



**“PREDICCIÓN DE TIPOS DE CAMBIO REALES UTILIZANDO
MODELOS VAR BAYESIANOS”**

**Trabajo de Investigación presentado
para optar al Grado Académico de
Magíster en Economía**

Presentado por

Sr. Kenji Alonso Higa Flores

Asesor: Profesor Diego Martin Winkelried Quesada

2016

Resumen ejecutivo

El presente trabajo busca documentar el potencial de los modelos VAR Bayesianos (BVAR) para la predicción de índices de tipos de cambio reales efectivos. Para esto, se prueban distintas especificaciones de modelos predictivos utilizando la base angosta de índices de tipos de cambio reales efectivos de BIS que incluye datos para 27 economías. En primera instancia se prueban modelos univariados simples para realizar las predicciones y tener un punto de referencia para las estimaciones BVAR.

El análisis de los resultados de las predicciones de los modelos BVAR tradicionales muestran que estos por sí solos no tienen un mejor desempeño que los modelos univariados. Estos resultados son robustos a la ventana de estimación, y a la especificación de los *priors* del BVAR.

Índice de contenidos

Índice de gráficos	iv
Índice de anexos	v
Capítulo I. Introducción	1
Capítulo II. Datos	4
Capítulo III. Modelos simples de referencia.....	5
1. Paseo aleatorio y modelos calibrados	5
2. Un modelo univariado estimado	9
Capítulo IV. Modelos VAR bayesianos	12
1. Estructura del modelo BVAR	12
2. Modelo BVAR adaptado.....	15
3. Modelo con búsqueda de hiperparámetros.....	17
4. Análisis de sensibilidad y robustez	19
Conclusiones	22
Bibliografía	23
Anexos	26

Índice de gráficos

Gráfico 1.	PCEPR promedio de los modelos de vida media	7
Gráfico 2.	PCEPR mediana de los modelos de vida media	8
Gráfico 3.	PCEPR para los modelos de vida media de 5 años	9
Gráfico 4.	Promedio y mediana de la PCEPR del modelo de vida media de cinco años y del modelo truncado	10
Gráfico 5.	PCEPR del modelo estimado utilizando el <i>prior</i> de Minnesota	15
Gráfico 6.	CPEPR utilizando el <i>prior</i> de Minnesota modificado y el modelo de vida media de 5 años	16
Gráfico 7.	PCEPR promedio del modelo con búsqueda de hiperparámetros	18
Gráfico 8.	PCEPR promedio del modelo con búsqueda de hiperparámetros modificado	19
Gráfico 9.	PCEPR promedio del modelo con distinto número de rezagos	20

Índice de anexos

Anexo 1.	Abreviaturas de las economías en la base de datos del BIS	27
Anexo 2.	Tipos de cambio reales y predicciones a horizontes de 48 meses	28
Anexo 3.	PCEP y PCEPR de los de paseo aleatorio y de vida media calibrada	29
Anexo 4.	PCEPR de los modelos AR(1) estimados por MCO y MCO truncado	30
Anexo 5.	PCEPR de modelo de búsqueda comparado con el paseo aleatorio	31
Anexo 6.	PCEPR de modelo de búsqueda comparado con el modelo calibrado	32
Anexo 7.	PCEPR de modelo de búsqueda modificado comparado con el modelo calibrado ..	33
Anexo 8.	PCEPR de modelo de búsqueda modificado comparado con el modelo calibrado ..	34
Anexo 9.	PCEPR del modelo calibrado para distintos tamaños de ventana	35
Anexo 10.	PCEPR del modelo de búsqueda modificado para distintos tamaños de ventana ...	36

Capítulo I. Introducción

La literatura económica que intenta realizar proyecciones de tipos de cambio nominales es muy rica y variada, especialmente si se la compara con la literatura que intenta predecir los tipos de cambio reales (TCR). Esto se debe, en parte, a que existe un consenso al que se ha llegado sobre qué constituye una predicción exitosa del tipo de cambio nominal. Desde el trabajo seminal de Meese y Rogoff (1983), tanto los investigadores académicos como los hacedores de política han aceptado que un paseo aleatorio es una forma aceptable de predecir el tipo de cambio y que, por tanto, cualquier método predictivo que sea una mejora sobre el paseo aleatorio es digno de atención. Cuando se revisa la literatura sobre predicción de tipos de cambio reales, no existe un punto de referencia tan claro como lo es el paseo aleatorio para los tipos de cambio nominales.

Meese y Rogoff (1988) encontraron resultados para la predicción de tipos de cambio reales similares a los que habían encontrado previamente para los tipos de cambio nominales. Esta evidencia contradecía a la hipótesis de Paridad de Poder de Compra (PPC), la principal explicación teórica sobre los movimientos de los TCR. La PPC asume que el dinero nominal debe poder comprar los mismos bienes en todas las economías; de lo contrario, existe una oportunidad de arbitraje. Si bien esto puede no cumplirse en el corto plazo, en el largo plazo se espera que este arbitraje genere movimientos del TCR alrededor de niveles de equilibrio determinados por las productividades relativas de bienes no transables. Estudios más recientes han tratado de refutar los resultados de Meese y Rogoff utilizando bases de datos más ricas, ya sea utilizan periodos muestrales más largos (Lothian y Taylor 1996) o empleando un enfoque multivariado (Jorion y Sweeney 1996 y Murray y Pappel 2004). Taylor *et al.* (2001) destacan la importancia de las no linealidades en el arbitraje de tipos de cambio real para explicar la dinámica de estos y el cumplimiento de la PPC. En líneas generales, la literatura actual sostiene la validez de la PPC¹ y la utiliza como base para la predicción de tipos de cambio reales. Aun así, no existe un consenso sobre las implicancias de este supuesto para la predicción de tipos de cambio reales en distintos horizontes.

Mejorar las predicciones de TCR es sumamente importante tanto desde un punto de vista teórico como práctico. Una metodología clara que permita probar y comparar las predicciones basadas en la PPC sería útil para comparar hipótesis que expliquen los desvíos de esta hipótesis. Desde un punto de vista empírico, contar con predicciones acertadas de TCR es fundamental

¹ Para una discusión más detallada de la verificación empírica de la PPC, ver Sarno y Taylor 2002.

para predecir variables relacionadas a transacciones internacionales como lo son los flujos comerciales o las cuentas corrientes.

Este documento busca contribuir a la literatura de predicción de tipos de cambio real en dos formas distintas. Primero, se hace un intento por establecer un método sencillo de predicción de TCR como punto de referencia que pueda ser usado para evaluar y comparar las contribuciones de modelos predictivos más complejos. Segundo, se documenta el poder predictivo de los modelos de vectores autoregresivos bayesianos (BVAR) comunes y se compara con el de métodos de predicción más sencillos.

Se utilizarán modelos BVAR, puesto que son un conjunto de modelos sumamente flexibles que permiten probar conjuntamente distintas hipótesis complementarias sobre la forma que debe tener el modelo. El uso de estos modelos para la predicción se origina con los trabajos de Doan *et al.* (1984) y Litterman (1986). En estos artículos se mostró que el acercar los coeficientes de un modelo de vectores autoregresivos (VAR) reduce los problemas de dimensionalidad de estos y, por ende, permite tener predicciones más acertadas. De Mol *et al.* (2008) propusieron formalmente un nivel de los hiperparámetros que permitía hacer que estos modelos tuvieran un desempeño predictivo aceptable.

Banbura *et al.* (2010) se basaron en estos trabajos previos y aplicaron la metodología de BVAR para hacer predicciones de variables macroeconómicas. Sus resultados no solo mostraron que los modelos BVAR generan predicciones tan buenas o mejores que otras metodologías de predicción de variables macroeconómicas, sino que, además, mostraron que estos mejores resultados se pueden obtener incluso para modelos con una gran cantidad de variables. Esto es particularmente importante, pues los modelos VAR tradicionales son susceptibles a problemas de sobreparametrización, problemas que se acentúan en modelos con muchas variables. Carriero *et al.* (2009), en una aplicación similar a la utilizada en este trabajo, utilizaron una metodología BVAR muy similar a la de Banbura *et al.* para predecir tipos de cambio nominales, y reportan una mejora frente a los modelos de paseo aleatorio. Además, presentan una metodología de optimización de hiperparámetros similar a la que se utilizará en este trabajo y distinta a la utilizada por Banbura *et al.*, que eligen sus hiperparámetros para alcanzar un nivel de ajuste determinado en la muestra, para evitar un sobreajuste del modelo. Carriero *et al.* utilizan errores de predicción pasados para elegir sus hiperparámetros².

² Una alternativa diferente de ambas es utilizar una premuestra para determinar los hiperparámetros con mejor desempeño predictivo. Un ejemplo de esta metodología se encuentra en Carrera y Ledesma (2015).

Además de la literatura de BVAR, existen otros modelos que se han utilizado para mejorar la predicción de tipos de cambio nominales y reales. Una revisión reciente de la literatura de predicción de tipos de cambio nominales se puede encontrar en Rossi (2013). Es particularmente relevante la metodología de Canova (1993), pues es fácilmente implementable en el entorno BVAR. Él utiliza un modelo bayesiano con coeficientes que varían en el tiempo para mejorar las predicciones de tipos de cambio nominales para algunas monedas, añadiendo información de tasas de interés para la predicción. Dado que los modelos BVAR estimados en este trabajo son modelos de variables para economías individuales, este es en efecto un modelo panel VAR sencillo³.

El resto del documento está estructurado de la siguiente forma. En el capítulo II, se describe y discute la información utilizada para realizar y evaluar las predicciones. En el capítulo III, se presentan los modelos sencillos de predicción de tipos de cambio, así como los resultados de estas predicciones. En el capítulo IV, se comparan las predicciones hechas utilizando modelos BVAR tanto con *priors* tradicionales y ajustados específicamente para mejorar la predicción de tipos de cambio reales. Finalmente, se presentan las conclusiones.

³ Una revisión detallada de la metodología panel VAR puede hallarse en Canova y Ciccarelli (2013).

Capítulo II. Datos

La principal fuente de información para la estimación y la predicción de TCR en este trabajo es la base angosta de índices de tipos de cambio reales efectivos del *Bank for International Settlements* (BIS). Esta base contiene los promedios mensuales de los tipos de cambio reales efectivos de 27 economías desarrolladas, incluyendo un tipo de cambio real separado para la Zona Euro⁴. Se utiliza la muestra completa disponible desde enero de 1964 hasta septiembre de 2015, lo que implica una muestra de 621 meses para un total de 16.767 observaciones.⁵

Existen dos razones principales por las que se eligió trabajar con índices de tipos de cambio efectivos en lugar de utilizar tipos de cambio reales bilaterales. En primer lugar, los índices de tipo de cambio efectivo permiten resumir si una moneda está sobre o subvaluada. Esta es la razón por la que los hacedores de política tienden a seguir de cerca el tipo de cambio efectivo o multilateral en lugar de varios tipos de cambio bilaterales. En segundo lugar, utilizar tipos de cambio efectivos permite asociar los movimientos de los tipos de cambio a economías específicas y así probar el cumplimiento de la hipótesis de PPC para economías individuales en lugar de entre pares de economías. Cuando se analizan las desviaciones de la PPC en términos bilaterales es difícil identificar si para una economía en particular se cumple o no la PPC o si el cumplimiento es solo en relación con el país con el que se compara.

El BIS cuenta con una base de datos de tipos de cambio reales más amplia que incluye 61 economías. La metodología que se utiliza para generar esta base de datos es más refinada, pero la disponibilidad de datos solo permite una base de datos más corta. Los datos disponibles de esta base comienzan en 1994. Si bien utilizar esta base de datos como fuente principal podría generar resultados más robustos y generalizables, la poca cantidad de información es una restricción demasiado limitante. Los procesos que se estudian en este trabajo se caracterizan por la alta persistencia de las distorsiones, por lo que la longitud de las series es fundamental para tener estimaciones robustas. En algunas aplicaciones específicas se mencionarán los resultados de utilizar la base de datos ancha.

⁴ Para una discusión detallada de la base de datos del BIS, revisar Turner y Van't dack (1993).

⁵ El Anexo 2 muestra una selección de las series de tipos de cambio real.

Capítulo III. Modelos simples de referencia

En este capítulo se presentan distintos modelos sencillos que buscan servir como punto de referencia para los métodos predictivos más complejos del siguiente capítulo. Para cumplir este papel, los modelos de esta sección deben ser relativamente sencillos de implementar. Por este motivo, se ha elegido atenerse a modelos autoregresivos de orden uno, los llamados modelos AR(1). La subsección 1 muestra los resultados de utilizar los modelos de paseo aleatorio y modelos calibrados de vida media, ambos casos específicos de modelos AR(1). La subsección 2 presenta un modelo bayesiano simple para la predicción de TCR que estima la velocidad de convergencia a la PPC en lugar de calibrarla. La subsección 3 analiza en más detalle los errores de predicción de estos modelos.

1. Paseo aleatorio y modelos calibrados

Los modelos calibrados de vida media realizan predicciones asumiendo que los TCR siguen un proceso AR(1) de la forma:

$$(y_t - \mu) = \rho(y_{t-1} - \mu) + e_t$$

Donde μ representa el nivel de tipo de cambio multilateral, que es consistente con la PPC y que es constante en el tiempo. Este parámetro se estima utilizando la media de los datos. El parámetro ρ representa la velocidad con la que se disipan los choques al tipo de cambio multilateral. Este parámetro puede ser estimado o puede ser calibrado de acuerdo a la siguiente expresión:

$$\rho = e^{\log(0,5)/vm}$$

En esta ecuación, vm representa la vida media de las desviaciones de la PPC medida en meses. Dada esta expresión, es posible notar que el paseo aleatorio es un caso especial de los modelos de vida media calibrada donde la vida media tiende al infinito y, por tanto, $\rho = 1$.

