



Predicción de tipos de cambio utilizando monedas MILA con Google Trends:

Francisca Menéndez Cortes

Michelle Sepúlveda Díaz

Escuela de Economía y Negocios, Universidad Finis Terrae

Profesor Guía

Nicolás Hardy Hernández

Escuela de Economía y Negocios, Universidad Finis Terrae

Tesis presentada a la Facultad de Economía y Negocios de la Universidad Finis Terrae, para optar al título de Ingeniera Comercial con Master en Finanzas.

Santiago, Chile

2020

RESUMEN

El propósito de esta investigación es evaluar la capacidad predictiva que tiene la herramienta de Google Trends para predecir los tipos de cambio de los países que componen el MILA: Chile, Perú, Colombia y México. El argumento económico y financiero detrás de esta investigación es que la frecuencia de búsqueda que entrega Google Trends es un proxy de las expectativas que tienen los agentes en el mercado sobre el rendimiento en la economía. Se utiliza el Diccionario de Harvard para reconocer palabras con connotación positiva y negativa, respecto al estado de la economía. Se realizan análisis dentro y fuera de muestra para evaluar la capacidad predictiva de Google Trends. Consistente con evidencia previa, los resultados de predictibilidad son inestables y poco robustos. Este estudio es importante para inversionistas, portfolio manager y/o agentes que deben gestionar el riesgo del tipo de cambio.



UNIVERSIDAD
Finis Terrae

UNIVERSIDAD FINIS TERRAE
FACULTAD DE ECONOMÍA Y NEGOCIOS
ESCUELA DE INGENIERÍA COMERCIAL

PRONÓSTICOS DE TIPOS DE CAMBIO CON GOOGLE TRENDS

Francisca Menéndez & Michelle Sepúlveda

Proyecto de Tesis presentado a la Facultad de Economía y Negocios de la Universidad Finis Terrae, para optar al título de Ingeniería Comercial mención Finanzas.

Profesor(es) Guía:

Nicolás Hardy: 6.0

María José Quinteros: 5.5

Carolina Martínez: 5.0

Santiago, Chile

2020

AGRADECIMIENTOS

Queremos agradecer, en primer lugar, a nuestro principal ejemplar y guía en este proceso, nuestro profesor Nicolás Hardy, PhD en Finanzas, Master en Economía Financiera y Máster en Ingeniería Financiera, quien con sus conocimientos y apoyo incondicional nos ayudó a alcanzar los objetivos de esta investigación.

Por parte de Francisca Menéndez; agradecer a mis padres, hermano, familia y amigas, haciendo una mención especial a mi madre Elisa Cortés y abuela Margot Úbeda. Por parte de Michelle Sepúlveda; agradecer a mis padres José Sepúlveda, Sandra Díaz y hermana Nicole Sepúlveda; por su constante apoyo moral y paciencia para no rendirnos ante este desafío.

1. INTRODUCCIÓN

Predecir los precios de las monedas se ha vuelto cada vez más importante para inversionistas y/o agentes económicos quienes deben gestionar el riesgo de sus inversiones, valorizar instrumentos derivados cuyo valor subyace del precio del activo y tomar decisiones de inversión en cuanto a la diversificación de sus portafolios; tal como mencionan Diebold y Lopez (1996) buenos pronósticos te llevan a tomar buenas decisiones. Además, es una actividad crítica para reguladores y Bancos Centrales, ya que el precio de las monedas afecta directamente a indicadores de inflación y crecimiento de la economía. Se puede decir también, que esta actividad se torna más crítica en periodos donde existe alta incertidumbre.

Basado en Campbell y Shiller (1987) y Engel y West (2005), el valor de un activo se basa en expectativas racionales, por ende, el precio de cualquier activo está determinado por las expectativas de sus fundamentales en el futuro. Sin embargo, medir las expectativas del mercado es una tarea desafiante, recientes estudios Masuda y Takeda (2019) y Coble y Pincheira (2017) utilizan las frecuencias diarias de Google Trends como un proxy del interés y expectativas del mercado.

El propósito de esta investigación es evaluar la capacidad predictiva de las frecuencias de búsqueda de Google Trends para predecir los tipos de cambio de los países que componen el mercado MILA: Chile, Perú, Colombia y México. La implicancia financiera detrás de esta investigación es entregarnos un proxy de las expectativas del mercado que tienen los agentes como: personas, inversionistas y/o economistas sobre el rendimiento futuro de la economía.

Google Trends entrega las frecuencias de búsquedas que diferentes personas realizan en Google, las cuales se pueden segmentar por país, región, o en distintos intervalos de tiempo. Los valores de estas frecuencias se conocen como el Índice de Volumen de Búsqueda (IVS), el cual toma valores de cero a 100, donde la mayor frecuencia de búsqueda dentro de un periodo de tiempo es 100. Distintos estudios demuestran que las frecuencias de búsqueda que entrega esta herramienta pueden ser utilizados para explicar y/o predecir fenómenos de la vida real, por ejemplo, Choi y Varian (2012) utilizando la frecuencia de búsqueda de la palabra “empleo” muestran que cuando esta búsqueda aumenta existe una alta asociación de manera contemporánea con el nivel de desempleo, de igual manera muestran que la frecuencia de búsqueda de la palabra “automóviles” tiene una alta relación con la venta de automóviles.

Respecto a la literatura de pronósticos de tipo de cambio, existe evidencia que el hecho estilizado es una baja predictibilidad, obteniendo un éxito moderado en sus resultados, puesto a lo difícil que se presenta esta tarea. Meese y Rogoff (1983) muestran que ninguno de los modelos de tipos de cambio de los años 70 logra predecir significativamente mejor que un simple paseo aleatorio, esto es conocido en la literatura como el Meese y Rogoff Puzzle, de Mossa y Burns (2015), a pesar de tener una gran cantidad de modelos y evidencia que respalda una relación entre los tipos de cambio y sus fundamentales, por alguna razón no se logra mejorar los pronósticos de tipos de cambio. Más aún, la evidencia no sólo está circunscrita a tipos de cambio, sino que a retornos de activos en general, por ejemplo, Goyal y Welch (2008)

muestran que ningún modelo conocido de Asset Pricing logran superar de manera significativa al paseo aleatorio. Elliott y Timmermann (2008) menciona que la predictibilidad es sumamente inestable y difícil de explotar en tiempo real. Finalmente, Rossi (2013) muestra que la predictibilidad en general no es un fenómeno constante, sino que aparece solo por momentos en el tiempo, “*momentos de predictibilidad*”.

