aunque los errores no son estadísticamente distintos a LR, posiblemente asociado a su mayor simplicidad y su limitado número de variables explicativas. Esto evidencia el conflicto habitual entre el logro de la mejor capacidad predictiva pero con el riesgo de sobredimensionamiento en la especificación de los modelos.

En definitiva, considerando nuestra pregunta original, estas conclusiones señalan la importancia que tienen los modelos que incorporan una adecuada descripción de las variables explicativas (fundamentales o de corto plazo) en el proceso predictivo. En particular, para horizontes de un trimestre los modelos de series de tiempo serían una elección apropiada, en tanto que para horizontes superiores los modelos de forma reducida parecen ser los más adecuados.

No obstante, es necesario destacar que, debido principalmente a los problemas que surgen por el tamaño muestral y las propiedades de las proyecciones en muestra finita, estos resultados no permiten obtener una conclusión definitiva. Por esto resulta necesario seguir realizando estos ejercicios de evaluación a medida que se dispone de mayor disponibilidad de datos. Adicionalmente, una posible avenida de profundización de esta evaluación consiste en una revisión más exhaustiva en condiciones de tiempo real.



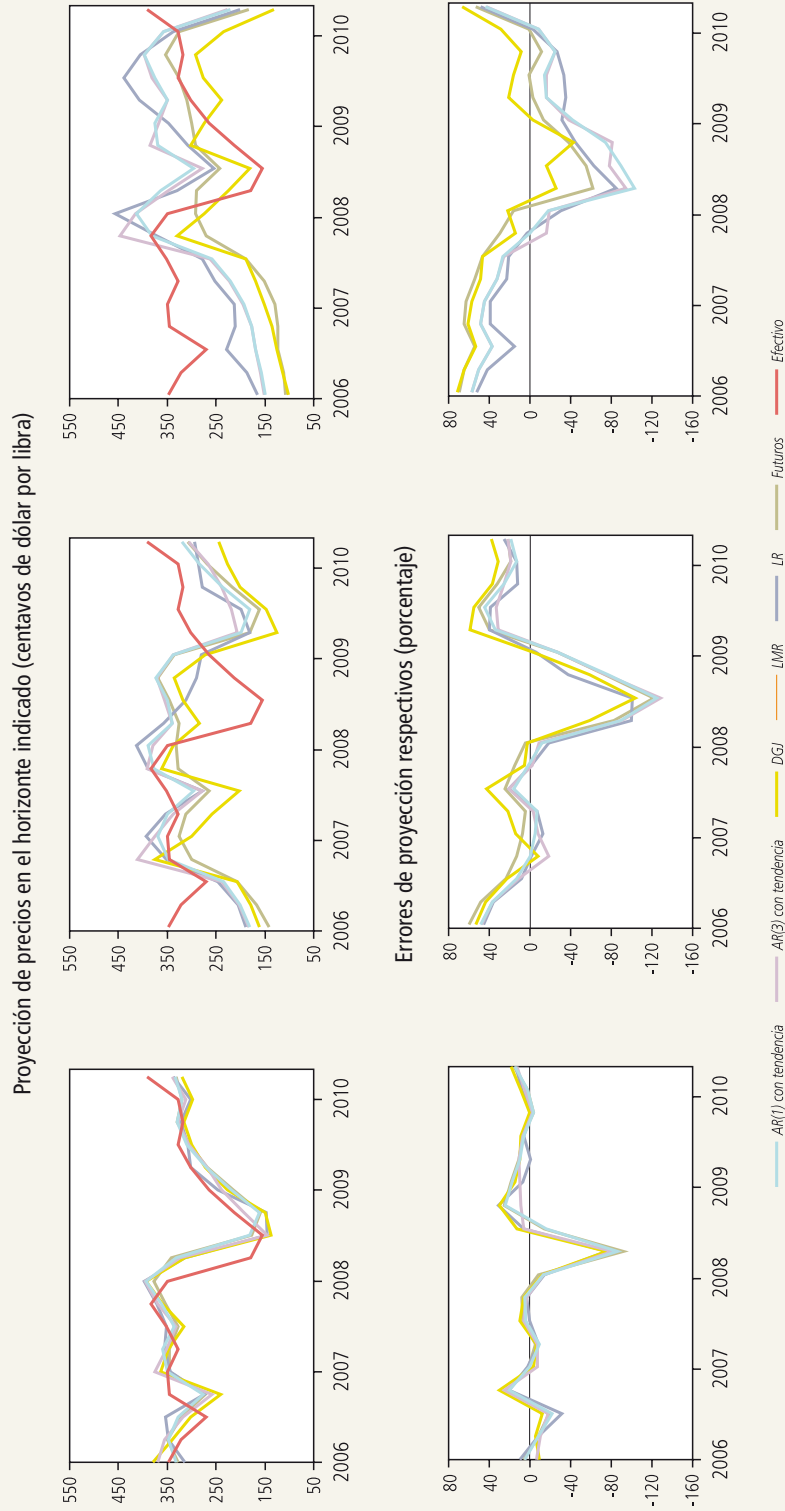
REFERENCIAS

- Abarca, A., F. Alarcón., P. Pincheira y J. Selaive (2007). “Tipo de Cambio Nominal Chileno: Predicción en Base a Análisis Técnico.” Documento de Trabajo N°425, Banco Central de Chile.
- Clements, M. y D. Hendry (1998). *Forecasting Economic Time Series*: Cambridge University Press.
- De Gregorio, J., F. Jaque y H. González (2005). “Fluctuaciones del Dólar, Precio del Cobre y Términos de Intercambio.” Documento de Trabajo N°310, Banco Central de Chile.
- Diebold, F.X. y J. López (1996). “Forecast Evaluation and Combination.” NBER Technical Working Papers N°0192.
- Diebold, F.X. (2007). *Elements of Forecasting*, tercera edición: Thomson/South Western.
