



Banca Central

No. 81 - enero / junio - 2021 - Año XXX - Guatemala, C. A.



CONSEJO EDITORIAL

Director

Johny Rubelcy Gramajo Marroquín

Consejeros

Jorge Vinicio Cáceres Dávila
Leonel Moreno Mérida
Ivar Ernesto Romero Chinchilla
Juan Carlos Castañeda Fuentes
Carlos Eduardo Castillo Maldonado

Coordinación

Ronald Vinicio Ruiz Alonzo

Producción

Erick Roberto Vaides Morales
Leonel Enrique Dubón Quiñonez

Diagramación

Julia Andrea Mayorga Santos

Servicios secretariales

Auri Stephany Avila Oliva

Edición

Juan Francisco Sagúí Argueta

Impresión

Serviprensa, S. A.

Banca Central es una publicación semestral, divulgativa del pensamiento institucional del Banco de Guatemala. Debido a que es una Revista de amplio criterio, también está abierta a ideas no necesariamente coincidentes con las del Banco.

Los colaboradores de la Revista son entera y exclusivamente responsables por sus opiniones y, por consiguiente, estas no reflejan la posición oficial del Banco, a menos que ello se haga constar expresamente.

Es libre la reproducción de los artículos, gráficas y cifras que figuren en la Revista, siempre y cuando se mencione la fuente.

Toda correspondencia deberá dirigirse a: Revista Banca Central, Banco de Guatemala, 7ª. avenida, 22-01, zona 1. Código Postal No. 01001.

ÍNDICE

Presentación 3

Evaluación del Esquema de Metas Explícitas de Inflación (EMEI) en Guatemala 5

Juan Carlos Castañeda Fuentes
Carlos Eduardo Castillo Maldonado
D. N. Galindo González
Mariano José Gutiérrez Morales
Edson Roger Ortiz Cardona

Pronóstico del tipo de cambio utilizando redes neuronales convolucionales 25

David José Gabriel Maselli

Estimación de pobreza a nivel municipal en Guatemala mediante la utilización de “machine learning”* 49

Walter Figueroa
Mark Peñate
Paolo Marsicovetere

Estimación del efecto diploma en Guatemala Años 2002 y 2018 65

Guillermo Díaz Castellanos

Secciones permanentes

Junta Monetaria 79

Autoridades y funcionarios superiores del Banco de Guatemala 80

Red nacional de Bibliotecas del Banco de Guatemala 81

PRESENTACIÓN

La revista Banca Central incluye en su edición enero-junio 2021 trabajos investigativos de profesionales de las ciencias económicas egresados de la Universidad de San Carlos, Universidad Rafael Landívar y de la Universidad del Valle, todas de Guatemala.

El primer aporte tiene por título “Evaluación del Esquema de Metas Explícitas de Inflación (EMEI) en Guatemala” de los autores **Juan Carlos Castañeda Fuentes, Carlos Eduardo Castillo Maldonado, Douglas Napoleón Galindo Gonzáles, Mariano José Gutiérrez Morales y Edson Roger Ortiz Cardona**, quienes pretenden evaluar la efectividad del EMEI en nuestro país y para ello analizan el impacto de dicha herramienta en las principales variables macroeconómicas de Guatemala como la persistencia inflacionaria, la toma de decisiones de tasa de interés por parte de la autoridad monetaria y en la reacción de la economía ante choques de política monetaria. El período de análisis que abordan es desde 1991 hasta 2017, donde 1991-2004 es el período previo a la implementación del esquema y 2005-2017 es el período donde el EMEI ha funcionado. Los autores sostienen que los resultados empíricos muestran evidencia de una reducción significativa en el valor medio y en la persistencia de la inflación a partir de la introducción del EMEI y observan cambios en la respuesta de la inflación ante choques de política monetaria, dando un claro indicio de la efectividad del EMEI en el corto y mediano plazo.

David José Gabriel Maselli presenta la investigación “Pronóstico del tipo de cambio utilizando redes neuronales convolucionales” en la que se planteó como objetivo evaluar si las redes neuronales convolucionales, en particular la red neuronal WaveNet, son capaces de superar el poder predictivo del modelo de caminata aleatoria. El autor utilizó datos diarios entre 2013 y 2016; y datos

mensuales entre 2013 y 2019. Realizó pruebas tanto con la red WaveNet no condicional univariada, como la condicional multivariada; comparando los resultados con los de los modelos de caminata aleatoria, modelo ARIMA y modelo de corrección de error. Las medidas para evaluar el poder predictivo de cada modelo fueron, según Gabriel, el promedio de errores cuadráticos, el promedio de errores absolutos, el promedio de errores porcentuales absolutos, la precisión direccional y el estadístico de Pesaran y Timmermann. Para los datos diarios, con el modelo WaveNet no condicional, el autor obtuvo el mejor ajuste tanto adentro como afuera de la muestra. Sostiene el autor que a pesar de que no se cuenta con una prueba de hipótesis para demostrar que los pronósticos hechos por las redes neuronales son estadísticamente diferentes, la prueba de Pesaran y Timmermann revela que el modelo WaveNet contiene información de la dirección del cambio para los datos diarios, a diferencia del modelo de caminata aleatoria.