Los pronósticos que se presentan en esta sección se realizan utilizando un método de predicción iterativa, por lo que los pronósticos tienen la forma:

$$y_{t+h|t} = \hat{\mu} + \rho^h(y_t - \mu)$$

Los resultados en esta subsección son muy similares a los presentados por Ca'Zorzi *et al.* (2015), quienes trabajaron con la misma base de datos. Sus resultados mostraron que los modelos calibrados de vida media pueden superar a los modelos que asumen un comportamiento tipo paseo aleatorio. También mostraron que los modelos calibrados dominan a los modelos univariados estimados ya sea a través de métodos frecuentistas o bayesianos. Ellos reportaron que el modelo calibrado para una vida media de cinco años generaba mejores predicciones, en términos del error cuadrático medio de predicción, que el modelo de paseo aleatorio. Ca'Zorzi *et al.* analizan en mayor detalle los resultados para 9 de las economías de la muestra (Australia, Canadá, la Zona Euro, Japón, México, Nueva Zelanda, Suiza, Reino Unido y Estados Unidos), pero en términos de la muestra completa encuentra que para 21 de las 27 economías en el horizonte de un año y para 16 de 21 economías para un horizonte de cinco años, las predicciones con el modelo calibrado superan a las realizadas con un paseo aleatorio. De estas, en seis economías se superó el test de Diebold y Mariano (1995) al 10% en el horizonte de un año, y para diez economías se superó el test de DM al 5% en el horizonte de 5 años.

Para realizar sus predicciones principales, Ca'Zorzi *et al.* (2015) utilizaron ventanas de 180 meses para estimar los tipos de cambio reales de largo plazo para cada economía recursivamente. Las predicciones se realizaron para horizontes de hasta 60 meses. Además de estas estimaciones, los autores también presentaron análisis de sensibilidad utilizando ventanas de datos distintas (120 y 240 meses) y calibraciones distintas de la vida media (1, 3 y 10 años). Los resultados parecen indicar que una ventana más larga de datos genera mejores predicciones y que la calibración de la vida media impacta en las predicciones de forma distinta, dependiendo del horizonte de predicción.


Para los resultados que se presentan en esta subsección se utilizan calibraciones de entre 3 a 5 años de vida media. El consenso sobre una vida media de las desviaciones de la PPC de entre 3 y 5 años fue reportado por primera vez en Rogoff (1996). A partir de esta publicación, otros autores han seguido debatiendo estas estimaciones utilizando diferentes metodologías y fuentes de información (ver Khillian y Zha 2002 y Murray y Pappel 2004), sin embargo, el consenso aún se mantiene. Para hacer más comparables los resultados, los pronósticos se han realizado utilizando la misma ventana móvil de datos de 180 meses como en Ca'Zorzi *et al.* (2015) y el mismo máximo horizonte de predicción de 60 meses. A diferencia de Ca'Zorzi *et al.*, en este trabajo se presentan los resultados de la predicciones para los mismos periodos sin importar el

horizonte de predicción. Esto significa que se está evaluando la misma cantidad de periodos (382 meses) para cada horizonte.

Los resultados de estas predicciones para horizontes seleccionados se presentan en el anexo 3.

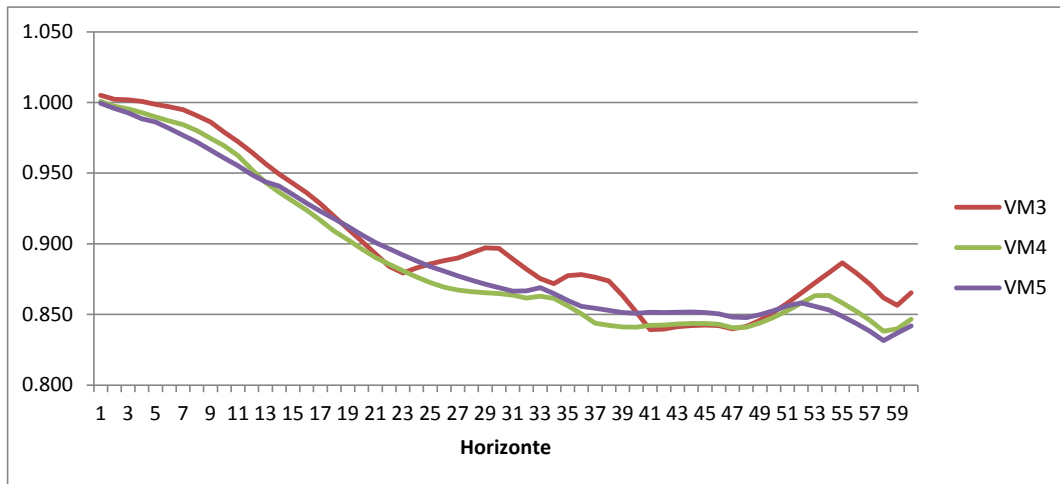
Como es usual, en la literatura se reporta el promedio cuadrático del error de predicción (PCEP) para el paseo aleatorio y el promedio cuadrático del error de predicción relativo (PCEPR) para las estimaciones de vida media calibrada. En el caso del PCEPR, este muestra que la predicción es mejor que la predicción base, generalmente el paseo aleatorio, cuando el valor es menor que uno. Los resultados muestran que los modelos de vida media calibrada pueden, en promedio, generar mejores predicciones que el paseo aleatorio en horizontes tan cortos como seis meses. Esto se muestra en los gráficos 1 y 2, que presentan el promedio del PCEPR por economías y la mediana del PCEPR por economías para los tres modelos calibrado. En general, estos modelos tienen un mejor desempeño relativo en horizontes más largos. Incluso, cuando se limita el análisis a las 9 economías analizadas por Ca'Zorzi *et al.* (2015), se observa que los modelos de vida media calibrada tienen un desempeño aun mejor.

Gráfico 1. PCEPR promedio de los modelos de vida media



Fuente: Elaboración propia 2016.

Gráfico 2. PCEPR mediana de los modelos de vida media




Fuente: Elaboración propia 2016.

Si bien los resultados promedio son alentadores, al analizar el desempeño individual de las estimaciones el panorama es menos claro. De forma similar a los resultados hallados por Ca'Zorzi *et al.* (2015), muchas de las predicciones de los modelos de vida media no son estadísticamente superiores a las predicciones del modelo de paseo aleatorio. Tomando la calibración de 5 años y el horizonte de proyección de un año, solo 3 economías (Euro Zona, Noruega y Gran Bretaña) tienen mejores resultados que el paseo aleatorio al 5% de significancia. Este número sube a 12 economías (Bélgica, Euro Zona, Francia, Alemania, Italia, Países Bajos, Nueva Zelanda, Singapur, España, Suiza, Reino Unido y Estados Unidos) cuando el horizonte pasa a ser de cinco años. Incluso, al horizonte de 5 años, 2 economías tienen predicciones significativamente mejores en el modelo de paseo aleatorio que en el modelo de vida media de 5 años (Australia y Suecia).

Las ganancias de los modelos calibrados de vida media sobre el paseo aleatorio parecen ser muy diferentes entre las distintas economías. Incluso para horizontes de predicción de cinco años, nueve economías tienen mejores predicciones utilizando un paseo aleatorio que un modelo calibrado de vida media de tres años. Este número se reduce a ocho y siete años cuando se compara con calibraciones de cuatro y cinco años, respectivamente. El gráfico 3 muestra los PCEPR para las distintas economías en el modelo de vida media de cinco años. Estos resultados muestran que el desempeño de los modelos calibrados no es el resultado de una mejora en la predicción de todas las economías de la muestra. Es más, para algunas economías, al parecer, el paseo aleatorio tiene un desempeño relativamente mejor en horizontes más largos. Esto implica

que puede existir cierto espacio para estimar distintas tasas de convergencia para las distintas economías.

Gráfico 3. PCEPR para los modelos de vida media de 5 años



Fuente: Elaboración propia 2016.

En la misma línea, los resultados promedio de los modelos calibrados no muestran las diferencias en los desempeños de los modelos calibrados por economía. Aun cuando los modelos calibrados a 5 años tienen en promedio mejores resultados que los de tres años, entre 8 y 12 economías tienen predicciones más acertadas con los segundos modelos, dependiendo del horizonte de predicción que se analice. Si este mejor desempeño está, de alguna manera, correlacionado con el mejor ajuste del modelo en la muestra, entonces las predicciones pueden mejorarse si se estima la vida media en lugar de calibrarse. La siguiente subsección intenta hacer justamente eso al estimar la vida media.

2. Un modelo univariado estimado

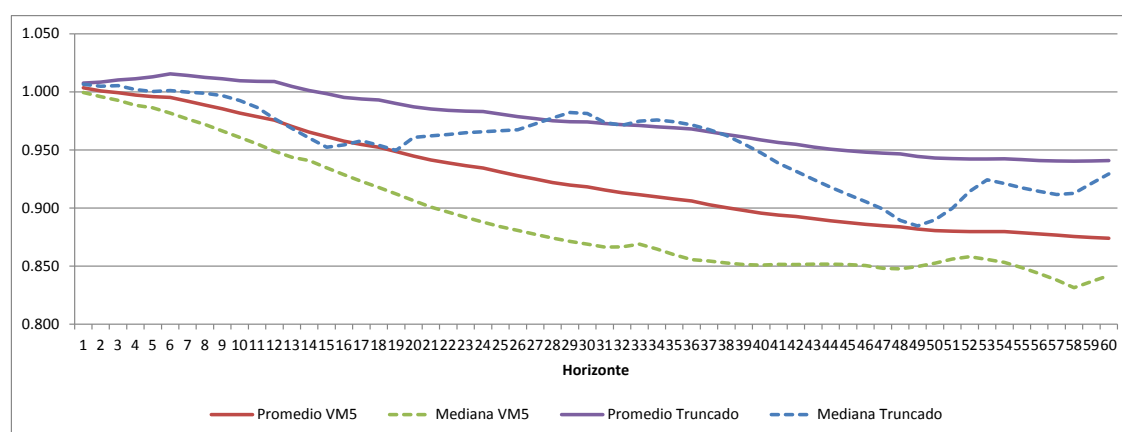
En esta subsección se busca mejorar el desempeño alcanzado por los modelos calibrados presentados previamente. Al introducir una calibración en la sección anterior lo que se hace es introducir en la muestra información previa sobre una creencia acerca del comportamiento de los tipos de cambio. Si bien esto resulta relativamente efectivo, los modelos calibrados carecen de la flexibilidad necesaria para acomodar las diferencias que se observan entre economías.

Por otro lado, los modelos estimados bajo un enfoque frecuentista o bayesiano pueden resultar demasiado flexibles. Ca'Zorzi *et al.* (2015) mostraron claramente que modelos univariados

estimados por MCO o por métodos bayesianos no generan predicciones mejores a los modelos calibrados o al paseo aleatorio. En esta sección se presentan los resultados de un modelo estimado con una especificación diferente de la de Ca'Zorzi *et al.*

Se propone un modelo univariado estimado por MCO truncado. Este modelo puede interpretarse como un modelo bayesiano donde la distribución *prior* que se propone es uniforme entre los valores de truncamiento. Este *prior* busca capturar dos creencias que provienen de la literatura sobre tipos de cambio reales. Primero, que existe un consenso de que la vida media de las desviaciones de la PPC se encuentra entre 3 y 5 años; por lo tanto, la reversión a la PPC no debería ocurrir más rápido que con una vida media de 3 años. Segundo, que un paseo aleatorio puede vencer a los modelos de vida media de forma consistente para algunos horizontes y para algunas economías; por lo tanto, puede mejorar las predicciones en algunos contextos. El *prior* que se propone combina estas creencias de una manera sencilla.

Gráfico 4. Promedio y mediana de la PCEPR del modelo de vida media de cinco años y del modelo truncado



Fuente: Elaboración propia 2016.

Los resultados de las predicciones basadas en estas estimaciones por economías se presentan en la anexo 4, junto con los resultados de una predicción estimando con un modelo MCO el parámetro autoregresivo.

El gráfico 4 muestra la mediana y el promedio del PCEPR del modelo bayesiano simple y el modelo calibrado a 5 años.

Mientras que la estimación bayesiana presenta resultados que dominan a la estimación por MCO y es una mejora sobre los modelos de paseo aleatorio para horizontes mayores a 1 año, este no logra un mejor desempeño que los modelos calibrados en promedio o en mediana. Las estimaciones por país muestran que este modelo tampoco genera mejores predicciones en términos de significancia estadística con respecto al paseo aleatorio. Por este motivo, se reafirma que el modelo calibrado es el mejor punto de comparación univariado para evaluar modelos más complejos.

Capítulo IV. Modelos VAR bayesianos

El entorno VAR es, de alguna forma, un enfoque opuesto a los modelos univariados analizados en la sección anterior. Los modelos univariados son simples de estimar, pero no toman en cuenta la información que pueda estar presente en los comovimientos de los distintos tipos de cambio y sus rezagos. Los modelos VAR, por su parte, incluyen en la estimación todas las correlaciones presentes en la data; por lo tanto, tienen la ventaja de incluir estos datos en la predicción. Esto, a su vez, genera un problema de sobreparametrización que debe ser superado para tener un modelo que produzca predicciones aceptables. Cuando la base de datos incluye un número grande de variables y rezagos relevantes, la cantidad de parámetros puede hacer que el modelo sea imposible de estimar usando técnicas tradicionales. Incluso cuando la cantidad de observaciones es suficiente para estimar el modelo, tener que estimar muchos parámetros conlleva un desempeño pobre en términos de predicción.

Una forma de evitar el problema de la sobreparametrización es estimar el modelo VAR utilizando técnicas bayesianas. Al incluir información previa en la forma de un *prior* bayesiano, la cantidad de incertidumbre sobre los parámetros a estimar se reduce y el resultado es un modelo VAR que puede estimarse con menos información y que produce mejores predicciones.

En la siguiente subsección presentará la estructura básica del modelo BVAR. En el resto de la sección, se discutirán los resultados de las predicciones hechas con distintas variantes del modelo BVAR.