Por otro lado, existe algo de evidencia más alentadora y se ha comprobado que utilizar modelos para pronosticar tipos de cambio supera a modelos de paseo aleatorio en cierto grado; entre ellos; Engel, Mark y West (2007) y Mark (1995) hacen mención que las evaluaciones de sus pronósticos de tipos de cambio en el análisis fuera de muestra superan modelos driftless y random walk.

Con respecto a la literatura relacionada con el uso de la herramienta de Google Trends en cuanto a fenómenos económicos y financieros. D’Amuri y Marcucci (2010) la utilizan como una serie que se anticipa a la tasa de desempleo de Estados Unidos. Da, Engelberg y Gao (2011) lo aplican en predicción de precios de acciones para captar la atención de los inversores. Vosen y Schmidt (2011) en pronósticos de consumo. Hamid y Heiden (2015) para predicciones de la volatilidad semanal de las acciones entregando una medida de atención para los inversionistas. Coble y Pincheira (2017) en precios de vivienda e inversiones inmobiliarias. Finalmente, Hu, Tang, Zhang y Wang (2018) para pronosticar la dirección del índice bursátil.

Sin embargo, pese a que distintos estudios aplican la herramienta de Google Trends para pronósticos financieros, existe poca evidencia sobre su poder predictivo en tipos de cambio, salvo una investigación por Masuda y Takeda (2019) donde utilizan las frecuencias de Google Trends para predecir tipos de cambio de los países Japón y Estados Unidos.

A nuestro mejor entender, esta investigación es un aporte a la literatura, por tres razones. En primer lugar, la aplicación de Google Trends como herramienta predictiva para pronósticos de tipos de cambio es escasa, por lo que este trabajo aporta a la discusión. En segundo lugar, los trabajos de predicción de monedas MILA han recibido poca atención por la literatura. En tercer lugar, se propone una metodología distinta, la cual incorpora el uso del Diccionario de Harvard IV-4 para la búsqueda de las palabras en Google Trends, utilizando sus connotaciones positivas y negativas con etiqueta económica y financiera. El uso de este diccionario tiene como objetivo evitar cualquier tipo de arbitrariedad en la connotación de las palabras.

En esta investigación se utilizan modelos lineales en un análisis tanto dentro de muestra como fuera de muestra, para evaluaciones fuera de muestra se usan recursivas, incorporando el ENCNEW Clark y McCracken (2001). Se observa que los resultados muestran una leve capacidad predictiva.

El resto del documento se organiza de la siguiente forma: En la sección 2 se presentan datos y metodología utilizada para el análisis tanto dentro como fuera de muestra. En la sección 3 se muestran los resultados y discusión de ellos. Finalmente, la sección 4 muestra las conclusiones generales de la investigación.

2. DATOS Y METODOLOGÍA

Se consideran series de los tipos de cambio con respecto al dólar americano con una frecuencia mensual, los cuales abarcan un intervalo de tiempo desde mayo del 2010 hasta mayo del 2020, utilizando los precios de cierre de las cuatro economías consideradas (Chile, Perú, Colombia y México). Los datos fueron extraídos de Thomson Reuters Datastream obteniendo una muestra total de 121 observaciones. Las frecuencias de búsqueda de las palabras extraídas de Google Trends se obtienen en el mismo intervalo de tiempo¹.

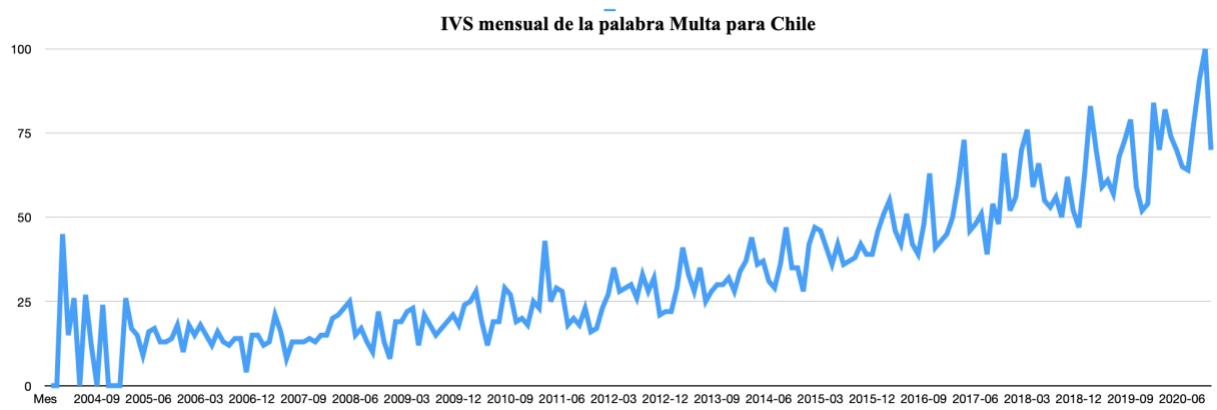
Para esta investigación se utiliza el Diccionario Harvard-IV², el cual clasifica sus palabras según su significado como: “positivas” y “negativas”. Este estudio se basa en palabras relacionadas al ámbito financiero y económico, por lo tanto, las palabras se filtran con etiquetas económicas y financieras. En general, las palabras con una connotación positiva muestran una imagen positiva de la economía o del mercado financiero de cada país, como, por ejemplo: rentable, beneficio u oro; mientras que palabras con connotación negativa como: multa, despedido o chantaje muestran una imagen contraria de la economía, lo que se logra asociar a las expectativas de cada mercado.