La “Estimación de pobreza a nivel municipal en Guatemala mediante la utilización de *machine learning*” es el trabajo investigativo de **Walter Figueroa, Mark Peñate y Paolo Marsicovetere**, quienes afirman que, en países como Guatemala, la medición de la pobreza es una práctica poco común y no tan frecuente, señalando que el país es el único en Latinoamérica donde la pobreza se mide aun quinquenalmente. Destacan que la última medición se efectuó en 2014, mediante la Encuesta de Condiciones de Vida (Encovi), mientras que la última medición de pobreza en el ámbito municipal se realizó en 2002. En este sentido, sostienen, debido a los altos índices de pobreza del país, la política pública requiere de datos actualizados, precisos y desagregados territorialmente. Agregan que el avance de métodos computacionales, como el aprendizaje de *machine learning*, ha permitido disponer de herramientas potentes,



algunas de las cuales pueden ser aplicables a la medición de pobreza. La aplicación de estos métodos, agregan, contribuye a reducir los altos costos que podría implicar una eventual medición de pobreza municipal. En virtud de ello, su estudio realiza una medición de la pobreza municipal, mediante el método de algoritmos supervisados *random forest*, los cuales han sido entrenados con información de la Encovi 2014 para poder predecir la pobreza mediante los resultados del XII Censo Nacional de Población y VII de Vivienda.

Guillermo Díaz Castellanos desarrolla la investigación “Estimación del efecto diploma en Guatemala. Años 2002 y 2018” en la que aporta evidencia empírica sobre la existencia del efecto *sheepskin* o diploma en el mercado laboral guatemalteco, con el objetivo de conocer cuánto agrega en el retorno de la educación la obtención de un diploma académico en los niveles secundario, universitario y de posgrado. El autor tomó como base datos de Encuestas de Empleo e Ingresos de los años 2002 y 2018, para realizar una estimación de la ecuación de Mincer, en su forma *spline* discontinua. Elaboró la estimación por medio de los métodos de mínimos cuadrados ordinarios y de dos etapas de Heckman para control del sesgo de selección. Los resultados le confirmaron la existencia del efecto diploma en los tres niveles educativos investigados. Díaz también aporta evidencia de una devaluación de los títulos académicos en 2018 comparado con 2002.

Evaluación del Esquema de Metas Explícitas de Inflación (EMEI) en Guatemala¹

*J. C. Castañeda Fuentes
C. E. Castillo Maldonado
D. N. Galindo González
M. J. Gutiérrez Morales
E. R. Ortiz Cardona*

El presente documento pretende evaluar la efectividad del Esquema de Metas Explícitas de Inflación (EMEI) en Guatemala, el cual fue establecido como marco de política monetaria por el banco central en 2005. Para tal efecto se analiza el impacto del EMEI en las principales variables macroeconómicas del país, en la persistencia inflacionaria, en la toma de decisiones de tasa de interés por parte de la autoridad monetaria, y en la reacción de la economía ante choques de política monetaria. El período de análisis comprende desde 1991 hasta 2017, donde 1991-2004 es el período previo a la implementación del esquema y 2005-2017 es el período donde el EMEI ha funcionado.

Los resultados empíricos muestran evidencia de una reducción significativa en el valor medio y en la persistencia de la inflación a partir de la introducción del EMEI. Asimismo, se observan cambios en la respuesta de la inflación ante choques de política monetaria, dando un claro indicio de la efectividad del régimen de metas explícitas de inflación, en el corto y mediano plazo.

¹ Los autores laboran en el Departamento de Investigaciones Económicas (DIE) del Banco de Guatemala. Las opiniones emitidas en el documento no necesariamente representan las de las autoridades del Banco de Guatemala y son la sola responsabilidad de los autores, junio 2021.