1. Estructura del modelo BVAR

Los modelos BVAR buscan incluir en la estimación de un VAR información que está fuera de la muestra. La estructura del modelo VAR que se busca estimar será:

$$Y_t = c + A_1 Y_{t-1} + \dots + A_p Y_{t-p} + u_t$$

Donde $Y_t = (y_{1,t} \ y_{2,t} \ \dots \ y_{n,t})'$ es el vector de variables dependientes, c es un vector de constantes, A_i son matrices de coeficientes de dimensión $N \times N$ y u_t es un vector de ruidos blancos con matriz de covarianzas Ψ .

Los T sistemas de ecuaciones que componen todas las observaciones de este modelo pueden reordenarse en un sistema de regresiones como en Kadiyala y Karlsson (1997):

$$Y = X B + U$$

Donde $Y = (Y_1, Y_2, \dots, Y_T)'$ de dimensiones TxN, $X = (X_1, X_2, \dots, X_T)'$ es una matriz de Txk donde $X_t = (Y_{t-1}', Y_{t-2}', \dots, Y_{t-p}', 1)'$, $U = (u_1, u_2, \dots, u_T)'$ es una matriz de dimensión TxN y $B = (A_1, A_2, \dots, A_p, c)'$ es una matriz kxN y donde $k = np + 1$.

Para realizar la primera estimación bayesiana de este modelo, se utilizará el *prior* de Minnesota, propuesto para aplicaciones VAR por Litterman (1986) pero utilizando una modificación propuesta por Kadiyala y Karlsson (1997). Este *prior* tiene la característica de estar centrado alrededor de un paseo aleatorio con tendencia. Por tanto, la aplicación de este *prior* hará que el modelo estimado tienda a:

$$Y_t = c + Y_{t-1} + u_t$$

Este *prior* también incorpora la creencia de que los rezagos más lejanos tienen información menos valiosa para el valor presente de la variable y que una variable debe estar explicada más por sus propios rezagos que por los de las demás variables del VAR. La distribución *prior* que cumple estas características será:

$$\mathbb{E}[(A_k)_{ij}] \begin{cases} 1 & \text{si } i = j, k = 1 \\ 0 & \text{de otra forma} \end{cases}$$

$$\mathbb{V}[(A_k)_{ij}] \begin{cases} \frac{\lambda^2}{k^2} & \text{si } i = j \\ \vartheta \frac{\lambda^2 \sigma_i^2}{k^2 \sigma_j^2} & \text{de otra forma} \end{cases}$$

Se asume que las matrices A_i son independientes entre sí y se distribuyen normalmente. También se asume que la distribución del intercepto es difusa. Sobre los residuos, se asume que su matriz de covarianza es diagonal, fija y conocida. Tendrá la forma:

$$\Psi = \Sigma = \text{diag}(\sigma_1^2, \dots, \sigma_n^2)$$

Este supuesto de residuos no correlacionados es problemático, puesto que en el caso de los índices de tipo de cambio no se espera que los residuos no tengan relación. Para solucionar este problema, se aplica la modificación propuesta en Kadiyala y Karlsson (1997) y Robertson y Tallman (1999). Esta modificación establece que la varianza de los coeficientes proviene de una distribución Wishart Invertida. El *prior* con este supuesto será:

$$\begin{aligned} \text{vec}(B)|\Psi &\sim N(\text{vec}(B_0), \Psi \otimes \Omega_0) \\ \Psi &\sim iW(S_0, \alpha_0) \end{aligned}$$


Donde los parámetros B_0 , Ω_0 , S_0 y α_0 son escogidos para que la distribución de B coincida con la del *prior* de Minnesota, mientras que la esperanza de Ψ sea igual a la matriz Σ del *prior* original (ver Kadiyala y Karlsson 1997 para más detalles). Dado que este es un *prior* conjugado, la distribución posterior tiene una forma cerrada, por lo que es posible estimar su valor esperado de forma analítica. Sin embargo, si se desea establecer un grupo de *priors* en lugar de solo el *prior* de Minnesota, entonces la implementación través de observaciones adicionales se vuelve una mejor alternativa. En el caso del Minnesota *prior*, se sabe que el valor esperado de la distribución posterior será igual a la estimación por MCO del VAR si se le agregan las siguientes T_d observaciones adicionales:

$$Y_d = \begin{pmatrix} \text{diag}(\sigma_1, \dots, \sigma_n)/\lambda \\ 0_{n(p-1) \times n} \\ \dots \\ \text{diag}(\sigma_1, \dots, \sigma_n) \\ \dots \\ 0_{1 \times n} \end{pmatrix} \quad X_d = \begin{pmatrix} J_p \otimes \text{diag}(\sigma_1, \dots, \sigma_n)/\lambda & 0_{np \times 1} \\ \dots & \dots \\ 0_{n \times np} & 0_{n \times 1} \\ \dots & \dots \\ 0_{1 \times np} & \varepsilon \end{pmatrix}$$

Donde $J_p = \text{diag}(1, 2, \dots, p)$. El primer bloque de np observaciones impone el *prior* para los coeficientes del VAR. El segundo bloque de n observaciones impone el *prior* sobre la matriz de covarianzas. La última observación impone el *prior* no informativo para la tendencia. Los parámetros σ_i representan la dispersión esperada en los residuos de las variables. En esta estimación, se utiliza como *priors* la varianza de los residuos de regresiones univariadas de orden p, como es usual en la literatura. El hiperparámetro λ define cuan estricto es el *prior*. Cuando este tiende a infinito, el *prior* se vuelve no informativo sobre el valor de los coeficientes. Cuando el parámetro tiende a cero, entonces se vuelve un *prior* estricto, es decir, la distribución posterior de los coeficientes coincidirá con la distribución *prior*.

El gráfico 5 muestra el resultado de aplicar este *prior* con un valor de $\lambda = 10^{-5}$, con una ventana de 180 meses y un horizonte de predicción de 60 meses.

Gráfico 5. PCEPR del modelo estimado utilizando el *prior* de Minnesota



Fuente: Elaboración propia 2016.

Claramente, esta estimación genera predicciones bastante peores que el paseo aleatorio y que los modelos calibrados. Ahora bien, la aplicación directa del *prior* de Minnesota genera estas predicciones por dos motivos. Primero, debido a que el *prior* difuso sobre el coeficiente de tendencia genera estimaciones que identifican tendencias espurias, cuyo efecto se hace más notorio en horizontes largos. Segundo, porque el *prior* de Minnesota centra la distribución de los coeficientes alrededor del paseo aleatoria, cuando se ha identificado que este no es el mejor modelo univariado.

En la siguiente subsección, se realizará una estimación utilizando un *prior* similar al de Minnesota pero adaptado para corregir estas características.

2. Modelo BVAR adaptado

Para estimar un modelo BVAR que concuerde con la información previa sobre el comportamiento del tipo de cambio real, es necesario hacer dos modificaciones al *prior* de Minnesota. En primer lugar, es necesario establecer que se necesita un *prior* más estricto y centrado en cero sobre el coeficiente de la tendencia, debido a que no se espera que el tipo de


cambio real de un país se expanda o se contraiga de forma permanente. Esto implicaría que la competitividad de una economía se expande o se contrae de forma explosiva. Ello puede suceder durante un cierto periodo, no es posible que este proceso se dé de manera indeterminada.

Además de introducir un *prior* más estricto para el coeficiente de tendencia, es necesario evaluar si centrar el *prior* alrededor del paseo aleatorio es mejor que centrarlo en otro modelo. Con la siguiente configuración, es posible centrar la distribución *prior* en otro modelo AR(1). Para esto, las observaciones adicionales que se deben agregar son:

$$Y_d = \begin{pmatrix} \text{diag}(\sigma_1, \dots, \sigma_n) \delta / \lambda \\ 0_{n(p-1) \times n} \\ \dots \\ \text{diag}(\sigma_1, \dots, \sigma_n) \\ \dots \\ \mu(1 - \delta) / \lambda \end{pmatrix} \quad X_d = \begin{pmatrix} J_p \otimes \text{diag}(\sigma_1, \dots, \sigma_n) / \lambda & 0_{npx1} \\ \dots & \dots \\ 0_{n \times np} & 0_{nx1} \\ \dots & \dots \\ 0_{1 \times np} & 1 / \lambda \end{pmatrix}$$

Donde μ es un vector que contiene los *priors* de las medias de largo plazo de los tipos de cambio real y δ es el *prior* del coeficiente de autocorrelación. Cuando $\delta = 1$ se tiene que este *prior* es igual al *prior* de Minnesota visto anteriormente. El vector μ se estima en lugar de imponerse un *prior*, se le da el valor de la media muestral del índice del tipo de cambio en la ventana de estimación. Utilizando el δ consistente con una vida media de 5 años, es posible generar una nueva predicción.

Gráfico 6. CPEPR utilizando el *prior* de Minnesota modificado y el modelo de vida media de 5 años



Fuente: Elaboración propia 2016.

Como se observa en el gráfico, a partir de un $\lambda = 10^{-5}$ se tienen predicciones muy similares a la de los modelos calibrados. Esta estimación, sin embargo, no parece tener, por ahora, ninguna ventaja sobre los modelos calibrados, pues los comovimientos no parecen aportar lo suficiente con un *prior* tan estricto como para mejorar las predicciones. Tampoco se están aprovechando dos hechos importantes que pueden mejorar la predicción: que el ritmo de convergencia de las distintas economías no necesariamente es el mismo y que se espera una mejor predicción para algunos horizontes del modelo de paseo aleatorio que del modelo de vida media. Ambos conceptos se pueden aprovechar con un proceso de búsqueda de hiperparámetros, el cual se presenta en la siguiente sección.

3. Modelo con búsqueda de hiperparámetros

La búsqueda de hiperparámetros permite aprovechar la relación entre los errores de predicción para tener pronósticos más acertados. La forma más directa de realizar esta búsqueda es utilizar una rejilla de valores posibles de los hiperparámetros y utilizar los errores de predicción pasados para elegir cuál es el hiperparámetro más adecuado. Este enfoque es el que utilizan Carriero *et al.* (2009) para elegir el ajuste de su *prior*⁶. A diferencia de Carriero *et al.*, al utilizar una modificación del *prior* de Minnesota se tienen en realidad 2 hiperparámetros en el modelo, λ y δ . La segunda diferencia será en el método de búsqueda, en este caso se va a utilizar una búsqueda de parámetros por economía, por horizonte y por periodo, a diferencia de Carriero *et al.*, donde se hace una búsqueda del parámetro que en promedio predice mejor a todos los tipos de cambio. La búsqueda se hace de forma recursiva en cada periodo y se utiliza el último error de predicción disponible para cada horizonte de proyección. Este proceso genera que las predicciones de horizontes largos se retrasen, pues es necesario evaluar estas predicciones antes de elegir el hiperparámetro para la siguiente predicción. Es por esto que, en este caso, se evalúan predicciones de solo 322 meses. La matriz donde se busca los parámetros será:

$$\delta \in \{e^{\log(0,5)/60}, 1\}$$

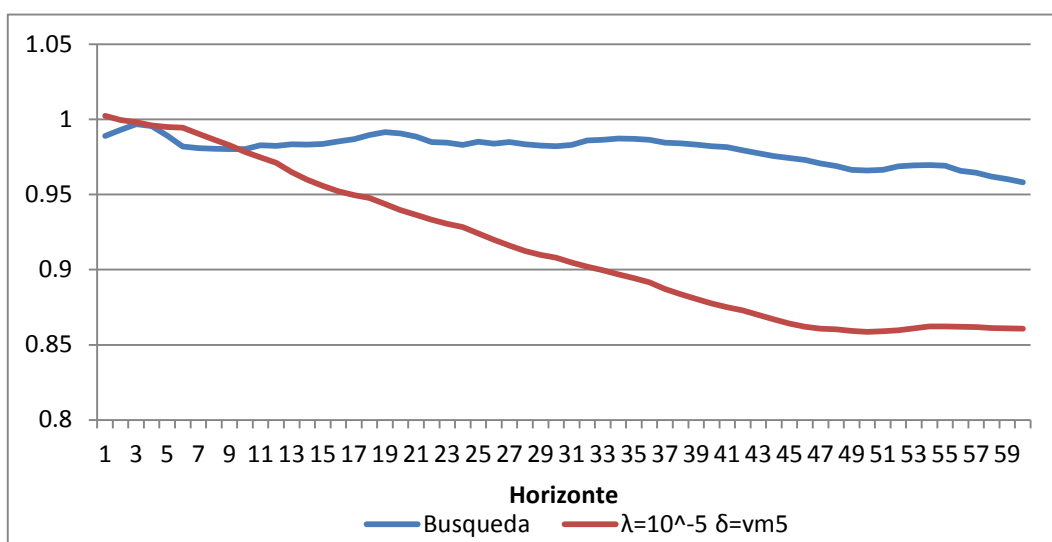
$$\lambda \in \{10^{-5}, 10^{-6}\}$$

El gráfico 7 expone los resultados de este modelo comparado con un modelo estimado utilizando el *prior* de Minnesota con parámetros fijos. Los resultados muestran que el

⁶ Una discusión más extensa de la búsqueda de hiperparámetros para modelos BVAR puede encontrarse en Giannone *et al.* (2015).

desempeño predictivo es mejor para el modelo con búsqueda de hiperparámetros para horizontes de predicción de hasta nueve meses. Para horizontes largos, la búsqueda de hiperparámetros genera resultados mejores que el paseo aleatorio pero peores que el modelo calibrado. Esto demuestra que existe un costo alto de utilizar la búsqueda que aparentemente estaría siendo provechoso para horizontes cortos.

Gráfico 7. PCEPR promedio del modelo con búsqueda de hiperparámetros




Fuente: Elaboración propia 2016.