Se obtiene una base total de 150 palabras, las que son buscadas en Google Trends, segmentando la búsqueda por cada país MILA e intervalo de tiempo definido, lo que nos entrega una frecuencia de búsqueda la cual contiene valores por cada mes, lo que se conoce como el IVS. Para evitar que el índice posea palabras con datos insuficientes las frecuencias que tengan un 10% de IVS igual a cero son eliminadas, lo que finalmente nos queda un total de 135 palabras (*Apéndice A*). Cabe recalcar que las palabras buscadas son traducidas según corresponda para cada país. A modo de ejemplo, la Figura 1 muestra la frecuencia de búsqueda de la palabra *Multa* en Chile en el intervalo de tiempo mencionado anteriormente (Mayo 2010 a Mayo 2020).

¹ La decisión del intervalo de tiempo está relacionada con la disponibilidad de datos en Google Trends.

² Diccionario Harvard-IV clasifica sus palabras según categorías “active”, “pasive”, “strong” y “weak” y además contiene diferentes secciones como: deportiva, religiosa, económica, artes, entre otras. Diccionario disponible en: <http://www.wjh.harvard.edu/~inquirer/homecat.htm>

Figura 1:



Fuente: Elaboración de autoras

Las especificaciones econométricas básicas están inspiradas en los benchmarks utilizados por Chen et al. (2010) y en una extensa literatura que ha demostrado que tanto el Random Walk, Driftless Random Walk, y los modelos autorregresivos, suelen ser benchmarks difíciles de superar al momento de pronosticar tipos de cambio (y activos financieros en general). Las especificaciones utilizadas en nuestra investigación para los análisis dentro y fuera de muestra están inspiradas en las que utilizan los autores Pincheira y Hardy (2019).

Definidas como:

$$\Delta \ln(\gamma_{t+1}) = c + \beta \Delta \ln(\chi_t) + \rho \Delta \ln(\gamma_t) + \varepsilon_{1,t+1} \quad (1)$$

$$\Delta \ln(\gamma_{t+1}) = c + \beta \Delta \ln(\chi_t) + \varepsilon_{2,t+1} \quad (2)$$

$$\Delta \ln(\gamma_{t+1}) = \beta \Delta \ln(\chi_t) + \varepsilon_{3,t+1} \quad (3)$$

Donde:

$$\Delta \ln(\gamma_{t+1}) = \ln(\gamma_{t+1}) - \ln(\gamma_t)$$

$$\Delta \ln(\chi_{t+1}) = \ln(\chi_{t+1}) - \ln(\chi_t)$$

Donde $\Delta \ln(\gamma_{t+1})$ representa el retorno del tipo de cambio y $\Delta \ln(\chi_{t+1})$ representa la diferencia logarítmica de la frecuencia de búsqueda de Google Trends, c y β son los coeficientes de regresión y $\varepsilon_{i,t+1}$ para $i=1, 2, 3$ son los términos de error.

En la especificación (1)³ el pronóstico de los retornos de los precios de tipos de cambio de un periodo, se establece como una constante (c) más un rezago de la variable Google Trends más una componente autorregresiva para el retorno del tipo de cambio de cada país MILA en un tiempo t . En la especificación (2) es igual a la especificación (1) pero con la diferencia que no incluye la componente autorregresiva, es decir, el rezago de los retornos de Y . Por último, la especificación (3) se elimina la constante (c) y la componente autorregresiva de orden 1.

Para los análisis dentro de muestra como fuera de muestra se utilizan estimadores para la Varianza de largo plazo HAC siguiendo a Newey y West (1987, 1994).

En el análisis dentro de muestra se realiza una comparación contra un modelo autorregresivo, y para el análisis fuera de muestra se realiza una comparación de las especificaciones (1) - (3) contra los modelos benchmarks naturales (AR(1), Random Walk y Driftless Random Walk).

2.1. METODOLOGÍA DENTRO DE MUESTRA

Para determinar la capacidad predictiva que tienen las series de Google Trends en los tipos de cambio, se evalúa la siguiente prueba de hipótesis para la especificación (1):

$$H_0: \beta = 0$$

$$H_1: \beta \neq 0$$

La hipótesis nula establece que la herramienta de Google Trends no aporta información relevante ni contenido predictivo al tipo de cambio. Para evaluar esta prueba de hipótesis se utiliza el t-statistic asociado al parámetro β y se estudia su significancia. Esto con el fin de darnos una idea de las mejores palabras que pueden explicar y predecir los tipos de cambio para cada país.

2.2. METODOLOGÍA FUERA DE MUESTRA

Existen varias críticas a los análisis dentro de muestra para establecer capacidad predictiva. Primero, no son un ejercicio de pronóstico en tiempo real. Segundo hay un sesgo del investigador al buscar significancia White (2000). Tercero, un hecho estilizado es que los análisis dentro de muestra tienen tendencia a mostrar overfitting, es decir, un sobreajuste del modelo. Por esta razón, se considera un análisis fuera de muestra para disminuir las preocupaciones por sobreajuste, y son por naturaleza ejercicios de pronósticos en tiempo real.

³ La especificación (1) es un modelo diseñado para ser comparado con un AR(1), la especificación (2) con un Random Walk y la especificación (3) con un Driftless Random Walk.

Los modelos inspirados en Pincheira y Hardy (2019) que se encuentran en la especificación (1) - (3) están sujetos a restricciones. Para la especificación (2) se realiza la restricción de $\rho=0$, es decir, se excluye la componente autorregresiva, para la especificación (3) se realizan dos restricciones, $\rho=0$ y la constante (c) igual a cero. Cumplidas estas restricciones la especificación (1) es un AR(1), la especificación (2) es un Random Walk y la especificación (3) un modelo Driftless Random Walk. Luego, se compara las especificaciones (1) - (3) contra estos benchmarks para evaluar si la herramienta de Google Trends agrega contenido predictivo adicional.

Para comparar los tres benchmarks se utiliza el estadístico ENCNEW⁴ de Clark y McCracken (2001). La distribución asintótica del estadístico ENCNEW bajo la hipótesis nula es no estándar, en particular bajo la nula el ENCNEW es un funcional de movimientos Brownianos que depende de: 1) el número de exceso de parámetros del modelo a evaluar (modelo 1), 2) del límite P/R donde P es la ventana de predicción de tamaño P y R la ventana de estimación de tamaño R y 3) del esquema utilizado para actualizar las estimaciones de los parámetros (que puede ser rodante, recursivo o fijo).