- Engel, E. y R.O. Valdés (2001). “Prediciendo el Precio del Cobre: ¿Más Allá del Camino Aleatorio?” Documento de Trabajo N°100, Centro de Economía Aplicada, Universidad de Chile.
- Inoue, A. y L. Kilian (2006). “On the Selection of Forecasting Models.” *Journal of Econometrics* 130(2): 273–306.
- López, E., F. Meneses y V. Riquelme (2009). “Elasticidades de Precios de Productos Relevantes para la Economía Chilena.” *Economía Chilena* 12(3): 103–16.
- López, E. y V. Riquelme (2010). “Auge, Colapso y Recuperación de Precios de Materias Primas, ¿Qué Hay Detrás?” *Economía Chilena* 13(2): 129–45.
- Meese, R. y K. Rogoff (1983). “Empirical Exchange Rate Models of the Seventies, Do they Fit Out of Sample?” *Journal of International Economics* 14: 3–24.
- Patton, A. y A. Timmermann (2007). “Testing Forecast Optimality under Unknown Loss.” *Journal of the American Statistical Association* 102: 1172–84.
- Patton, A. y A. Timmermann (2011). “Predictability of Output Growth and Inflation: A Multi-horizon Survey Approach.” *Journal of Business and Economic Statistics* 29(3): 397-410.
- Pesaran M.H. e Y. Shin (1999). “An Autoregressive Distributed Lag Modelling Approach to Cointegration Analysis.” En *Econometrics and Economic Theory in the 20th Century*, The Ragnar Frisch Centennial Symposium: Cambridge University Press.
- Pesaran, M., Y. Shin y R. Smith (2001). “Bounds Testing Approaches to the Analysis of Level Relationships.” *Journal of Applied Econometrics* 16(3): 289–326.
- Pincheira, P. y M. Calani (2010) “Communicational Bias In Monetary Policy: Can Words Forecast Deeds?” *Economía* 11(1): 103-52.
- Pincheira, P. (2010) “A Real Time Evaluation of the Central Bank of Chile GDP Growth Forecasts.” *Money Affairs* XXIII(1): 37-73.
- Rogoff, K. y V. Stavrakeva (2008). “The Continuing Puzzle of Short Horizon Exchange Rate Forecasting.” NBER Working Paper N°14071.
- Schmidt, P. (1974). “The Asymptotic Distribution of Forecasts in the Dynamic Simulation of an Econometric Model.” *Econometrica* 42: 303–9.

APÉNDICE A

GRÁFICO A1

Proyecciones y Errores Predictivos de Modelos Alternativos



Fuente: Cálculo de los autores.