Los anexos 5 y 6 muestran los PCEPR del modelo de búsqueda hiperparámetros, comparado con el modelo de paseo aleatorio y con el modelo calibrado a 5 años, respectivamente. Las mejoras en predicción en el horizonte de un mes son estadísticamente significativas para 15 economías si se compara con el modelo de paseo aleatorio, y para 12 economías si se comparan con el modelo calibrado. Como sugieren los resultados promedio, el modelo calibrado predice mejor en horizontes largos, y esta diferencia es estadísticamente significativa para entre 6 y 10 economías en horizontes mayores a 2 años. Esta diferencia se explica, en parte, por el alto costo de realizar una búsqueda de hiperparámetros utilizando los errores pasados para el mismo horizonte. Esto resulta en predicciones que utilizan información muy antigua para la elección del hiperparámetro óptimo. Una posible forma de reducir este costo es utilizar para todos los horizontes los errores de predicción del horizonte de un periodo que parece tener resultados prometedores, al menos, en horizontes cortos.

El gráfico 8 muestra los resultados promedio utilizando este método de búsqueda con la misma matriz de hiperparámetros. El desempeño promedio de la búsqueda de hiperparámetros es bastante mejor utilizando esta especificación para todos los horizontes. El motivo de esto es que la búsqueda de hiperparámetros está identificando de forma adecuada a las economías cuyos tipos de cambio reales se predicen mejor utilizando la calibración de vida medio o el paseo aleatorio. Esto permite mejorar las predicciones; sin embargo, no permite identificar que las predicciones con vida media calibrada son mejores para horizontes largos. Aun así, la mejora en la predicción para horizontes cortos es bastante significativa y representa un resultado importante.

Los anexos 7 y 8 muestran los resultados en detalle utilizando esta especificación. Con esta especificación, existe un rango de horizontes donde los modelos calibrados son estadísticamente superiores para varias economías de la muestra. Sin embargo, los modelos de búsqueda tienen la ventaja de no ser estadísticamente inferiores al paseo aleatorio para ninguna economía para horizontes mayores a 4 años, algo que no sucede con los modelos calibrados. Es por esto que los resultados de este modelo son también importantes incluso para horizontes largos.

Gráfico 8. PCEPR promedio del modelo con búsqueda de hiperparámetros modificado (I)




Fuente: Elaboración propia 2016.

4. Análisis de sensibilidad y robustez

Una primera variable de interés para el análisis es la posible mejora de las estimaciones con modelos BVAR ante especificaciones que incluyan menos rezagos. Esto, en teoría, permite relajar el hiperparámetro del *prior* y obtener mayor información de los primeros rezagos en la muestra. El gráfico 9 muestra los resultados de reducir el número de rezagos mientras que se relaja el hiperparámetro del *prior* de Minnesota. Si bien reducir el número de rezagos parece mejorar el desempeño predictivo para distintos niveles del hiperparámetro, esta mejora solo es relevante alrededor del parámetro de ajuste óptimo para horizontes cercanos a los 5 años. Incluso en dichos casos las ganancias en términos de predicción son modestas.

Gráfico 9. PCEPR promedio del modelo con distinto número de rezagos



Fuente: Elaboración propia 2016.

Un segundo parámetro al que puede ser sensible el modelo es el tamaño de muestra que se utiliza para estimar el tipo de cambio real al que converge la predicción. Una ventana de datos más larga reduce la incertidumbre en la estimación de los parámetros, pero potencialmente empeora el sesgo si el tipo de cambio real de equilibrio varía en el tiempo. Ca'Zorzi *et al.* (2015) probaron ventanas de datos entre 10 y 20 años y encontraron que las ventanas más largas generan mejores predicciones tanto para los modelos estimados como los calibrados. El anexo 9 muestra los resultados para estas ventanas utilizando el modelo calibrado; y el anexo 10, utilizando el modelo de búsqueda modificado. En ambos casos se utiliza el tamaño de muestra menor (asociado al mayor tamaño de ventana) para que se evalúe la misma cantidad de periodos para cada horizonte y tamaño de ventana.

Los resultados muestran que en la nueva muestra, diez años más corta, los modelos calibrados y de búsqueda parecen tener mejor desempeño con una ventana de 20 años que una de 15 años y peor desempeño con otros tamaños de ventana. Además, en esta ventana de datos más corta

ninguno de los dos tipos de modelos parece superar en promedio al paseo aleatorio para horizontes largos. Sin embargo, el número de economías para las que se tienen mejores predicciones al paseo aleatorio no cae drásticamente para los distintos horizontes, ni sube el número de economías que se predicen mejor con el paseo aleatorio de forma estadísticamente significativa. A su vez, se mantiene la significancia estadística del mejor desempeño del modelo de búsqueda en horizontes cortos, por lo que se concluye que este es robusto al tamaño de muestra.

Conclusiones

Los resultados en modelos univariados muestran que los modelos calibrados pueden generar mejores predicciones que utilizando un paseo aleatorio. Esto se da con mayor frecuencia para horizontes de predicción mayores a 3 años. Este desempeño predictivo puede mejorarse para horizontes menores a 3 años cuando se utilizan los errores de predicción pasados para la elección de los parámetros de la calibración. Específicamente, cuando se utilizan errores de predicción cortos, se logran mejoras robustas en la capacidad predictiva de los modelos calibrados.

Los resultados de aplicar la metodología BVAR demuestran que estos no extraen suficiente información de los comovimientos de las series de tipo de cambio real como para justificar enfrentarse a un modelo más complejo. En su especificación más sencilla, estos modelos no mejoran las predicciones sobre los modelos calibrados. La agenda pendiente se define, principalmente, por los refinamientos posibles para los modelos BVAR. Las alternativas que se han probado en modelos BVAR comprenden especificaciones que incluyan restricciones como los modelos globales (GVAR) o utilicen modelos VAR con restricciones espaciales. También es posible utilizar información adicional que pueda ser agregada al modelo de forma parsimoniosa en el entorno BVAR.

Bibliografía

- Bañbura, M., Giannone, D. y Reichlin, L. (2010). *Large Bayesian Vector Autoregressions*. Journal of Applied Econometrics, 25, 71-92.
- Ca' Zorzi, M., Muck, J. y Rubaszek, M. (2015). *Real Exchange Rate Forecasting and PPP: This Time the Random Walk Loses*. (229). Federal Reserve Bank of Dallas.
- Canova, F. (1993). *Modelling and forecasting exchange rates with a Bayesian time-varying coefficient model*. Journal of Economic Dynamics and Control, 17, 233-261.
- Canova, F. y Ciccarelli, M. (2013). *Panel Vector Autoregressive Models, a Survey*. Working Paper Series (1507).
- Carrera, C. y Ledesma, A. (2015). *Aggregate Inflation Forecast with Bayesian Vector Autoregressive Models*. Working Paper (50).
- Carriero, A., Kapetanios, G. y Marcellino, M. (2009). *Forecasting Exchange Rates With a Large Bayesian VAR*. International Journal of Forecasting, 25(2), 400-417.
- De Mol, C., Giannone, D. y Reichlin, L. (2008). *Forecasting using a large number of predictors: Is Bayesian shrinkage a valid*. Journal of Econometrics, 142, 318-328.
- Diebold, F. y Mariano, R. (1995). *Comparing Predictive Accuracy*. Journal of Business & Economic Statistics, 13(3), 134-144.
- Doan, T., Litterman, R. y Sims, C. (1984). *Forecasting and conditional projection using realistic prior distributions*. Econometric Review, 3(1), 1-100.
- Giannone, D., Lenza, M. y Primiceri, G. E. (2015). *Prior Selection for Vector Autoregressions*. The Review of Economics and Statistics, 97(2), 436-451.
- Jorion, P. y Sweeney, R. J. (1996). *Mean reversion in real exchange rates: evidence and implications for forecasting*. Journal of International Money and Finance, 15(4), 535-550.

- Kadiyala, K. R. y Karlsson, S. (1997). *Numerical Methods for Estimation and Inference in Bayesian VAR-Models*. Journal of Applied Econometrics, 12(2), 99-132.
- Killian, L. y Zha, T. (2002). *Quantifying the uncertainty about the half-life of deviations from PPP*. Journal of Applied Econometrics, 17, 107-125.
- Litterman, R. (1986). *Forecasting with Bayesian vector autoregressions five years of experience*. Journal of Business & Economic Statistics, 4(1), 25-38.
- Lothian, J. R. y Taylor, M. P. (1996). *Real Exchange Rate Behavior: The Recent Float from the Perspective of the Past Two*. The Journal of Political Economy, 104(3), 488-509.
- Meese, R. A. y Rogoff, K. (1983). *Empirical exchange rate models of the seventies: Do they fit out of sample?* Journal of International Economics, 14(1-2), 3-24.
- Meese, R. A. y Rogoff, K. (1988). *Was It Real? The Exchange Rate-Interest Differential Relation Over The Modern Floating-Rate Period*. Journal of Finance, 43(4), 933-948.
- Murray, C. J. y Pappell, D. H. (2002). *The purchasing power parity persistence paradigm*. Journal of International Economics, 56(1), 1-19.
- Robertson, J. C. y Tallman, E. W. (1999). *Vector autoregressions: forecasting and reality*. Economic Review, 84(1), 4-18.
- Rogoff, K. (1996). *The purchasing power parity puzzle*. Journal of Economic Literature, 34(2), 647-668.
- Rossi, B. (2013). *Exchange Rate Predictability*. Journal of Economic Literature, 51(4), 1063-1119.
- Sarno, L. y Taylor, M. P. (2002). *Purchasing Power Parity and the Real Exchange Rate*. IMF Staff Papers, 49(1), 65-105.

Taylor, M., Peel, D. y Sarno, L. (2001). *Nonlinear Mean-Reversion in Real Exchange Rates: Toward a Solution to the Purchasing Power Parity Puzzles*. *International Economic Review*, 42(4), 1015-1042.


Turner, P. y Van't dack, J. (1993). *Measuring international price and cost competitiveness*. *BIS Economic Papers*(39). BIS.

Anexos

Anexo 1. Abreviaturas de las economías en la base de datos del BIS

Australia	RNAU
Austria	RNAT
Belgica	RNBE
Canadá	RNCA
Taiwan	RNTW
Dinamarca	RNDK
Zona Euro	RNXM
Finlandia	RNFI
Francia	RNFR
Alemania	RNDE
Grecia	RNGR
Hong Kong	RNHK
Irlanda	RNIE
Italia	RNIT
Japón	RNJP
Korea del Sur	RNKR
México	RNMX
Países Bajos	RNNL
Nueva Zelanda	RNNZ
Noruega	RNNO
Portugal	RNPT
Singapur	RNSG
España	RNES
Suecia	RNSE
Suiza	RNCH
Reino Unido	RNGB
Estados Unidos	RNUS

Anexo 2. Tipos de cambio reales y predicciones a horizontes de 48 meses.



Fuente: Elaboración propia 2016.