Para realizar la evaluación fuera de muestra, se divide la muestra total en dos ventanas: La ventana de predicción de tamaño P y la ventana de estimación de tamaño R, por lo que resulta, $P+R=T$, donde T es el número total de observaciones. Para actualizar los pronósticos se utiliza ventana recursiva. Se emplean tres formas distintas para dividir la muestra de estimación y evaluación: $P/R=1$ ($R=61$; $P=60$), $P/R=2$ ($R=40$; $P=81$) y $P/R=0.4$ ($R=80$; $P=41$). Para más detalle sobre evaluación de pronósticos fuera de muestra ver West (2006) y Clark y McCracken (2011).

3. RESULTADOS

A continuación, se presentan los resultados dentro de muestra y fuera de muestra. En el análisis dentro de muestra se utiliza la especificación (1) para las 135 palabras para cada uno de los países, lo que da un total de 540 regresiones. Estos resultados están disponibles en el *Apéndice B* y los mejores resultados se encuentran en el *Apéndice C*. Para efecto de la discusión de resultados se muestran los más destacados en la Tabla 1-3.

Luego, se procede con el análisis fuera de muestra, donde se presentan los resultados del estadístico ENCNEW de Clark y McCracken (2001) para los tres modelos en evaluación para las especificaciones (1) – (3). Estos resultados están disponibles en el *Apéndice D* con ventanas recursiva y rodante. Para efecto de la discusión de resultados se muestran los más destacados en la Tabla 4-7.

⁴ Adicionalmente se utiliza el ENCT de Clark y West (2005) (2006), Clark y McCracken (2001) los resultados fueron muy similares y están disponibles en caso de ser solicitados por los revisores.

3.1. RESULTADOS DENTRO DE MUESTRA

El *Apéndice C* muestra las 53 palabras que presentaron resultados estadísticamente significativos para predecir tipos de cambio. En Chile se obtuvo un resultado de 24 palabras significativas, en Perú 10, en Colombia 13 y para México 6.

Las siguientes tablas muestran los resultados más destacados y fueron separadas según su etiqueta de connotación perteneciente al diccionario utilizado, lo cual genera tres diferentes tablas: **Tabla 1** etiqueta positiva, **Tabla 2** etiqueta negativa y **Tabla 3** sin connotación (ni positiva ni negativa).

Tabla 1

Análisis dentro de muestra: Tabla de palabras positivas. Frecuencia mensual.

(1)	(2)	(3)	(4)	(5)
	Chile	Perú	Colombia	México
Acumular	-0.003*** (0.000)	-0.001 (0.004)	-0.002*** (0.000)	0.003 (0.009)
AR(1)	0.005 (0.078)	-0.016 (0.101)	0.083 (0.078)	-0.041 (0.083)
Constante	0.003 (0.002)	0.001 (0.001)	0.005 (0.002)	0.005 (0.002)
R-squared	0.038	0.001	0.016	0.002
Observations	119	119	119	119

Notas: La tabla 1 presenta estimación de la especificación (1) incorporando la frecuencia de búsqueda de la palabra Acumular. Las desviaciones estándar se encuentran entre paréntesis.

*p < 10%, **p < 5%, ***p < 1%.

Fuente: Elaboración de autoras.

En la Tabla 1 se utiliza la especificación (1), en donde se analiza la palabra *Acumular*, la cual tiene una connotación positiva en el Diccionario de Harvard. Se puede observar que es significativa para Chile y Colombia al 1%. Cuando se trabaja con palabras de connotación positiva se espera que a la economía le vaya mejor, por ende, existe una valorización del tipo de cambio con respecto al dólar americano, por lo que se espera un signo negativo del coeficiente de la palabra y se puede observar que existe una relación consistente con el signo del coeficiente de la palabra para todos los países a excepción de México.

Para los países Chile y Colombia, se encuentra evidencia de predictibilidad en sus tipos de cambio y sus R^2 son 3.8% y 1.6% respectivamente.

Tabla 2
Análisis dentro de muestra: Tabla de palabras negativas. Frecuencia mensual.

(1)	(2)	(3)	(4)	(5)
	Chile	Perú	Colombia	México
Deudas	0.026** (0.008)	0.001 (0.006)	0.036** (0.017)	0.023 (0.020)
AR(1)	0.009 (0.071)	-0.016 (0.112)	0.074 (0.079)	-0.053 (0.090)
Constante	0.003 (0.002)	0.001 (0.001)	0.005 (0.002)	0.005 (0.002)
R-squared	0.050	0.000	0.028	0.013
Observations	119	119	119	119

Notas: La tabla 1 presenta estimación de la ecuación (1) incorporando la frecuencia de búsqueda de la palabra Deudas. Las desviaciones estándar se encuentran entre paréntesis.

*p < 10%, **p < 5%, ***p < 1%.

Fuente: Elaboración de autoras.

En la Tabla 2 se utiliza la especificación (1), en donde se analiza la palabra *Deudas* la cual tiene una connotación negativa en el Diccionario de Harvard. Al igual que para el análisis de la palabra *Acumular* descrito en la Tabla 1 se puede observar que la palabra *Deudas* también presenta evidencia de predictibilidad en los países Chile y Colombia, pero se obtiene una significancia al 5%, y sus R^2 son 5% y 2.8% respectivamente. Además, existe una relación consistente con el signo del coeficiente de la palabra para los cuatro países, ya que cuando se trabaja con palabras de connotación negativa se espera un signo positivo del coeficiente, debido a la desvalorización del tipo de cambio frente al dólar americano.

Tabla 3

Análisis dentro de muestra: Tabla de palabras sin connotación. Frecuencia mensual.