APÉNDICE B

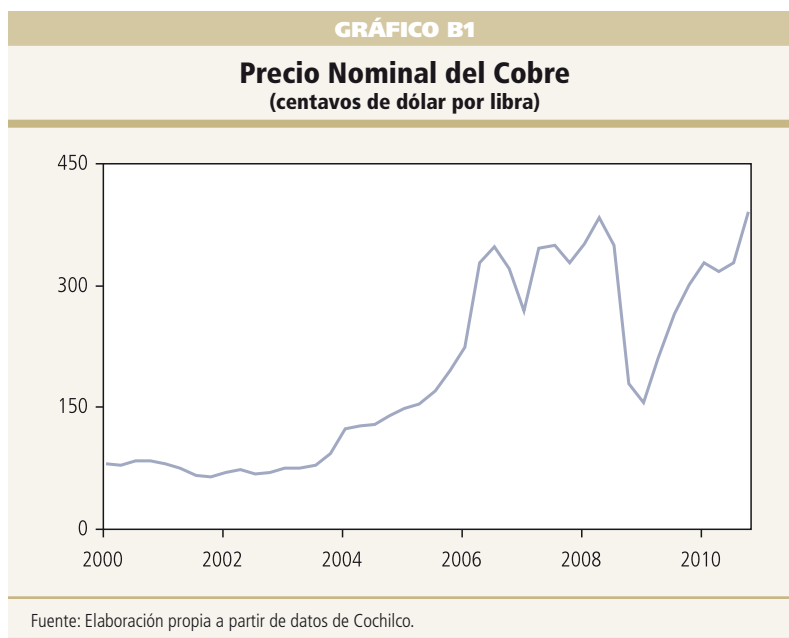
Algunos Comentarios Respecto de los Resultados

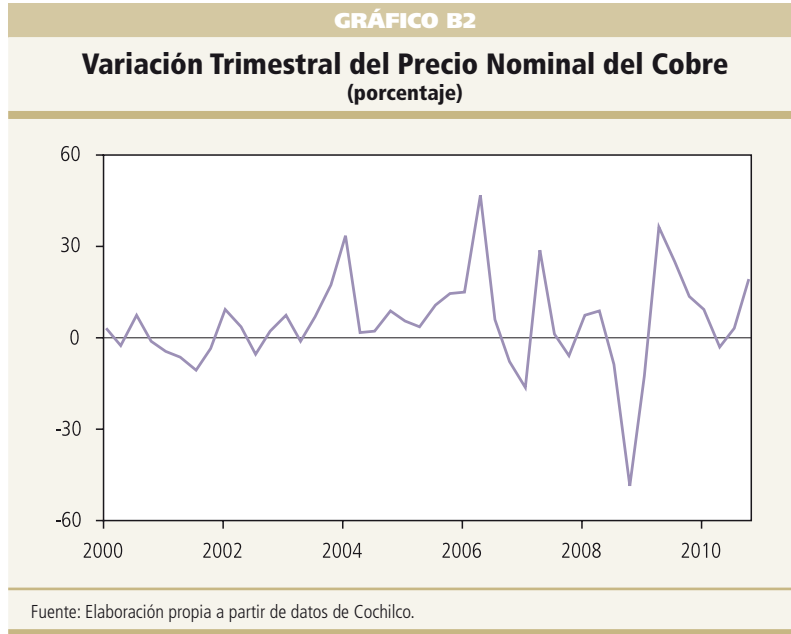
Bajo la función de pérdida consistente en la media de los errores cuadráticos, las proyecciones óptimas y el error de proyección asociado satisfacen un set de condiciones estándares. (ver Diebold y López, 1996; Patton y Timmermann, 2007). Una de ellas corresponde a que la varianza incondicional del error de proyección es una función no decreciente del horizonte de proyección. Esto también implica que la media de los errores cuadráticos debe ser función no decreciente del horizonte de proyección (Patton y Timmermann, 2007, 2011; Diebold, 2007).

En nuestro ejercicio no se cumple dicha condición para los modelos LR, DGJ y el método de futuros en el ejercicio sin incertidumbre; en tanto, para el caso con incertidumbre en los regresores, tenemos que en el modelo DGJ dicha condición no se cumple.

Este hecho obedece a dos motivos: primero, al error en la estimación paramétrica que puede ser importante en muestras finitas, provocando que la media de los errores de proyección no sea función monótonica del horizonte de proyección (Patton y Timmermann, 2011; Schmidt, 1974; Clements y Hendry, 1998), ya que para la evaluación usamos una ventana de proyección de solo 18 datos.

El segundo motivo se refiere a la ventana específica de proyección, la que presenta una caída atípica (ver gráfico 1 y gráfico 2), la cual ninguno de los modelos fue capaz de predecir y cuya respuesta difiere, siendo en algunos casos mejor en los de horizonte mayor. Otro hecho a favor de este argumento, que permite descartar que sea un problema en los modelos econométricos, corresponde a que los errores mediante el método no econométrico de futuros presentan el mismo comportamiento anormal.





Por último, para corroborar esto y ver si se trata de un dato puntual, eliminamos el error de proyección de mayor tamaño en cada horizonte y recalculamos el RECOMP. El resultado fue un patrón monótonicamente creciente a través de los horizontes.