Anexo 3. PCEP y PCEPR de los de paseo aleatorio y de vida media calibrada

Modelos	PA							VM3							VM4							VM5						
	1	6	12	24	36	48	60	1	6	12	24	36	48	60	1	6	12	24	36	48	60	1	6	12	24	36	48	60
RNAU	3.78	32.01	62.29	123.49	176.53	216.96*	229.24*	1.02°	1.06	1.11	1.17	1.24°	1.32°	1.48°	1.01	1.03	1.05	1.09	1.15	1.22°	1.37°	1.01	1.01	1.03	1.06	1.10	1.16°	1.29°
RNAT	0.31	2.02	4.53	8.65	12.27	16.25	19.12	1.01	1.04	1.04	1.08	1.11	1.09	1.13	1.01	1.02	1.01	1.03	1.05	1.03	1.06	1.00	1.01	1.00	1.00	1.02	1.00	1.02
RNBE	0.33	3.04°	6.93	12.98	20.26°	34.90°	52.10°	0.99	0.95	0.91	0.88	0.89	0.77**	0.65**	0.99	0.94	0.90	0.84	0.84*	0.75**	0.66**	0.99	0.94*	0.90	0.83	0.82**	0.75**	0.68**
RNCA	1.62	15.08	31.66	64.18	102.76	132.59	152.48	1.03°	1.07	1.09	1.11	1.06	1.05	1.07	1.02°	1.03	1.04	1.04	1.00	0.99	1.01	1.01	1.02	1.02	1.01	0.97	0.96	0.97
RNTW	4.13	31.17	63.00	93.25	119.91	142.23	167.93	1.00	1.00	0.98	1.06	1.14	1.25	1.31	1.00	0.99	0.97	1.01	1.06	1.15	1.20	1.00	0.98	0.97	0.99	1.02	1.09	1.14
RNDK	0.42	3.50°	7.82	12.65	15.68	21.09	30.16	1.00	0.95	0.90	0.85	0.85	0.81	0.69	0.99	0.95	0.91	0.84	0.83	0.79	0.69	0.99	0.95*	0.92	0.85	0.83	0.79	0.71
RNXM	1.98	18.03°	40.57°	72.82°	93.32°	123.51°	154.79°	1.00	0.95	0.89*	0.79*	0.71**	0.61**	0.53**	1.00	0.95	0.90**	0.81**	0.74**	0.65**	0.57**	1.00	0.96*	0.91**	0.83**	0.76**	0.68**	0.61**
RNFI	1.18	12.87	34.36	90.62	126.00	140.74	153.14	1.04°	1.07	1.04	0.94	0.91	0.92	0.93	1.02°	1.03	1.01	0.92	0.89	0.90	0.90	1.02	1.02	0.99	0.92	0.89	0.88	0.88
RNFR	0.45	3.73	8.52	15.75	23.11°	33.10	35.21°	0.99	0.95	0.92	0.88	0.86*	0.81**	0.87	0.99	0.95	0.92	0.87	0.85**	0.80	0.85*	0.99	0.96	0.92	0.88	0.85**	0.81	0.84**
RNDE	0.70	5.87	13.57	26.87°	34.19°	47.19°	64.72°	1.00	0.97	0.92	0.82*	0.76**	0.68**	0.56**	1.00	0.97	0.92	0.83*	0.76**	0.69**	0.59**	1.00	0.97	0.93	0.84**	0.78**	0.71**	0.62**
RNGR	1.37	4.48*	8.85*	21.84	36.82	52.11	62.12	1.01	1.17°	1.30°	1.37°	1.37°	1.37°	1.46°	1.00	1.10°	1.19°	1.23	1.25	1.25	1.33	1.00	1.07°	1.13°	1.16	1.17	1.18	1.25
RNHK	3.16*	31.58	73.06	170.06	260.06	370.35	490.22	1.06°	1.14	1.19	1.19	1.16	1.08	0.97	1.04°	1.08	1.10	1.09	1.07	1.01	0.93	1.02°	1.05	1.06	1.04	1.02	0.97	0.90
RNIE	1.11	9.79	20.91	39.07	58.95	72.89	90.62	1.02	1.03	1.01	0.99	0.94	0.91	0.84	1.01	1.01	0.98	0.96	0.91	0.88	0.82	1.01	1.00	0.97	0.94	0.90	0.87	0.82
RNIT	1.06	9.89	21.94	45.51	73.93	87.02°	99.52°	1.01	1.00	0.96	0.87	0.74	0.65	0.56**	1.01	0.99	0.95	0.86	0.75	0.67	0.58**	1.00	0.98	0.95	0.87	0.77	0.69*	0.60**
RNJP	6.35	62.53	120.65	266.00	388.58	409.46	370.10	1.02	1.01	1.01	0.95	0.91	0.98	1.20	1.01	1.00	0.99	0.94	0.89	0.95	1.12	1.00	0.99	0.98	0.93	0.90	0.93	1.07
RNKR	7.08	67.33	142.20	289.97°	365.00°	397.73°	393.69	1.00	0.97	0.93	0.85*	0.82*	0.84	0.93	1.00	0.97	0.93	0.87*	0.83*	0.84	0.90	1.00	0.97	0.94	0.88*	0.85**	0.85*	0.90
RNMX	7.64	67.28	144.99	298.41°	359.51°	400.60°	508.19	1.00	0.96	0.90	0.80*	0.76*	0.76*	0.69	1.00	0.96	0.91	0.82**	0.77**	0.76**	0.70	1.00	0.96	0.92	0.84**	0.79**	0.77**	0.72
RNNL	0.57	4.42	10.04	18.86°	21.89°	26.20°	34.87°	1.00	0.97	0.93	0.85	0.84	0.78*	0.66*	1.00	0.97	0.93	0.86*	0.83*	0.78**	0.67*	1.00	0.97	0.93	0.87*	0.84*	0.78**	0.68**
RNNZ	3.92	31.67	66.20°	123.21°	188.99°	229.48°	224.91°	1.00	0.96	0.92	0.85*	0.74**	0.68**	0.68**	1.00	0.96	0.93	0.86*	0.77**	0.71**	0.70**	1.00	0.97	0.93*	0.88*	0.80**	0.74**	0.73**
RNNO	1.44	9.85°	18.21°	22.94°	26.29°	31.17°	26.96	0.99	0.95*	0.89**	0.86	0.88	0.86	1.02	0.99	0.95*	0.91**	0.87	0.87	0.85	0.97	1.00	0.96*	0.92**	0.88*	0.87*	0.86*	0.95
RNPT	0.44**	3.64	8.62	19.98**	31.79*	44.50	60.54	1.07°	1.25°	1.38°	1.51°	1.57°	1.57°	1.49	1.04°	1.15	1.23°	1.32°	1.38°	1.39°	1.34	1.03°	1.10	1.16	1.23°	1.27°	1.28	1.25
RNSG	1.08**	10.12**	28.63	81.63	145.06	202.14	246.97°	1.08°	1.26°	1.26°	1.15	1.03	0.93	0.88**	1.05°	1.17°	1.17°	1.09	0.99	0.92	0.87**	1.04°	1.12°	1.12	1.05	0.98	0.91	0.87**
RNES	0.70	5.59	13.93	35.62	57.31	78.67°	99.66°	1.02	1.06	1.04	0.94	0.86	0.78	0.71**	1.01	1.02	1.00	0.92	0.85	0.78*	0.72**	1.01	1.01	0.99	0.92	0.85	0.79*	0.73**
RNSE	2.53	23.66	51.57	101.68	142.20	156.75	176.13*	1.01	1.01	0.99	1.07	1.21	1.48°	1.71°	1.00	0.99	0.96	1.00	1.11	1.32°	1.51°	1.00	0.98	0.95	0.97	1.05	1.22	1.38°
RNCH	1.86	12.40	25.36	46.16°	56.50°	63.23°	78.62°	1.00	0.99	0.95	0.87**	0.84*	0.83*	0.76**	1.00	0.99	0.95	0.88**	0.84**	0.84**	0.77**	1.00	0.99	0.96	0.89**	0.86**	0.84**	0.79**
RRGB	3.59	32.20°	61.63°	117.87°	170.85°	240.15°	250.25°	1.00	0.95	0.91*	0.79**	0.68**	0.57**	0.53**	1.00	0.96*	0.91**	0.81**	0.71**	0.62**	0.57**	1.00	0.96**	0.92**	0.83**	0.74**	0.66**	0.61**
RNUS	2.59	24.83	53.62	109.78°	170.18°	245.28°	303.25°	1.01	0.97	0.92	0.81	0.70*	0.60**	0.52**	1.00	0.97	0.92	0.82*	0.73**	0.64**	0.57**	1.00	0.97	0.93	0.84*	0.76**	0.67**	0.61**
Promedio	2.27	19.95	42.36	86.29	121.41	148.75	169.46	1.01	1.02	1.01	0.97	0.95	0.93	0.92	1.01	1.00	0.98	0.94	0.92	0.89	0.89	1.00	1.00	0.98	0.93	0.91	0.88	0.87
ZMR	3.71	32.89	67.44	135.77	189.69	229.03	252.43	1.01	0.99	0.97	0.90	0.85	0.82	0.83	1.00	0.98	0.96	0.90	0.85	0.82	0.82	1.00	0.98	0.96	0.90	0.85	0.82	0.82
DM > 5%	2.00	1.00	0.00	1.00	0.00	0.00	2.00	0.00	0.00	1.00	2.00	4.00	7.00	9.00	0.00	0.00	3.00	4.00	8.00	9.00	10.00	0.00	1.00	3.00	5.00	10.00	9.00	12.00
DM < 5%	0.00	1.00	3.00	5.00	10.00	9.00	12.00	5.00	2.00	2.00	1.00	1.00	1.00	2.00	3.00	2.00	0.00	1.00	0.00	0.00	2.00	2.00	1.00	0.00	1.00	0.00	0.00	2.00

* Mejor predicción que el modelo base al 10%, ** Mejor predicción que el modelo base al 5%

* Peor predicción que el modelo base al 10%, ** Peor predicción que el modelo base al 5%

El estadístico de Diebold y Mariano se calcula con respecto al Paseo Aleatorio para los modelos de vida media y con respecto al modelo de vida media de 5 años para el Paseo Aleatorio

Anexo 4. PCEPR de los modelos AR(1) estimados por MCO y MCO truncado

H	MCO							MCO Truncado						
	1	6	12	24	36	48	60	1	6	12	24	36	48	60
RNAU	1.02°°	1.09°°	1.17°°	1.27°°	1.31°°	1.33°°	1.41°°	1.01°	1.05°	1.10°	1.16°°	1.20°°	1.23°°	1.32°°
RNAT	1.02°	1.09	1.10	1.15	1.17	1.15	1.20	1.01	1.04	1.05	1.10	1.12	1.10	1.15
RNBE	1.01	0.99	0.94	0.87	0.89	0.84*	0.83**	1.00	0.97	0.93	0.89	0.89	0.83**	0.79**
RNCA	1.02°°	1.05	1.09	1.03	1.00	1.08	1.38	1.01°°	1.04	1.06	1.01	0.99	1.00	1.03
RNTW	1.01	0.99	0.97	1.05	1.13	1.23	1.29	1.00	0.98	0.95	1.00	1.05	1.14	1.20
RNDK	1.01	1.00	1.00	1.01	1.07	0.99	0.80	1.00	0.97	0.95	0.94	0.97	0.89	0.74
RNXM	1.01°	1.01	0.96	0.91	0.86*	0.79**	0.71**	1.00	0.99	0.94	0.89	0.84**	0.76**	0.68**
RNFI	1.02°°	1.07°	1.09°	1.09	1.08	1.02	0.94	1.02°°	1.05	1.07	1.06	1.05	1.01	0.94
RNFR	1.02	1.08	1.09	1.07	1.05	0.90**	0.97	1.00	0.96	0.93	0.92	0.92	0.85	0.90
RNDE	1.02°	1.07	1.05	0.97	0.85	0.74**	0.63**	1.01	1.02	0.99	0.92	0.83*	0.73**	0.63**
RNGR	1.08°°	1.70°°	2.03°°	1.94°°	1.74°°	1.60°°	1.62°°	1.01	1.16°°	1.28°°	1.35°	1.36°	1.36°	1.44°
RNHK	1.01	1.09	1.23	1.53°	1.81°	2.17°	2.83°	1.01	1.02	1.03	1.09	1.15	1.17	1.14
RNIE	1.04°°	1.10	1.14	1.31°	1.32	1.44	1.41	1.01	1.00	0.99	1.03	1.02	1.03	0.96
RNIT	1.02°°	1.07°	1.10°	1.10	1.10	1.09	1.02	1.01	1.03	1.05	1.04	1.03	1.01	0.93**
RNJP	1.02°°	1.04	1.06	1.07	1.07	1.12°	1.20°°	1.01°°	1.02	1.04	1.05	1.04	1.07	1.13°
RNKR	1.04°°	1.08	1.05	0.94	0.85	0.86	0.97	1.01	0.99	0.95	0.88	0.83	0.85	0.93
RNMX	1.03°	1.01	0.96	0.85	0.85	0.84	0.71	1.00	0.95	0.89	0.80*	0.76*	0.76*	0.69
RNNL	1.01	0.99	0.92	0.82	0.82	0.79*	0.73*	1.00	0.97	0.93	0.85*	0.84	0.81*	0.75*
RNNZ	1.00	1.00	0.96	0.85*	0.77**	0.68**	0.68*	1.00	0.98	0.96	0.87*	0.80**	0.72**	0.70**
RNNO	1.01	1.01	0.96	0.98	1.00	0.97	1.15	1.00	0.96	0.91**	0.88	0.89	0.88	1.02
RNPT	1.12°°	1.50°°	1.72°	1.58°	1.47°	1.40°	1.33°	1.05°°	1.21°°	1.32°°	1.28°°	1.25	1.21	1.16
RNSG	1.01°	1.05	1.05	1.04	0.99	0.96	0.92**	1.01°	1.04	1.04	1.01	0.98	0.94	0.90**
RNES	1.04°°	1.15°	1.21	1.14	1.04	0.91	0.81*	1.02°	1.06	1.08	1.02	0.94	0.84	0.77**
RNSE	1.01	1.00	0.99	1.08	1.22	1.49°	1.84°°	1.01	0.99	0.96	0.97	1.04	1.22	1.41°°
RNCH	1.05	1.17	1.21	1.41	2.41	5.80	0.77**	1.00	1.02	0.98	0.90	0.85*	0.80**	0.78**
RNGB	1.01	0.97	0.90	0.78**	0.70**	0.59**	0.56**	1.00	0.96	0.91*	0.79**	0.71**	0.61**	0.57**
RNUS	1.01°	1.01	0.98	0.89	0.80*	0.76**	0.78**	1.01	0.99	0.95	0.86	0.80*	0.76**	0.75**
Promedio	1.03	1.09	1.11	1.10	1.13	1.24	1.09	1.01	1.02	1.01	0.98	0.97	0.95	0.94
DM > 5%	0.00	0.00	0.00	1.00	2.00	6.00	7.00	0.00	0.00	1.00	1.00	3.00	7.00	10.00
DM < 5%	10.00	3.00	2.00	2.00	2.00	2.00	4.00	4.00	2.00	2.00	2.00	1.00	1.00	2.00

* Mejor predicción que el Paseo Aleatorio al 10%, ** Mejor predicción que el Paseo Aleatorio al 5%

° Peor predicción que el Paseo Aleatorio al 10%, °° Peor predicción que el Paseo Aleatorio al 5%