(1)	(2)	(3)	(4)	(5)
	Chile	Perú	Colombia	México
Commodity	-0.000 (0.000)	-0.006*** (0.000)	-0.014* (0.008)	0.001 (0.007)
AR(1)	-0.013 (0.072)	-0.001 (0.095)	0.113 (0.105)	-0.041 (0.093)
Constante	0.003 (0.002)	0.001 (0.001)	0.005 (0.002)	0.005 (0.002)
R-squared	0.008	0.007	0.038	0.001
Observations	119	119	119	119

Notas: La tabla 3 presenta la estimación de la ecuación (1) incorporando la frecuencia de búsqueda de la palabra Commodity. Las desviaciones estándar se encuentran entre paréntesis.

*p < 10%, **p < 5%, ***p < 1%.

Fuente: Elaboración de autoras.

En la Tabla 3 se utiliza el modelo de la especificación (1) en donde se analiza la palabra *Commodity*, la cual no presenta connotación positiva ni negativa, es por esto que la Tabla 3 recibe el nombre de “tabla de palabras sin connotación”. En este caso, no se espera signo específico para el coeficiente, ya que las palabras sin connotación no contienen una etiqueta positiva o negativa.

Sin embargo, se puede realizar un análisis connotando a la palabra como positiva, puesto que se asocia su búsqueda como una expectativa positiva para el mercado, ya que se presentan cuatro economías exportadoras. Por ende, si existe un incremento en la atención por el precio del commodity, esto puede dar un fortalecimiento a la moneda con respecto al dólar americano. En línea con lo anterior, los signos arrojados por el coeficiente presentan una relación consistente en todos los países a excepción de México.

Por otra parte, al igual que las Tablas 1 y 2, esta palabra presenta significancia en el país Colombia al 10%, pero se incorpora evidencia de predictibilidad en el país Perú, con una significancia al 1%, en donde sus R^2 son 0,7% y 3.8% respectivamente.

3.2. RESULTADOS FUERA DE MUESTRA

En esta sección, las Tablas 4-7 muestran los resultados más destacados por cada país MILA del estadístico ENCNEW de Clark y McCracken (2001) con ventana recursiva de las especificaciones (1) - (3). Estos resultados tanto para ventana recursiva como rodante se pueden observar en el *Apéndice D*.

Se utilizan tres divisiones para los ejercicios de fuera muestra de las Tablas 4-7 en donde, el *Panel A* corresponde a la primera ventana de estimación ($P/R=1$), para el *Panel B* a la segunda ventana de estimación ($P/R=2$) y para el *Panel C* la tercera ventana de estimación ($P/R=0.4$). Para la actualización de las estimaciones se utilizan ventanas recursivas.

A continuación, se presentan las tablas 4, 5, 6 y 7 las cuales cada una es representativa por país. La Tabla 4 corresponde a Chile, la Tabla 5 a Perú, la Tabla 6 a Colombia, y finalmente la Tabla 7 muestra el país de México. El análisis de cada tabla se encuentra después de ellas.

Tabla 4**Análisis fuera de muestra para Chile: ENC-NEW. Ventana recursiva. Frecuencia mensual.**

Panel A	(1)	(2)	(3)	(4)	(5)	(6)	(7)
Modelo Benchmark	Beneficio	Cohecho	Corporación	Multa	Empleo	Trabajo	Profesión
AR(1)	1.56*	3.02***	1.41*	2.24**	1.15*	1.28*	1.40*
RW	1.58**	3.52***	1.60**	2.47**	1.12*	1.43*	1.50*
DRW	0.80	0.50	0.51	0.93	0.50	0.36	0.17
Panel B	(1)	(2)	(3)	(4)	(5)	(6)	(7)
Modelo Benchmark	Beneficio	Cohecho	Corporación	Multa	Empleo	Trabajo	Profesión
AR(1)	1.28*	1.33*	1.39*	1.85*	0.75	0.06	0.70
RW	1.47*	1.28*	1.58*	1.78*	0.74	0.21	0.82
DRW	1.29*	2.09**	1.00	0.90	0.59	0.19	0.51
Panel C	(1)	(2)	(3)	(4)	(5)	(6)	(7)
Modelo Benchmark	Beneficio	Cohecho	Corporación	Multa	Empleo	Trabajo	Profesión
AR(1)	1.72**	0.77*	0.74*	1.38**	0.17	0.28	0.09
RW	0.76*	0.73*	1.48**	1.33**	0.21	0.23	0.02
DRW	0.65	0.72*	2.09***	2.35***	0.20	0.20	0.01

Notas: Para el Panel A los valores críticos para el 10%, 5% y 1% de significancia son 0,984, 1.584 y 3.209 respectivamente. Para el Panel B son 1.280, 2.085 y 4.134 respectivamente y para el Panel C 0.685, 1.079 y 2.098 respectivamente. Cuando existe 1 parámetro adicional y se utiliza ventana recursiva.

*p < 10%, **p < 5%, ***p < 1%.

Fuente: Elaboración de autoras.

Tabla 5**Análisis fuera de muestra para Perú: ENC-NEW. Ventana recursiva. Frecuencia mensual.**

Panel A	(1)	(2)	(3)	(4)	(5)	(6)	(7)
Modelo Benchmark	Cuota	Despedido	Efectivo	Empleo	Intereses	Pensión	Rentable
AR(1)	2.49**	0.67	1.04*	1.31*	1.11*	1.69**	1.69**
RW	2.43**	1.04*	1.05*	1.33*	1.09*	1.57**	1.58**
DRW	1.49*	1.61*	1.07*	1.18*	1.12*	0.72	0.69
Panel B	(1)	(2)	(3)	(4)	(5)	(6)	(7)
Modelo Benchmark	Cuota	Despedido	Efectivo	Empleo	Intereses	Pensión	Rentable
AR(1)	1.77*	1.15	1.00	1.22	1.26	1.19	2.32*
RW	1.78*	1.58*	1.02	1.26	1.35*	1.34*	2.08**
DRW	1.47*	2.40**	1.28*	1.24	2.12**	0.86	1.02
Panel C	(1)	(2)	(3)	(4)	(5)	(6)	(7)
Modelo Benchmark	Cuota	Despedido	Efectivo	Empleo	Intereses	Pensión	Rentable
AR(1)	1.36**	1.07**	1.23**	0.90*	1.16**	1.02*	0.92*
RW	1.30**	1.00*	1.23**	0.98*	1.15**	0.99*	0.90*
DRW	2.17***	0.82*	1.19**	0.78*	1.11*	0.83*	0.72*

Notas: Para el Panel A los valores críticos para el 10%, 5% y 1% de significancia son 0,984, 1.584 y 3.209 respectivamente. Para el Panel B son 1.280, 2.085 y 4.134 respectivamente y para el Panel C 0.685, 1.079 y 2.098 respectivamente. Cuando existe 1 parámetro adicional y se utiliza ventana recursiva.