Introducción

El Esquema de Metas Explícitas de Inflación (EMEI) es una estrategia de política monetaria que consiste en el anuncio de una meta para la tasa de inflación interna en el mediano plazo y el compromiso público de la autoridad monetaria por cumplir con su objetivo. Este esquema fue implementado por primera vez en Nueva Zelanda en 1990 y gradualmente ha sido adoptado por bancos centrales en economías desarrolladas, emergentes y en desarrollo. Según el Fondo Monetario Internacional (FMI), con información a 2017, un total de 40 países han adoptado este esquema monetario (FMI: ARAER, 2017). El Banco de Guatemala transitó gradualmente hacia un EMEI por un período de cinco años (2000-2004), en el cual se llevaron a cabo reformas legislativas que contribuyeron a fortalecer la flexibilidad cambiaria y a establecer un objetivo inflacionario. Adicionalmente, se llevaron a cabo cambios operativos que permitieron establecer el instrumento de política monetaria, definir la meta de inflación, así como llevar a cabo una reestructuración organizacional para la implementación eficiente del nuevo marco de política monetaria. Oficialmente Guatemala adoptó el EMEI en 2005 y se convirtió, en ese entonces, en el sexto país latinoamericano en adoptar este esquema.²

Ahora bien, luego de trece años de vigencia, y de la experiencia de navegar por diversos episodios del ciclo económico, es necesario detenerse y evaluar la efectividad de la política monetaria bajo este sistema. En este sentido, el presente documento pretende llevar a cabo una evaluación objetiva de la efectividad del EMEI en Guatemala, en línea con los estudios efectuados por Arestis, Ferrari y de Paula (2011), Ramos-Francia y Torres (2005), Landerretche, Morandé y Schmidt-Hebbel (1999), Cabrera, Bejarano y Savino (2011) y Urrutia, Hofstetter y Hamann (2014), para los casos de Brasil, México, Chile, Perú y Colombia, respectivamente. Para tal efecto se llevan a cabo diversos estudios empíricos. En primer lugar, se presenta un análisis estadístico comparativo con datos anuales para los períodos 1991-2004 (previo a EMEI) y 2005-2017 (con EMEI), en el cual se compara la media y la desviación estándar de las principales variables macroeconómicas cuyo comportamiento se espera que cambie como consecuencia del nuevo esquema de política monetaria.³ En segundo lugar se lleva a cabo una estimación, por medio de ventanas móviles, de la

persistencia inflacionaria, entendida esta como el coeficiente del componente rezagado de la inflación total en la Curva de Phillips. Esta estimación se basa en información trimestral para el período 1995-2017 y trata de identificar si existe un cambio en la persistencia inflacionaria en el período posterior a 2005. En tercer lugar, se analiza la reacción de política monetaria a desvíos de la inflación respecto de su meta por medio de Reglas de Taylor alternativas que tratan de identificar si las decisiones de política monetaria del banco central obedecen a un comportamiento de largo plazo prospectivo luego de la implementación del esquema. Finalmente, se lleva a cabo un análisis econométrico por medio de un modelo VAR estimado con información trimestral para dos períodos de tiempo: 1995-2004 (previo a EMEI) y 2005-2017 (con EMEI), en el cual se trata de analizar el efecto de un choque monetario en la inflación y en el crecimiento económico interno.

Los resultados empíricos permiten concluir que: i) existe evidencia de una reducción significativa en el valor medio y en la persistencia de la inflación a partir de la introducción del EMEI; ii) existe un efecto significativo y negativo de la inflación ante un ajuste positivo en la tasa de interés de política monetaria para el período 2005-2017, no así para el período previo a la implementación del EMEI; y iii) las decisiones de política monetaria se basan en expectativas de inflación más prospectivas, en relación con el período previo a la implementación del esquema en referencia. Los resultados anteriores nos permiten afirmar que la introducción del EMEI en 2005 ha producido cambios relevantes en el comportamiento de las principales variables macroeconómicas del país y que las medidas implementadas por el banco central han permitido el logro de los objetivos de corto y mediano plazo de la autoridad monetaria.

El resto del presente documento se encuentra organizado de la siguiente manera. En la Sección II se describe la evolución histórica del proceso de implementación del EMEI en Guatemala; posteriormente, en la Sección III se presenta la metodología empleada para evaluar la efectividad del esquema; en la Sección IV se presentan los resultados del análisis empírico y en la Sección V se presentan las conclusiones de este estudio.

² Le antecedieron Brasil, Chile y Colombia en 1999, México en 2001 y Perú en 2002 (Hammond, 2012).

³ La inflación total, las expectativas de inflación, el crecimiento económico y el tipo de cambio nominal.