Anexo 5. PCEPR de modelo de búsqueda comparado con el paseo aleatorio

H	1	2	3	4	5	6	7	8	9	10	11	12	24	36	48	60
RNAU	0.99*	1.01	1.01	1.02	1.02°	1.00	1.01	1.01	1.01	1.02	1.03	1.02	1.05°°	1.08°°	1.15°°	1.22°
RNAT	0.99**	1.00	1.01	1.00	0.98	0.97*	0.97	0.98	0.99	0.98	1.00	1.00	0.99	0.98	0.96	0.95
RNBE	0.98**	0.99*	0.98	0.98	0.98**	0.96**	0.96**	0.97	0.97	0.97	0.98	0.98	0.98	0.97	0.84*	0.69**
RNCA	1.00	0.98*	0.99	0.99	0.99	0.99	0.99	1.00	1.00	1.01	1.02	1.01	1.05	1.02	1.09	1.14°
RNTW	0.99	1.01	1.01	1.01	1.00	1.00	0.99	0.99	0.98	1.00	1.01	1.01	0.99	0.92	0.95	1.09
RNDK	0.99**	0.99*	0.98*	0.99	0.99	0.98	0.97**	0.96**	0.96**	0.96**	0.96**	0.96**	0.99	0.98	0.99	0.91
RNXM	0.99**	0.99*	0.99*	0.99*	0.98*	0.98**	0.98*	0.98	0.97	0.97	0.97*	0.97*	0.94**	1.04°°	0.93	0.80**
RNFI	0.98**	0.99	0.98	0.98	0.97	0.95	0.95	0.94	0.94	0.95	0.96	0.97	0.96	1.00	1.04	1.13°°
RNFR	0.99**	0.99*	0.98**	0.98**	0.97**	0.96**	0.95**	0.96**	0.96*	0.96*	0.97*	0.97*	0.96	1.03	0.87**	0.78**
RNDE	0.99**	0.99	0.99	1.00	0.98*	0.97*	0.97*	0.97	0.97	0.96	0.97	0.97	0.99	0.88**	0.75**	0.65**
RNGR	1.00	1.01°	1.05°°	1.04°°	1.01	1.00	1.01	1.02	1.02	0.99	0.97	0.94*	0.92	1.03	1.06	1.07°
RNHK	0.98*	0.99	0.98	1.00	1.01	1.01	0.99	0.97	0.97	0.97	0.97	0.98	0.96	1.00	1.12°	1.16°°
RNIE	0.98**	0.98**	0.99	0.99	0.99	0.98	0.98	0.97	0.97	0.97	0.97	0.97	0.98	1.06	1.12	1.12°
RNIT	0.98**	0.99	0.99	0.98	0.99	0.99	0.99	1.00	1.00	1.00	1.01	1.02	1.04°°	0.98	1.03	1.06
RNJP	0.99**	0.98*	1.00	1.00	0.99	0.98	0.97**	0.96*	0.96**	0.96*	0.96**	0.95**	0.98	1.04	1.08°°	1.01
RNKR	0.99**	0.99	0.99	0.99	0.99*	0.98**	0.97**	0.96**	0.97**	0.96**	0.96**	0.96**	0.94**	0.88*	0.84*	0.91
RNMX	0.99*	0.99	0.99	0.98*	0.97*	0.97*	0.96**	0.95**	0.94**	0.94**	0.93**	0.93**	0.94*	0.88	0.88*	0.85**
RNNL	0.99**	1.00	0.99	1.00	1.00	0.99	0.99	0.98	0.99	0.99	1.00	1.00	0.96	1.04	0.96	0.89
RNNZ	0.99	0.99	1.00	1.00	0.99	0.97*	0.96**	0.96**	0.96*	0.97	0.98	0.97	0.96	0.86**	0.73**	0.77**
RNNO	0.99*	0.99**	0.99*	0.98*	0.98	0.99	1.00	1.01	1.01	1.01	1.00	1.00	0.95	0.97	0.99	1.10°°
RNPT	0.99	1.01	1.02	0.99	0.96	0.97	1.00	1.02	1.03	1.05	1.08°	1.09°°	1.15°°	1.10°	1.15	1.13
RNSG	0.99	0.99	1.00	1.00	0.99	0.97	0.98	0.96*	0.96*	0.95*	0.96	0.96	0.96	0.98	0.95	0.94*
RNES	0.99*	1.00	1.02°°	1.00	0.98	0.98	0.98	0.97	0.98	0.96	0.97	0.97	0.98	1.04°	1.05	1.01
RNSE	0.99**	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	0.99	0.98	0.95	0.97	1.02	1.03
RNCH	1.00	0.99	1.00	1.00	0.99	0.98	0.99	0.99	0.98	0.97*	0.96*	0.97**	1.01	0.93	0.93*	0.87
RRGB	0.99**	1.00	0.99	1.00	0.99	0.99	0.99	1.00	1.00	1.00	1.00	0.99	0.98	0.94**	0.84**	0.81**
RNUS	0.98**	0.99	1.00	1.01	1.02	1.00	0.99	0.98	0.98	0.98	0.97	0.97	0.97	1.02	0.87*	0.79**
Promedio	0.99	0.99	1.00	1.00	0.99	0.98	0.98	0.98	0.98	0.98	0.98	0.98	0.98	0.99	0.97	0.96
DM > 5%	15.00	2.00	1.00	1.00	2.00	4.00	7.00	5.00	4.00	3.00	4.00	5.00	2.00	3.00	4.00	8.00
DM < 5%	0.00	0.00	2.00	1.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00	3.00	2.00	2.00	3.00

* Mejor predicción que el modelo base al 10%, ** Mejor predicción que el modelo base al 5%

* Peor predicción que el modelo base al 10%, ** Peor predicción que el modelo base al 5%

Anexo 6. PCEPR de modelo de búsqueda comparado con el modelo calibrado

H	1	2	3	4	5	6	7	8	9	10	11	12	24	36	48	60
RNAU	0.98**	1.00	1.01	1.01	1.01	0.98	1.00	1.00	1.00	1.01	1.02	1.01	1.01	0.99	0.96	0.91
RNAT	0.99*	1.01	1.02°	1.01	1.00	0.99	1.00	1.01	1.03	1.03	1.05	1.06	1.08	1.07	1.07	1.02
RNBE	0.99**	1.00	1.01	1.02	1.02	1.01	1.01	1.03	1.04	1.05	1.06°	1.08°	1.13°°	1.21°°	1.19°°	1.09°°
RNCA	0.99	0.97**	0.97*	0.97	0.97	0.98	0.98	0.99	0.99	1.00	1.01	1.01	1.06	1.08	1.18°	1.24°
RNTW	0.99*	1.00	1.00	1.00	0.99	0.99	0.98	0.98	0.97	0.99	1.00	1.01	0.91	0.83	0.79	0.83
RNDK	0.99*	1.00	1.00	1.01	1.01	1.01	1.00	1.01	1.01	1.02	1.03	1.03	1.08	1.06	1.18°	1.13
RNXM	0.99**	1.00	1.01	1.01	1.01	1.01	1.02	1.03	1.04	1.05	1.05°	1.06°	1.12°	1.35°°	1.34	1.27°°
RNFI	0.97**	0.98*	0.97	0.97	0.96*	0.95**	0.95*	0.95*	0.95*	0.96	0.98	1.00	1.07	1.16	1.21	1.30
RNFR	0.99	1.00	0.99	1.00	1.00	0.99	0.99	1.00	1.01	1.02	1.03	1.04	1.09	1.23°	1.13°°	1.06
RNDE	0.99	1.00	1.01	1.03°	1.02	1.01	1.02	1.03	1.04	1.04	1.06°	1.07°	1.19°°	1.19°°	1.18°°	1.18°
RNGR	1.00	1.01°	1.04°°	1.02	0.97	0.93*	0.95	0.96	0.95	0.91*	0.87*	0.81**	0.79	0.91	0.92	0.88
RNHK	0.96**	0.96*	0.96	0.97	0.98	0.97	0.95	0.94	0.93	0.94	0.94	0.95	0.98	1.05	1.26°°	1.41°°
RNIE	0.98**	0.97**	0.98	0.99	0.99	0.98	0.99	0.98	0.98	0.99	0.99	1.00	1.06	1.23°°	1.35°°	1.41°°
RNIT	0.98*	1.00	1.00	1.00	1.01	1.02	1.03	1.04	1.05	1.06	1.07	1.09	1.22	1.29	1.47°	1.66°
RNJP	0.99	0.99	1.01	1.02	1.02	1.02	1.01	1.00	1.00	1.00	1.01	1.01	1.12	1.26°°	1.25°°	0.99
RNKR	0.99*	1.01	1.02°°	1.02°°	1.03°°	1.02°	1.02	1.02	1.03°	1.04°	1.04°°	1.05°°	1.16°°	1.19°	1.17°	1.19°°
RNMX	1.00	1.01	1.01°°	1.01	1.01	1.01	1.01	1.00	1.00	1.01	1.01	1.02	1.20°°	1.28°°	1.38°	1.42°°
RNNL	0.99**	1.01	1.01	1.02	1.02	1.02	1.02	1.02	1.04	1.04	1.05°	1.06°	1.07	1.19°	1.16°°	1.09
RNNZ	1.00	1.00	1.01	1.02	1.01	1.00	0.99	1.00	1.00	1.02	1.04	1.04	1.09	1.07°	1.01	1.12
RNNO	1.00	1.00	1.00	1.01	1.02	1.03°	1.05°°	1.06°°	1.07°°	1.07°°	1.08°°	1.08°°	1.06	1.09	1.12	1.10
RNPT	0.95**	0.95**	0.93**	0.89**	0.85**	0.85**	0.87	0.88	0.88	0.90	0.92	0.92	0.92	0.87	0.90	0.90
RNSG	0.98**	0.98	0.97	0.96	0.94	0.92*	0.92	0.91	0.90	0.89	0.90	0.90	0.93	1.00	1.06	1.13°°
RNES	0.98**	0.99	1.02	0.99	0.96	0.96	0.96	0.96	0.98	0.96	0.97	0.97	1.05	1.18	1.25°	1.26°°
RNSE	0.99**	1.00	1.00	1.01	1.02	1.02	1.02	1.02	1.03	1.03	1.04	1.03	1.03	1.03	0.96	0.86
RNCH	1.00	1.00	1.01	1.01	1.00	0.99	0.99	0.99	0.99	0.99	0.99	1.00	1.13°°	1.08	1.13°°	1.12°°
RNGB	0.99	1.01	1.01	1.01	1.01	1.02	1.03°	1.04°°	1.05°°	1.06°°	1.07°°	1.07°°	1.17°°	1.23°°	1.21°	1.23°°
RNUS	0.98**	1.00	1.01	1.03°	1.04°°	1.04	1.03	1.03	1.03	1.04	1.05	1.05	1.11	1.22°	1.22°°	1.21°°
Promedio	0.99	0.99	1.00	1.00	1.00	0.99	0.99	1.00	1.00	1.00	1.01	1.02	1.07	1.12	1.15	1.15
DM > 5%	12.00	3.00	1.00	1.00	1.00	2.00	0.00	0.00	0.00	0.00	0.00	1.00	0.00	0.00	0.00	0.00
DM < 5%	0.00	0.00	3.00	1.00	2.00	0.00	1.00	2.00	2.00	2.00	3.00	3.00	6.00	7.00	9.00	10.00

* Mejor predicción que el modelo base al 10%, ** Mejor predicción que el modelo base al 5%

* Peor predicción que el modelo base al 10%, ** Peor predicción que el modelo base al 5%

Anexo 7. PCEPR de modelo de búsqueda modificado comparado con el modelo calibrado

H	1	2	3	4	5	6	7	8	9	10	11	12	24	36	48	60
RNAU	0.99*	0.94**	0.93**	0.94**	0.95**	0.95*	0.95*	0.94*	0.94*	0.94*	0.94	0.94	0.97	0.99	1.06	1.14°
RNAT	0.99**	0.94**	0.93**	0.94**	0.93**	0.93**	0.93**	0.92**	0.91**	0.91**	0.91**	0.91**	0.89	0.93	0.94	0.99
RNBE	0.98**	0.94**	0.93**	0.93**	0.92**	0.92**	0.92**	0.92**	0.92**	0.91**	0.90**	0.89**	0.89**	0.88**	0.85**	0.83**
RNCA	1.00	0.95**	0.94**	0.94**	0.95**	0.94**	0.95*	0.95*	0.96	0.95	0.95	0.95	0.96	0.97	0.94	0.96
RNTW	0.99	0.95**	0.95**	0.95**	0.96**	0.96**	0.96*	0.96*	0.96*	0.96	0.96	0.96	1.01	1.01	1.01	1.13
RNDK	0.99**	0.96**	0.95**	0.95**	0.95**	0.94**	0.95**	0.94**	0.94**	0.94**	0.94**	0.94**	0.95	0.94	0.91	0.90
RNXM	0.99**	0.95**	0.94**	0.95**	0.94**	0.94**	0.94**	0.94**	0.93**	0.93**	0.92**	0.92**	0.88**	0.85**	0.85**	0.85**
RNFI	0.98**	0.94**	0.93**	0.94**	0.95**	0.96*	0.95*	0.95*	0.94*	0.94*	0.94*	0.94	0.95	0.94	0.91	0.92
RNFR	0.99**	0.95**	0.95**	0.95**	0.95**	0.94**	0.95**	0.94**	0.94**	0.93**	0.92**	0.92**	0.92*	0.90**	0.89**	0.85**
RNDE	0.99**	0.95**	0.94**	0.94**	0.95**	0.95**	0.95**	0.95**	0.94**	0.94**	0.94**	0.94*	0.89**	0.88**	0.83**	0.80**
RNGR	1.00	0.95**	0.94**	0.95**	0.95**	0.99	0.99	0.95*	0.96	0.97	0.99	1.03	1.04	1.04	1.05	1.07
RNHK	0.98*	0.92**	0.91**	0.92**	0.92**	0.93**	0.93*	0.93*	0.93*	0.94*	0.93	0.94	0.95	0.97	0.94	0.94
RNIE	0.98**	0.94**	0.94**	0.94**	0.94**	0.94**	0.94**	0.95**	0.95**	0.94**	0.93**	0.93**	0.91*	0.91*	0.89**	0.92
RNIT	0.98**	0.94**	0.93**	0.94**	0.94**	0.94*	0.95*	0.94*	0.93*	0.92*	0.92*	0.92*	0.93	0.89	0.87	0.83*
RNJP	0.99**	0.95**	0.95**	0.94**	0.94**	0.94**	0.94**	0.93*	0.93*	0.92*	0.92*	0.92*	0.89**	0.90**	0.91**	1.02
RNKR	0.99**	0.97**	0.96**	0.96**	0.96**	0.95**	0.95**	0.95**	0.95**	0.94**	0.93**	0.92**	0.87**	0.87**	0.86**	0.89*
RNMX	0.99*	0.97**	0.96**	0.96**	0.96**	0.95**	0.95**	0.95**	0.94**	0.93**	0.92**	0.92**	0.86**	0.82**	0.84**	0.85**
RNNL	0.99**	0.95**	0.95**	0.95**	0.95**	0.95**	0.95**	0.95**	0.95**	0.94**	0.94**	0.94**	0.93*	0.92*	0.92**	0.91**
RNNZ	0.99	0.95**	0.94**	0.94**	0.94**	0.94**	0.94**	0.94**	0.94**	0.93**	0.93**	0.92**	0.93**	0.92**	0.90**	0.85**
RNNO	0.99*	0.97**	0.96**	0.96**	0.95**	0.95**	0.94**	0.94**	0.94**	0.94**	0.94**	0.93**	0.93**	0.91**	0.95	1.00
RNPT	0.99	0.93**	0.93**	0.94	0.96	0.99	1.00	1.00	1.00	1.01	1.02	1.03	1.12°	1.11°	1.12	1.11
RNSG	0.99	0.93**	0.93**	0.93**	0.94**	0.94**	0.94*	0.94*	0.95*	0.95	0.95	0.94	0.95	0.96	0.94	0.94**
RNES	0.99*	0.94**	0.93**	0.94**	0.95*	0.96	0.96	0.95	0.95	0.95	0.96	0.96	0.93	0.91	0.90	0.91*
RNSE	0.99**	0.95**	0.95**	0.96**	0.96**	0.96**	0.96**	0.95**	0.95**	0.95**	0.96**	0.95**	0.94*	0.95	1.00	1.05
RNCH	1.00	0.96**	0.96**	0.96**	0.96**	0.97**	0.97	0.96	0.96	0.95	0.95*	0.94	0.94**	0.93*	0.92**	0.89
RNGB	0.99**	0.95**	0.95**	0.95**	0.95**	0.95**	0.95**	0.95**	0.94**	0.94**	0.93**	0.93**	0.92**	0.89**	0.86**	0.83**
RNUS	0.98**	0.94**	0.93**	0.93**	0.93**	0.93**	0.94**	0.94**	0.93**	0.93**	0.92**	0.92**	0.89*	0.89*	0.84**	0.86**
Promedio	0.99	0.95	0.94	0.94	0.95	0.95	0.95	0.95	0.94	0.94	0.94	0.94	0.93	0.93	0.92	0.93
DM > 5%	15.00	27.00	27.00	26.00	25.00	21.00	16.00	15.00	15.00	15.00	15.00	14.00	10.00	10.00	13.00	10.00
DM < 5%	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00	1.00	0.00	0.00