*p < 10%, **p < 5%, ***p < 1%.

Fuente: Elaboración de autoras.

Tabla 6**Análisis fuera de muestra para Colombia: ENC-NEW. Ventana recursiva. Frecuencia mensual.**

Panel A	(1)	(2)	(3)	(4)	(5)	(6)	(7)
Modelo Benchmark	Apuesta	Beca	Chantaje	Contaminar	Commodity	Deudas	Retail
AR(1)	1.83**	2.46**	1.21*	0.29	0.70	1.06*	2.02**
RW	1.87**	2.30**	1.42*	0.92	0.80	1.00*	1.86**
DRW	1.81**	3.45***	1.53*	1.25*	1.47*	1.19*	1.89**
Panel B	(1)	(2)	(3)	(4)	(5)	(6)	(7)
Modelo Benchmark	Apuesta	Beca	Chantaje	Contaminar	Commodity	Deudas	Retail
AR(1)	0.05	1.90*	1.74*	0.66	0.64	1.57*	1.80*
RW	0.39	1.89*	1.85*	1.03	0.67	1.63*	2.22**
DRW	1.36*	2.96**	1.89*	1.41*	1.70*	1.65*	2.30**
Panel C	(1)	(2)	(3)	(4)	(5)	(6)	(7)
Modelo Benchmark	Apuesta	Beca	Chantaje	Contaminar	Commodity	Deudas	Retail
AR(1)	0.54	0.23	1.02*	1.11**	1.19*	0.28	0.08
RW	0.49	0.71*	1.37**	0.68*	0.72	0.91*	0.76*
DRW	0.84*	1.11**	2.45***	2.34***	1.12*	1.23**	0.99*

Notas: Para el Panel A los valores críticos para el 10%, 5% y 1% de significancia son 0,984, 1.584 y 3.209 respectivamente. Para el Panel B son 1.280, 2.085 y 4.134 respectivamente y para el Panel C 0.685, 1.079 y 2.098 respectivamente. Cuando existe 1 parámetro adicional y se utiliza ventana recursiva.

*p < 10%, **p < 5%, ***p < 1%.

Fuente: Elaboración de autoras.

Tabla 7**Análisis fuera de muestra para México: ENC-NEW. Ventana recursiva. Frecuencia mensual.**

Panel A	(1)	(2)	(3)	(4)	(5)	(6)	(7)
Modelo Benchmark	Atrasado	Beca	Corredor	Dueño	Factura	Liquidación	Peaje
AR(1)	0.87	0.50	2.01**	1.23*	0.98*	1.14*	1.26**
RW	0.85	0.52	1.95**	1.50*	1.58*	1.22*	1.49*
DRW	1.78*	1.61*	2.08**	1.40*	1.22*	2.16**	1.40*
Panel B	(1)	(2)	(3)	(4)	(5)	(6)	(7)
Modelo Benchmark	Atrasado	Beca	Corredor	Dueño	Factura	Liquidación	Peaje
AR(1)	1.29*	0.70	1.85*	1.43*	0.81	1.44*	1.38*
RW	2.13**	0.97	1.93*	1.72*	1.12	1.69*	1.64*
DRW	2.63**	1.39*	1.97*	1.70*	1.59*	3.38**	1.59*
Panel C	(1)	(2)	(3)	(4)	(5)	(6)	(7)
Modelo Benchmark	Atrasado	Beca	Corredor	Dueño	Factura	Liquidación	Peaje
AR(1)	0.72*	0.50	1.12**	1.15*	0.67	0.16	0.99*
RW	0.93*	0.86*	1.14**	1.42*	1.15**	0.57	1.09**
DRW	2.63***	1.04*	0.97*	0.76*	2.59***	0.98*	0.77*

Notas: Para el Panel A los valores críticos para el 10%, 5% y 1% de significancia son 0,984, 1.584 y 3.209 respectivamente. Para el Panel B son 1.280, 2.085 y 4.134 respectivamente y para el Panel C 0.685, 1.079 y 2.098 respectivamente. Cuando existe 1 parámetro adicional y se utiliza ventana recursiva.

*p < 10%, **p < 5%, ***p < 1%.

Fuente: Elaboración de autoras.

La Tabla 4 muestra los mejores resultados para el país de Chile, en donde las palabras que existe evidencia predictiva sobre los tipos de cambio son *Beneficio*, *Cohecho*, *Corporación*, *Multa*, *Empleo*, *Trabajo* y *Profesión*. Para la primera ventana de estimación (P/R=1), correspondiente al Panel A, se observa que en las siete palabras se logra un rechazo para la nula en los dos primeros benchmarks AR(1) y RW con al menos un 10% de significancia a excepción del DRW, esto quiere decir que para Chile no se encuentran buenos resultados en el último benchmark descrito en la especificación (3). En el Panel B (P/R=2) se encuentra que las palabras *Beneficio* y *Cohecho* superan a los tres benchmarks con al menos un 10% de significancia, pero, a diferencia del Panel A, en este panel no todas las palabras alcanzan significancia para los dos primeros benchmarks. En el último Panel C (P/R=0.4), se puede observar que existe una fuerte evidencia de predictibilidad para sólo tres palabras las cuales son *Cohecho*, *Corporación*, *Multa* contra los tres benchmarks. Cabe destacar que las palabras *Cohecho* y *Multa* tienen un buen comportamiento en los tres paneles, en donde la palabra *Multa* mejora en el Panel C contra los modelos AR(1) y RW presentando una significancia al 5% y al 1% en DRW, mientras que la palabra *Cohecho* presenta mayor evidencia de predictibilidad en el Panel A.