1 Implementación del Esquema de Metas Explícitas de Inflación (EMEI) en Guatemala

En este apartado se realiza una descripción del esquema monetario empleado por el Banco de Guatemala previo al EMEI, se indican los cambios operativos y organizacionales efectuados durante el período de transición entre ambos esquemas monetarios y se analizan los principales elementos del nuevo esquema y sus perspectivas a futuro.

A. Antecedentes

Durante la década de los 90, previo a la adopción del EMEI, la economía guatemalteca estaba regida por un esquema de política monetaria denominado Metas Monetarias (MM), el cual se basaba en el establecimiento de metas de crecimiento anual para la emisión monetaria y para agregados monetarios de más amplio espectro (i. e. el medio circulante y los medios de pago). Las metas de crecimiento para los agregados monetarios se calculaban con base en los siguientes factores: i) el crecimiento anual esperado de la economía guatemalteca; ii) la tasa de crecimiento esperada de la velocidad de circulación del agregado monetario respectivo; y iii) una meta anual de inflación.^{4,5} Se consideraba que el agregado monetario más relevante, cuya trayectoria era necesario controlar, era la emisión monetaria debido a la estrecha relación que esta variable guardaba con la inflación.⁶

Desde mediados de la década de los años 80 se empezó a gestar una reforma financiera que conllevó al establecimiento de un sistema de tipo de cambio flexible y eliminó el control que la autoridad monetaria ejercía

sobre las tasas de interés activas y pasivas del sistema bancario. Estas reformas aumentaron la influencia de factores exógenos en la economía guatemalteca y gradualmente propiciaron que la relación entre la emisión monetaria y la inflación, la cual denotaba un coeficiente de correlación superior a 0.80 en las dos décadas previas, se redujera durante la década de los 90. Es decir, los agregados monetarios perdieron su contenido informativo en relación con la inflación (no así con respecto de la actividad económica interna).

Otros factores que contribuyeron a la reducción de la correlación entre ambas variables fueron las innovaciones financieras que resultaron de la mayor flexibilidad de las tasas de interés (mayor uso de tarjetas de crédito y de débito), la apertura de la cuenta de capitales y la reforma constitucional de 1994, la cual, entre otros cambios, prohibió al banco central financiar el déficit fiscal.⁷ Cabe indicar que esta reforma constitucional ha sido fundamental para moderar el crecimiento de la oferta monetaria y, por consiguiente, de la inflación interna.

B. Período de transición: 2000-2004

Durante el período 2000-2004 se implementaron una serie de medidas macroeconómicas y legislativas que eran condiciones necesarias para establecer un EMEI en Guatemala. En particular, se llevaron a cabo reformas a la legislación financiera del país y se empezó a dar seguimiento a un conjunto específico de variables macroeconómicas como guía para la toma de decisiones de política monetaria.

Las reformas legislativas iniciaron con la emisión de la Ley de Libre Negociación de Divisas, la cual entró en vigencia en mayo de 2001. Esta ley permitió la libre tenencia y utilización de moneda extranjera para efectos de transacciones comerciales y financieras dentro y fuera del territorio nacional; asimismo autorizó el establecimiento de cuentas bancarias (monetarias y de ahorro) en otras monedas y formalizó la existencia de

⁴ El esquema de Metas Monetarias se basaba en la aplicación práctica de la Teoría Cuantitativa del Dinero (Fisher, 1913), cuya formulación matemática en tasas de crecimiento puede establecerse de la siguiente manera: $(1+m)(1+v) = (1+q)(1+p)$, donde m: tasa de crecimiento anual del agregado monetario; v: tasa de crecimiento anual de la velocidad de circulación del agregado monetario en referencia; q: tasa de crecimiento económico; y, p: tasa de inflación.

⁵ El Banco de Guatemala empezó a establecer metas para la inflación interanual desde 1991. En algunos años estas metas fueron establecidas en términos del valor puntual de la inflación interanual objetivo, mientras que en otros años fueron establecidos como un rango de valores objetivo para la inflación interanual. No obstante, en ambos casos, las metas eran solamente indicativas, ya que no existía un compromiso institucional por parte del banco central para cumplir con las mismas (como sí es el caso bajo un EMEI).

⁶ La emisión monetaria equivale al total de monedas y billetes en circulación más la caja de los bancos.