* Mejor predicción que el modelo base al 10%, ** Mejor predicción que el modelo base al 5%

* Peor predicción que el modelo base al 10%, ** Peor predicción que el modelo base al 5%

Anexo 8. PCEPR de modelo de búsqueda modificado comparado con el modelo calibrado

H	1	2	3	4	5	6	7	8	9	10	11	12	24	36	48	60
RNAU	0.98**	0.94**	0.93**	0.93**	0.94**	0.94**	0.94**	0.93**	0.93**	0.93**	0.93*	0.94*	0.94	0.91	0.89	0.85*
RNAT	0.99*	0.95**	0.95**	0.95**	0.95**	0.95**	0.95**	0.95**	0.95*	0.96*	0.96	0.97	0.98	1.02	1.05	1.06
RNBE	0.99**	0.95**	0.95**	0.96**	0.96**	0.96**	0.97	0.98	0.98	0.99	0.98	0.98	1.03	1.10	1.20°	1.30°
RNCA	0.99	0.93**	0.93**	0.93**	0.94**	0.93**	0.94**	0.94**	0.95*	0.94*	0.94*	0.94*	0.97	1.03	1.02	1.04
RNTW	0.99*	0.95**	0.95**	0.95**	0.95**	0.95**	0.96**	0.95**	0.95**	0.95*	0.95*	0.95	0.94	0.91	0.85	0.86
RNDK	0.99*	0.97**	0.97**	0.97**	0.97**	0.97*	0.98	0.99	0.99	0.99	1.00	1.00	1.03	1.02	1.08	1.12
RNXM	0.99**	0.96**	0.96**	0.97**	0.97**	0.98*	0.98	0.99	0.99	1.00	1.00	1.00	1.05	1.10°	1.23°	1.35°
RNFI	0.97**	0.93**	0.92**	0.93**	0.94**	0.95*	0.95*	0.95*	0.95	0.95	0.96	0.97	1.05	1.09	1.06	1.06
RNFR	0.99	0.96**	0.96**	0.97**	0.97*	0.97	0.98	0.98	0.99	0.99	0.99	0.99	1.04	1.07	1.16°	1.16°
RNDE	0.99	0.96**	0.96**	0.97**	0.98	0.99	1.00	1.00	1.01	1.01	1.02	1.03	1.07°	1.18°	1.31°	1.44°
RNGR	1.00	0.95**	0.93**	0.94**	0.92**	0.91**	0.93**	0.89**	0.89**	0.90**	0.89**	0.89**	0.89	0.91	0.91	0.89
RNHK	0.96**	0.90**	0.89**	0.89**	0.89**	0.89**	0.90**	0.90*	0.90*	0.90	0.91	0.91	0.97	1.02	1.05	1.14°
RNIE	0.98**	0.94**	0.93**	0.94**	0.94**	0.95*	0.95	0.96	0.96	0.96	0.96	0.95	0.99	1.05	1.07	1.16°
RNIT	0.98*	0.95**	0.94**	0.95**	0.96*	0.97	0.98	0.98	0.97	0.97	0.97	0.99	1.09	1.17	1.24°	1.30°
RNJP	0.99	0.96**	0.96**	0.96**	0.97**	0.97	0.97	0.97	0.97	0.97	0.97	0.98	1.02	1.08	1.05	1.00
RNKR	0.99*	0.98**	0.98**	0.99*	1.00	1.00	0.99	1.00	1.01	1.01	1.01	1.01	1.07°	1.18°	1.20°	1.18
RNMX	1.00	0.98**	0.98**	0.99	0.99	0.99	0.99	1.00	1.00	1.00	1.01	1.01	1.10°	1.19°	1.32°	1.43°
RNNL	0.99**	0.96**	0.96**	0.97**	0.98*	0.98	0.98	0.98	0.99	0.99	1.00	1.00	1.03	1.05	1.12°	1.11
RNNZ	1.00	0.96**	0.96**	0.96**	0.97**	0.97**	0.97*	0.97	0.98	0.98	0.98	0.98	1.05	1.15°	1.25°	1.25°
RNNO	1.00	0.98**	0.98**	0.98**	0.98	0.98**	0.99	0.99	1.00	1.00	1.01	1.00	1.04	1.01	1.08	1.00
RNPT	0.95**	0.87**	0.85**	0.85**	0.85**	0.86**	0.87**	0.87**	0.86**	0.86**	0.86**	0.87**	0.89**	0.88	0.88	0.88
RNSG	0.98**	0.92**	0.90**	0.90**	0.89**	0.89**	0.89**	0.88**	0.89*	0.90*	0.89	0.89	0.93	0.98	1.04	1.13
RNES	0.98**	0.93**	0.93**	0.93**	0.94**	0.94*	0.95	0.94	0.94	0.95	0.96	0.97	0.99	1.03	1.07	1.14°
RNSE	0.99**	0.96**	0.95**	0.97**	0.97*	0.98	0.98	0.98	0.98	0.99	1.00	1.00	1.02	1.01	0.95	0.87*
RNCH	1.00	0.97**	0.96**	0.97**	0.97*	0.97	0.98	0.97	0.97	0.97	0.97	0.98	1.05°	1.09°	1.12°	1.14
RNGB	0.99	0.96**	0.96**	0.97**	0.98**	0.98*	0.99	0.99	0.99	1.00	1.00	1.00	1.10°	1.15°	1.24°	1.26°
RNUS	0.98**	0.95**	0.95**	0.95**	0.96**	0.97**	0.98	0.98	0.99	0.99	0.99	0.99	1.02	1.07	1.18°	1.32°
Promedio	0.99	0.95	0.94	0.95	0.95	0.96	0.96	0.96	0.96	0.96	0.97	0.97	1.01	1.05	1.10	1.13
DM > 5%	12.00	27.00	27.00	25.00	18.00	12.00	8.00	7.00	4.00	3.00	2.00	2.00	1.00	0.00	0.00	0.00
DM < 5%	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	4.00	6.00	10.00	10.00

* Mejor predicción que el modelo base al 10%, ** Mejor predicción que el modelo base al 5%

* Peor predicción que el modelo base al 10%, ** Peor predicción que el modelo base al 5%

Anexo 9. PCEPR del modelo calibrado para distintos tamaños de ventana

H	10 Años							15 años							20 años							20 años						
	1	6	12	24	36	48	60	1	6	12	24	36	48	60	1	6	12	24	36	48	60	1	6	12	24	36	48	60
RNAU	0.97	1.00	1.05	1.18	1.21	1.17	1.14	0.86	0.84	0.89	0.94	0.97	1.00	1.05	0.91	0.89	0.92	0.95	1.03	1.09	1.14	1.00	0.99	1.01	1.08	1.14	1.14	1.14
RNAT	1.38	1.36	1.45	1.39	1.18	0.98	0.97	1.37	1.28	1.30	1.11	0.95	0.87	0.90	1.26	1.23	1.22	1.23	1.13	0.96	0.98	1.00	0.98	0.98	0.97	0.85	0.72	0.70
RNBE	1.17	1.32	1.33	1.30	1.22	1.16	1.22**	1.23	1.34	1.27	1.09*	0.76**	0.55**	0.50**	1.18	1.21	1.27	1.25	1.01	0.79**	0.74**	1.01	1.02	1.02	1.05	1.01	0.90	0.85*
RNCA	0.77°	0.78	0.85	1.03°	1.08	1.05	1.01	0.82	0.81	0.87	1.01	1.06	1.05	1.03	0.87	0.86	0.89	1.04	1.17	1.21	1.24	0.99	0.96	0.93	0.93	0.93	0.92	0.93
RNTW	1.92	2.77°	2.71	1.59	1.47	1.44	1.32	1.74	2.34°	2.33	1.50	1.60	1.61	1.47	1.31	1.44	1.55	1.28	1.37	1.48	1.47	1.02	1.15	1.29	1.38	1.57	1.76	1.75
RNDK	1.35	1.42	1.42	1.13	1.04	1.19	1.42	1.32	1.39	1.30	0.90	0.80	0.89	0.91	1.09	1.09	1.12	0.99	0.97	1.05	1.09	1.01	1.02	1.03	1.06	1.10	1.17	1.25
RNXM	0.90	0.99	0.96	0.82	0.65	0.59**	0.58	0.92	0.96	0.90	0.69*	0.55**	0.50**	0.49	0.90	0.91	0.89*	0.78*	0.65**	0.57**	0.55	1.00	0.97	0.93	0.87*	0.79**	0.71**	0.65
RNFI	2.88	4.03	4.72	6.26	5.93	4.95	5.17	3.21	4.48	5.18	6.92	6.52	5.29	5.32	1.43	1.73	1.75	2.49	3.09	3.10	3.52	1.02	1.08	1.10	1.22	1.39	1.52	1.72
RNFR	1.44	1.34	1.24	0.99	0.86**	0.81	0.72	1.35	1.24	1.17	0.84	0.66**	0.59	0.55**	1.20	1.04	1.05	0.91	0.78	0.72**	0.69**	1.01	1.04	1.03	0.99	0.95	0.91	0.90
RNDE	1.14	1.30	1.30	1.18	0.94**	0.84	0.85	1.12	1.18	1.13*	0.98**	0.81**	0.64**	0.53**	1.07	1.09	1.07*	0.95**	0.86**	0.71**	0.62**	1.00	0.99	0.96	0.89**	0.83**	0.74**	0.67**
RNGR	1.13	1.71°	1.38°	1.36	1.30	1.31	1.33°	1.01	1.30°	1.08°	1.11	1.13	1.22°	1.33°	1.01	1.34°	1.27°	1.37	1.41	1.49	1.62	1.01	1.26°	1.35°	1.48	1.54	1.64	1.78
RNHK	1.08°	1.11	1.25	1.36	1.39	1.22	1.12	1.11	1.08	1.13	1.17	1.17	1.03	0.93	1.18	1.14	1.21	1.24	1.18	0.99	0.87**	0.98	0.87	0.76	0.68	0.65	0.63*	0.59**
RNIE	1.16°	1.05	0.89	0.70	0.65	0.61	0.61	1.16	1.08	0.90	0.69	0.63	0.57*	0.55	1.00	0.89	0.85	0.76	0.69	0.64**	0.61	1.01	1.01	0.98	0.93	0.88	0.85	0.83
RNIT	3.43	4.17	3.91	3.71*	3.83	3.04	3.52	3.72	4.31	3.94	3.42**	3.40*	2.49*	2.58*	2.21	2.28	2.03	2.49**	2.76*	1.98*	1.92*	0.99	0.96	0.91	0.84**	0.77*	0.61*	0.59*
RNJP	1.21	1.10	1.18	1.09*	1.14*	1.13*	1.21**	1.23	1.12	1.13	1.02	1.03**	1.02**	1.11	1.26	1.10	1.09	1.08	1.10**	1.07	1.10	1.00	0.98	0.97	0.90	0.83*	0.72	0.66
RNKR	1.49	1.47**	1.15**	0.92**	0.83**	0.77**	0.76**	1.60	1.50**	1.11**	0.83**	0.70**	0.63*	0.63	1.79	1.64*	1.21**	0.90**	0.78*	0.75	0.79	0.99	0.93*	0.84**	0.79**	0.75	0.74	0.77
RNMX	1.38**	1.57**	1.79*	1.99*	1.53**	1.16**	1.22**	1.43	1.41*	1.46*	1.50*	1.13**	0.85**	0.75	1.71	1.62**	1.61**	1.55**	1.12**	0.79**	0.65	0.99	0.95**	0.90**	0.81**	0.70**	0.59**	0.53**
RNNL	1.10	1.13	1.12	1.03*	0.84*	0.76**	0.81**	1.14	1.07	1.03*	0.92*	0.80*	0.70**	0.66**	1.09	1.04	1.03	0.94	0.83	0.75**	0.70**	1.00	0.98	0.94	0.88	0.83	0.76**	0.71**
RNNZ	0.98	0.98	1.02	0.88	0.78**	0.68**	0.62*	0.76	0.81	0.85	0.79	0.72**	0.66**	0.61*	0.84	0.89	0.94	0.88	0.80*	0.72*	0.68*	1.00	0.99	0.98	0.95	0.88*	0.82*	0.81
RNNO	0.71	0.69	0.63**	0.63*	0.73	0.69	0.84	0.74	0.72*	0.67**	0.67*	0.77	0.75	0.95	0.86	0.82**	0.75**	0.71*	0.75	0.76	0.96	0.99*	0.94**	0.89**	0.80*	0.76*	0.70*	0.71
RNPT	1.84°	4.02°	3.95	4.23°	4.23°	4.41°	4.29°	1.78°	4.22°	4.46°	4.71°	4.84°	5.09°	4.95°	1.23°	2.14°	2.51°	2.67°	3.17°	4.05°	4.62°	1.09°	1.83°	2.30°	3.09°	3.57°	4.11°	4.37°
RNSG	1.20°	1.83°	1.75°	1.50	1.31	1.19	1.03**	1.11°	1.20°	1.02	0.85	0.81	0.86	0.83**	1.23°	1.40°	1.24	1.02	0.91	0.84	0.76**	1.05°	1.29°	1.33°	1.25	1.16	1.08	0.98
RNES	1.96°	3.11°	3.21	3.24	2.68	2.14	1.86	2.00	3.00	3.29	3.34	2.84	2.32	2.12	1.04	1.23	1.61	1.86	1.38	1.05	0.93	1.01	1.11	1.15	1.22	1.18	1.10	1.07
RNSE	1.36	1.43	1.34	1.49	1.90	2.07	2.34	1.56	1.68	1.59	1.65	1.84	1.85	2.04°	1.21	1.20	1.14	1.72	2.25°	2.51°	2.96°	1.02	1.10	1.17	1.39°	1.88°	2.36°	2.92°
RNCH	0.87	1.01	1.09	0.98	0.79	0.64**	0.61	0.93	1.04	1.12	0.98*	0.80**	0.68**	0.63	0.98	1.05	1.13	1.09	0.98*	0.85**	0.82	1.00	1.02	1.03	0.99	0.92	0.84	0.81
RNGB	1.34	1.48	1.37	1.17*	0.91**	0.80**	0.71**	1.18	1.27	1.25	1.11**	0.78**	0.67**	0.58**	1.00	1.03	1.10*	1.14**	0.90**	0.75**	0.66**	1.00	0.96	0.92*	0.85**	0.76**	0.69**	0.65**
RNUS	1.08	1.03	1.13	1.38	1.64	1.38**	1.24	0.93	0.81*	0.74*	0.75**	0.85**	0.91**	0.96**	0.97	0.86**	0.82**	0.77**	0.73**	0.64**	0.62**	1.00	0.97	0.93*	0.86*	0.81*	0.70**	0.62**
Promedio	1.38	1.67	1.67	1.65	1.56	1.41	1.43	1.38	1.61	1.60	1.54	1.44	1.31	1.29	1.18	1.23	1.23	1.26	1.25	1.20	1.23	1.01	1.05	1.06	1.08	1.09	1.09	1.11
DM > 5%	1.00	2.00	2.00	1.00	6.00	8.00	7.00	0.00	1.00	2.00	5.00	11.00	10.00	7.00	0.00	3.00	4.00	6.00	6.00	10.00	8.00	0.00	2.00	3.00	5.00	4.00	6.00	6.00
DM < 5%	2.00	3.00	1.00	0.00	1.00	1.00	2.00	1.00	2.00	1.00	1.00	1.00	1.00	2.00	2.00	3.00	1.00	1.00	1.00	2.00	2.00	2.00	3.00	1.00	1.00	2.00	2.00	2.00