La Tabla 5 muestra los mejores resultados para el país de Perú, en donde las palabras que presentan evidencia de predictibilidad sobre los tipos de cambio son *Cuota*, *Despedido*, *Efectivo*, *Empleo*, *Intereses*, *Pensión* y *Rentable*. Para el Panel A (P/R=1) se encuentran los mejores resultados para este país, mostrando un rechazo a la hipótesis nula en las palabras *Cuota*, *Efectivo*, *Empleo* e *Intereses* con al menos un 10% de significancia contra todos los benchmarks. Se encuentra una evidencia de predictibilidad en 4 de 7 palabras.

Sin embargo, en las palabras *Pensión* y *Rentable* no se rechaza la hipótesis nula para el DRW pero si tanto para el AR(1) como para el RW, ambas con un 5% de significancia. Para el Panel B (P/R=2) la única que tiene un mejor comportamiento en todos los modelos es la palabra *Cuota* con un nivel de significancia del 10% contra los tres benchmarks: AR(1), RW y DRW teniendo esta la mayor presencia de evidencia de predictibilidad. Por último, para el Panel C (P/R=0.4), las siete palabras obtienen un distinguido rechazo para la nula encontrando una mayor evidencia de predictibilidad contra todos los benchmarks con al menos un 10% de significancia, siendo este el mejor panel con los mejores resultados para Perú.

La Tabla 6 muestra los mejores resultados para el país de Colombia, en donde las palabras que presentan evidencia de predictibilidad sobre los tipos de cambio son *Apuesta*, *Beca*, *Chantaje*, *Contaminar*, *Commodity*, *Deudas*, *Fundación* y *Retail*. Se puede observar que en el Panel A (P/R=1) se encuentran los mejores resultados para este país, mostrando evidencia de predictibilidad en 5 de 7 palabras, en donde las palabras *Apuesta*, *Retail* muestran un 5% de significancia contra los tres benchmarks y *Beca* supera a los dos primeros benchmarks con un 5% de significancia y al DRW con 1% de significancia, mientras que las palabras *Chantaje* y *Deudas* lograron superar a los tres modelos benchmarks con un 10% de significancia.

A pesar de que en las palabras *Contaminar* y *Commodity* se encuentra una baja evidencia de predictibilidad, en ambas se rechaza la hipótesis nula superando al modelo DRW con un 10% de significancia. Para el Panel B (P/R=2) se encuentra un mejor comportamiento contra los tres modelos benchmarks en las palabras *Beca*, *Chantaje*, *Deudas* y *Retail*, presentando una evidencia de predictibilidad al 10% y 5% de significancia. Por último, para el Panel C (P/R=0.4) se puede observar que la palabra *Chantaje* mejora a diferencia, de los paneles A y B contra los modelos RW con una significancia del 5% y DRW con una significancia al 1%. Por otro lado, también se encuentra evidencia de predictibilidad en la palabra *Contaminar*, la que supera a los tres benchmarks con un 5%, 10% y 1% de significancia respectivamente.

La Tabla 7 muestra los mejores resultados para el país de México, en donde las palabras que presentan evidencia de predictibilidad sobre los tipos de cambio son *Atrasado*, *Beca*, *Corredor*, *Dueño*, *Factura*, *Liquidación* y *Peaje*. Se puede observar que en el Panel A (P/R=1) y Panel B (P/R=2) se presenta una mayoría de palabras que superan a los tres modelos benchmarks, encontrando una mayor evidencia de predictibilidad en 5 de 7 palabras por panel. Las palabras *Corredor*, *Dueño*, *Liquidación* y *Peaje* se comportan de una manera similar en ambos paneles (A y B), rechazando la hipótesis nula para los tres modelos benchmarks. En el Panel A la palabra *Corredor* supera a los modelos AR(1) y RW con un 5% de significancia mientras que en el Panel B al 10%, lo mismo ocurre para la palabra *Peaje*. En cuanto al Panel C (P/R=0.4), este solo presenta una evidencia de predictibilidad estable en *Corredor* y *Peaje*, las que también se repiten para los paneles A y B, teniendo comportamientos similares al Panel A en su significancia contra los modelos benchmarks.

4. CONCLUSIONES

En este estudio, exploramos el uso de la herramienta de Google Trends como una forma de captar las expectativas de economías MILA para ayudar a predecir o encontrar algo de evidencia de predictibilidad sobre los tipos de cambio de estos países con respecto al dólar americano. Existe evidencia en la literatura de pronósticos, que el valor de cualquier activo se basa en expectativas racionales, por lo tanto, el valor de un activo está determinado por las expectativas de sus fundamentales en el futuro.

Pronosticar los tipos de cambio es una tarea importante para inversionistas y/o agentes económicos quienes deben gestionar el riesgo de sus inversiones, valorizar instrumentos derivados y tomar decisiones de inversión. Diebold y Lopez (1996) mencionan que “*good forecasts lead to good decisions*”; “buenos pronósticos llevan a buenas decisiones”

En el análisis dentro de muestra, en cuanto a la relación consistente del signo en el coeficiente de cada palabra, a nuestro mejor entender, cuando una palabra posee una connotación negativa significa que existen malas expectativas de lo que va a suceder en la economía. Por ende, decimos que cuando existe una mayor frecuencia de búsqueda de una palabra con connotación negativa dentro de un país, se podría especular desvalorización en su tipo de cambio.

Por ejemplo, en el análisis dentro de muestra para el país de Colombia, la palabra *Deudas* posee una connotación negativa en el Diccionario de Harvard y entrega como resultado un signo positivo en el coeficiente, es decir, existe una relación consistente con el signo, ya que si las personas de este país incrementan la búsqueda de la palabra *Deudas*, estas tienen una mala expectativa sobre lo que sucederá en la economía del país, lo que genera una depreciación en el tipo de cambio, en donde la moneda local pierde valor frente al dólar, en otras palabras, se necesitan más pesos colombianos para adquirir un dólar.

En caso contrario, en palabras con connotación positiva, se debiese esperar a priori que el coeficiente de la palabra obtenga un signo negativo, debido a que, si se presentan buenas expectativas de lo que sucede en la economía, se estaría valorizando la moneda con respecto al dólar, en otras palabras, con la misma moneda se necesitan menos pesos para comprar un dólar. Cabe recalcar que este mismo análisis se puede realizar en todas las palabras trabajadas en las estimaciones del modelo para la especificación (1).

Con respecto al análisis fuera de muestra, a nivel poblacional (ENCNEW) se encuentra evidencia de predictibilidad en los países MILA pero en general es inestable, ya que cada mercado se comporta de una manera diferente. Sin embargo, en algunos países se muestran palabras significativas y una evidencia leve de predictibilidad, puesto que se logra vencer a los modelos benchmarks naturales.

En general los mejores resultados fueron encontrados en el Panel C ($P/R=0.4$) con ventana recursiva para cada país. En donde se obtiene la mayoría de palabras que rechazan significativamente la hipótesis nula para todos los modelos benchmarks en comparación a los Paneles A y B.

Podemos decir que, existe algo de contenido predictivo adicional en la herramienta de Google Trends sobre los tipos de cambio de los países MILA, no es ingenuo pensar que debiese funcionar para distintos países y mercados. Para investigaciones futuras se recomienda incorporar una mejora a nuestro modelo, modificando la variable de Google Trends como una combinación de las mejores palabras estadísticamente significativas para cada país. Se deja una interesante línea de investigación para proponer Google Trends como herramienta de predicción para otros mercados con ajustes en su metodología y modelos.

REFERENCIAS

- [1] Campbell, J. Y., & Shiller, R. J. (1987). Cointegration and tests of present value models. *Journal of political economy*, 95(5), 1062-1088.
- [2] Chen Y., K. Rogoff and B. Rossi (2010) Can Exchange Rates Forecast Commodity Prices? *The Quarterly Journal of Economics*, August 2010, 125 (3), 1145--1194.
- [3] Choi, H., & Varian, H. (2012). Predicting the present with Google Trends. *Economic record*, 88, 2-9.
- [4] Clark, T. E., & McCracken, M. W. (2001). Tests of equal forecast accuracy and encompassing for nested models. *Journal of econometrics*, 105(1), 85-110.
- [5] Coble, D., & Pincheira, P. M. (2017). Now-casting building permits with Google trends. Available at SSRN 2910165.
- [6] Da, Z., Engelberg, J., & Gao, P. (2011). In search of attention. *The Journal of Finance*, 66(5), 1461-1499.
- [7] Diccionario de Harvard-IV disponible en: <http://www.wjh.harvard.edu/~inquirer/homecat.htm>
- [8] Diebold, F. X., & Lopez, J. A. (1996). 8 Forecast evaluation and combination. *Handbook of statistics*, 14, 241-268.
- [9] D'Amuri, F., & Marcucci, J. (2010). 'Google it!' Forecasting the US unemployment rate with a Google job search index.
- [10] Elliott, G., & Timmermann, A. (2008). Economic forecasting. *Journal of Economic Literature*, 46(1), 3-56.
- [11] Engel, C., & West, K. D. (2005). Exchange rates and fundamentals. *Journal of political Economy*, 113(3), 485-517.
- [12] Engel, C., Mark, N., & West, K. (2007). Exchange rate models are not as bad as you think. *NBER Macroeconomic Annual*, 22, 381-441. doi:10.3386/w13318
- [13] Goyal A. and I. Welch (2008). A comprehensive look at the empirical performance of equity premium prediction. *Review of Financial Studies*, 21(4), 1455--1508.
- [14] Hamid, A., & Heiden, M. (2015). Forecasting volatility with empirical similarity and Google Trends. *Journal of Economic Behavior & Organization*, 117, 62-81.
- [15] Hu, H., Tang, L., Zhang, S., & Wang, H. (2018). Predicting the direction of stock markets using optimized neural networks with Google Trends. *Neurocomputing*, 285, 188-195.
- [16] Mark, N.C. (1995). Exchange rates and fundamentals: Evidence on long-horizon predictability. *American Economic Review*, 85(1), 201-218.
- [17] Masuda, M., & Takeda, F. (2019). Application of Google Trends Data in Exchange Rate Prediction.
- [18] Meese, R. A., & 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.

- [19] Moosa I.A., Burns K. (2015) The Meese-Rogoff Puzzle. In: Demystifying the Meese-Rogoff Puzzle. Palgrave Pivot, London.
- [20] Newey, W. K., & West, K. D. (1987). Hypothesis testing with efficient method of moments estimation. *International Economic Review*, 777-787.
- [21] Newey, W. K., & West, K. D. (1994). Automatic lag selection in covariance matrix estimation. *The Review of Economic Studies*, 61(4), 631-653.
- [22] Plataforma Google Trends disponible en: <https://trends.google.com/trends/?geo=US>
- [23] Pincheira Brown, P., & Hardy, N. (2019). Forecasting base metal prices with the Chilean exchange rate. *Resources Policy*, 62, 256–281.
- [24] Pincheira, P. M., & Hardy, N. (2019a). Forecasting Aluminum Prices with Commodity Currencies. Available at SSRN 3511564.
- [25] Rossi, B. (2013). Exchange rate predictability. *Journal of economic literature*, 51(4), 1063-1119.
- [26] Vosen, S., & Schmidt, T. (2011). Forecasting private consumption: survey-based indicators vs. Google trends. *Journal of forecasting*, 30(6), 565-578.
- [27] West, K. D. (2006). Forecast evaluation. *Handbook of economic forecasting*, 1, 99-134.
- [28] White, H. (2000). A reality check for data snooping. *Econometrica*, 68(5), 1097-1126.

APENDICES:

Este archivo se encuentra disponible para los revisores a su solicitud.

Los Apendices se encuentran descritos de la siguiente manera:

Apendice A: Palabras analizadas extraídas desde Google trends para análisis dentro y fuera de muestra.

Apendice B: Resultados análisis dentro de muestra del total de palabras para cada país MILA.

Apendice C: Mejores resultados obtenidos dentro de muestra, este apendice muestra todas las palabras estadísticamente significativas contra un AR(1).

Apendice D: Resultados análisis fuera de muestra, ENCNEW en ventana recursiva y rodante.