* Mejor predicción que el modelo base al 10%, ** Mejor predicción que el modelo base al 5%

* Peor predicción que el modelo base al 10%, ** Peor predicción que el modelo base al 5%

Anexo 10. PCEPR del modelo de búsqueda modificado para distintos tamaños de ventana

H	10 Años							15 años							20 años							25 años						
	1	6	12	24	36	48	60	1	6	12	24	36	48	60	1	6	12	24	36	48	60	1	6	12	24	36	48	60
RNAU	0.95	0.96*	1.00	1.13	1.15	1.10	1.03	0.85*	0.79*	0.84	0.88	0.88	0.88	0.89°	0.89*	0.85*	0.86	0.87	0.91	0.96	1.00°	0.99*	0.96*	0.95	0.99	1.03	1.06	1.09°
RNAT	1.37**	1.29**	1.42*	1.39	1.21	1.05	1.04	1.36**	1.21**	1.26*	1.09	0.96	0.92	0.95	1.24**	1.17**	1.19	1.22	1.16	0.99	1.01	0.99**	0.93**	0.94	0.96	0.88	0.82	0.86
RNBE	1.16**	1.26**	1.28**	1.29	1.24	1.27	1.47*	1.21**	1.29**	1.24**	1.13**	0.84**	0.66**	0.65**	1.17**	1.17**	1.25**	1.26*	1.03*	0.83**	0.80**	0.98**	0.94**	0.91**	0.92	0.94	0.93*	0.94**
RNCA	0.76	0.72	0.80	0.99°	1.08°	1.03	0.99	0.81	0.76**	0.82	0.98	1.09	1.07	1.07	0.86	0.80**	0.82	0.96	1.13	1.16	1.23	0.99	0.93**	0.92	0.90	0.91	0.91	0.96
RNTW	1.91	2.71	2.69	1.57	1.43	1.32	1.25	1.73	2.23	2.22	1.41	1.47	1.36	1.26	1.29	1.29*	1.37	1.08	1.07	1.13	1.15	1.00	0.93*	1.00	1.09	1.15	1.25	1.27
RNDK	1.34**	1.39**	1.43**	1.20	1.13	1.30	1.69	1.31**	1.35**	1.30*	0.93	0.81	0.96	1.02	1.07**	1.03**	1.08*	0.98	0.95	0.98	0.95	0.99**	0.93**	0.95	1.00	1.01	1.06	1.11
RNXM	0.89*	0.96**	0.96*	0.85	0.70	0.69	0.75	0.91**	0.93**	0.90**	0.72**	0.61**	0.62**	0.67**	0.89**	0.89**	0.90**	0.83**	0.72**	0.70	0.70	0.99**	0.94**	0.92**	0.89**	0.86**	0.88	0.86**
RNFI	2.79**	3.79*	4.49	6.45	6.31	5.13	5.31	3.11**	4.25**	5.00	7.26	7.10	5.62	5.63	1.39**	1.63**	1.65	2.38	3.11	3.22	3.99	0.98**	0.93**	0.94	0.99	1.10	1.18	1.29
RNFR	1.43*	1.30**	1.22*	1.00	0.91**	0.96	0.85	1.34**	1.21**	1.16*	0.87*	0.70**	0.68**	0.63	1.18*	0.99**	1.01*	0.91	0.79*	0.78**	0.76**	0.99*	0.95**	0.94	0.93	0.94	0.96	0.96
RNDE	1.13*	1.25**	1.26	1.20*	1.01**	0.93	1.02	1.12**	1.17**	1.16*	1.04**	0.95**	0.84**	0.76**	1.07**	1.09**	1.10**	1.04**	1.02**	0.90**	0.87**	0.99**	0.97**	0.96**	0.93**	0.91**	0.89**	0.86**
RNGR	1.13	1.61	1.28	1.27	1.24	1.26	1.29°	1.00	1.19	0.97	1.00	1.03	1.11	1.18°	1.00	1.15	1.06	1.12	1.16	1.23	1.33	1.01	1.02	1.09	1.16	1.21	1.27	1.36
RNHK	1.03	0.98	1.09	1.21	1.25	1.11	1.09	1.07	0.97*	1.03	1.14	1.19	1.08	1.06	1.14*	1.04**	1.13	1.23	1.25	1.09	1.06**	0.98*	0.88**	0.83	0.81*	0.81	0.78*	0.76**
RNIE	1.14*	0.99**	0.83	0.65	0.64	0.61	0.65	1.13**	1.02**	0.85*	0.68	0.66	0.61**	0.64	0.97**	0.82**	0.81*	0.76*	0.75*	0.73**	0.73	0.98**	0.92**	0.92*	0.92*	0.92*	0.91**	0.93**
RNIT	3.34**	3.93	3.72	3.72	4.01*	3.24	3.85	3.66**	4.18*	3.88	3.73**	3.99*	3.10	3.36	2.18**	2.20**	1.98*	2.90**	3.56*	2.83*	2.97*	0.98**	0.93*	0.90	0.88**	0.87**	0.89*	0.88*
RNJP	1.20*	1.07**	1.16*	1.12**	1.24**	1.20**	1.23	1.22	1.09*	1.10	1.04*	1.12**	1.07	1.12*	1.25	1.07*	1.05	1.08*	1.16**	1.14	1.17	1.00*	0.97**	0.96	0.91*	0.88**	0.83	0.85
RNKR	1.47**	1.45**	1.15**	0.96**	0.95**	0.91**	0.90**	1.59**	1.49**	1.13**	0.90**	0.83*	0.76**	0.74	1.77**	1.62**	1.22**	0.95**	0.87	0.83	0.88	0.97**	0.92**	0.87**	0.87**	0.89	0.86	0.91
RNMX	1.38**	1.53**	1.77**	2.08*	1.64**	1.36**	1.56**	1.43**	1.39**	1.48**	1.66**	1.34**	1.12**	1.07	1.71*	1.62**	1.65**	1.68**	1.28**	0.97**	0.85	0.99*	0.94**	0.92**	0.89**	0.84**	0.81**	0.82**
RNNL	1.09**	1.10**	1.11**	1.06**	0.88**	0.84*	0.93**	1.13**	1.05**	1.03**	0.95**	0.84**	0.78**	0.73**	1.08**	1.02**	1.03**	0.97**	0.88**	0.82**	0.77**	0.98**	0.94**	0.92**	0.90*	0.90**	0.90**	0.86**
RNNZ	0.98	0.97**	1.03**	0.93**	0.87**	0.81*	0.73	0.76	0.78**	0.83**	0.83*	0.82**	0.82*	0.77*	0.84	0.86**	0.91**	0.90*	0.89*	0.86*	0.80	0.99	0.95**	0.94**	0.95*	0.95*	0.95*	0.92
RNNO	0.71*	0.69**	0.64**	0.66**	0.76**	0.75	0.88	0.74*	0.71**	0.67**	0.70**	0.78**	0.81	0.94	0.86**	0.82**	0.76**	0.77**	0.78**	0.85	1.00	0.99**	0.94**	0.92**	0.89**	0.85**	0.87*	0.85*
RNPT	1.78	3.62	3.53	3.87°	3.76°	3.86°	3.82°	1.70	3.64	3.88	4.21°	4.26°	4.45°	4.36°	1.17	1.56	1.86°	1.76°	1.83°	2.48°	3.16°	1.04°	1.22°	1.42°	1.84°	2.04°	2.32°	2.50°
RNSG	1.15	1.60	1.55	1.40	1.29	1.22	1.11	1.09	1.06	0.91	0.79	0.79	0.89	0.94**	1.20	1.22	1.07	0.92	0.87	0.85	0.85	1.01	1.02	1.06	1.06	1.05	1.03	1.03
RNES	1.92	2.94	3.11	3.25	2.82	2.36	2.26	1.96**	2.82*	3.19	3.31	2.93	2.48	2.42	1.02**	1.14*	1.60	2.00	1.59	1.34	1.33	0.98**	0.97	1.02	1.05	1.06	1.04	1.04
RNSE	1.34**	1.41**	1.37*	1.55	1.93	1.99	2.12	1.54*	1.64**	1.59*	1.68	1.86	1.75	1.78°	1.18**	1.09**	1.01	1.57	1.94	1.94°	2.15°	0.99*	0.95*	0.99	1.10	1.29°	1.49°	1.73°
RNCH	0.87	0.99*	1.07	1.01	0.84	0.69**	0.67	0.93	1.01*	1.10	1.02	0.87*	0.76**	0.72	0.98	1.01*	1.07	1.12	1.02	0.89**	0.87	1.00	0.99	0.98	1.00	0.96	0.90	0.89**
RNGB	1.33*	1.47**	1.39*	1.26*	1.02**	0.99**	0.87**	1.17*	1.25**	1.25**	1.22**	0.90**	0.83**	0.73**	1.00**	1.01**	1.12**	1.27**	1.05**	0.93**	0.83**	0.99**	0.95**	0.94**	0.93**	0.89**	0.87**	0.82**
RNUS	1.05**	0.95**	1.07**	1.43	1.79	1.63**	1.64	0.92**	0.79**	0.73**	0.76**	0.91**	1.08**	1.27**	0.96**	0.86**	0.84**	0.85**	0.84**	0.77**	0.79**	0.99**	0.95**	0.93**	0.92**	0.90**	0.87**	0.88**
Promedio	1.36	1.59	1.61	1.65	1.60	1.47	1.52	1.36	1.53	1.54	1.55	1.50	1.38	1.38	1.16	1.15	1.16	1.24	1.25	1.19	1.26	0.99	0.96	0.96	0.99	1.00	1.02	1.05
DM>5%	10.00	16.00	8.00	5.00	9.00	6.00	4.00	14.00	17.00	9.00	10.00	11.00	11.00	7.00	15.00	19.00	10.00	9.00	8.00	9.00	7.00	14.00	18.00	10.00	8.00	9.00	6.00	10.00
DM<5%	0.00	0.00	0.00	0.00	2.00	1.00	2.00	0.00	0.00	0.00	1.00	1.00	1.00	2.00	0.00	0.00	0.00	1.00	1.00	2.00	2.00	0.00	0.00	1.00	1.00	2.00	2.00	2.00

* Mejor predicción que el modelo base al 10%, ** Mejor predicción que el modelo base al 5%

* Peor predicción que el modelo base al 10%, ** Peor predicción que el modelo base al 5%