⁷ La reforma constitucional que prohíbe al banco central financiar al gobierno tuvo su origen en los elevados niveles de inflación que se produjeron en 1989 y 1990 (20.2% y 60.0%, respectivamente) derivada de los altos niveles de déficit fiscal y de la depreciación cambiaria que tuvo lugar como consecuencia.

un mercado institucional de divisas conformado por el Banco de Guatemala e instituciones del sector financiero. La ley en referencia facilitó el intercambio entre monedas, contribuyó a minimizar los costos de transacción de las operaciones cambiarias y aumentó el grado de transparencia de las operaciones financieras con moneda extranjera entre los diferentes agentes económicos internos. En junio de 2002 entraron en vigencia reformas a la legislación financiera del país, particularmente, a la Ley Orgánica del Banco de Guatemala, a la Ley Monetaria, a la Ley de Bancos y Grupos Financieros y a la Ley de Supervisión Financiera. Las reformas efectuadas a la Ley Orgánica del Banco de Guatemala fueron relevantes para la constitución de un EMEI en el país. En primer lugar, se define con claridad el objetivo fundamental del banco central: la consecución de estabilidad en el nivel general de precios. En segundo lugar, se otorga al banco central autonomía operativa en la selección y gestión de los instrumentos que considere más apropiados para el logro de su objetivo fundamental. Finalmente, se propicia un

mayor grado de transparencia de la política monetaria y se establece un mecanismo de rendición de cuentas sobre el actuar del banco central.

Como medidas de transparencia, a partir de junio de 2002, se empezó a publicar un resumen de los argumentos que Junta Monetaria tomaba en consideración para la toma de decisiones de política monetaria (con dos meses de rezago), así como las evaluaciones macroeconómicas que se realizaban con periodicidad trimestral. Asimismo, se amplió la base de datos disponible para todo el público, por medio de internet, que contiene información estadística de las principales variables e indicadores macroeconómicos del país. Para efectos de rendición de cuentas, la Ley establece que el Presidente del Banco de Guatemala debe de presentar dos veces por año, ante el Congreso de la República, un informe de las acciones efectuadas para el logro de su objetivo fundamental. En este sentido, también se publican los informes en referencia.

Variable indicativa	Descripción y método de análisis
Pronósticos y Expectativas de Inflación (3 variables)	Los pronósticos de inflación total y subyacente, así como las expectativas de inflación, se comparan con la meta de inflación establecida. ⁸
Tasa de interés Parámetro (1 variable)	Esta tasa de interés calculada por medio de una Regla de Taylor que se compara con la tasa de interés promedio de las operaciones de reporto del mercado interbancario.
Pronósticos de Agregados Monetarios (3 variables)	Los pronósticos de Emisión Monetaria, de los Medios de Pago (M2) y del Crédito Bancario al Sector Privado se comparan con los valores observados de estas variables.
Índice de Condiciones Monetarias, ICM (1 variable)	Este indicador es una medición de la tasa de interés interna que resulta de la paridad descubierta de tasas de interés, tomando en consideración una tasa de interés externa y el comportamiento observado y esperado del tipo de cambio nominal. Este indicador se compara con la tasa de interés promedio de las operaciones de reporto del mercado interbancario.

Fuente: elaboración de los autores.

Cuadro 1. Variables indicativas de política monetaria

Para efectos de análisis macroeconómico y, con el objeto de guiar las decisiones de política monetaria, se empezó a dar seguimiento a un grupo de siete indicadores macroeconómicos.⁹ Este grupo de indicadores se denominó “variables indicativas” y estaba conformado por las variables que se describen en el cuadro 1 conjuntamente con el método empleado para extraer información relevante de cada indicador. Es importante mencionar que durante este periodo, el comportamiento de la Emisión Monetaria, particularmente los desvíos de esta variable respecto de lo programado, era la principal variable indicativa de política monetaria y las acciones del banco central se orientaban a restringir o expandir

la oferta monetaria por medio de operaciones de mercado abierto. La tasa de interés en este tipo de operaciones se determinaba de manera endógena, por lo que se registraba una volatilidad significativa en esta variable (ver figura 1). El banco central continuó operando de esta manera por unos años más, pero mantuvo la visión firme de transitar hacia el nuevo esquema de política monetaria en el corto plazo. Fue hasta finales de 2004, con la aprobación de la Política Monetaria, Cambiaria y Crediticia para 2005, que la Junta Monetaria del Banco de Guatemala estableció oficialmente un Esquema de Metas Explícitas de Inflación en el país.

⁸ La inflación total se refiere a las variaciones interanuales del Índice de Precios al Consumidor (IPC), mientras que la inflación subyacente es aquella inflación que resulta de depurar el IPC por sus componentes más volátiles tales como los precios de los vegetales y legumbres, así como los precios de los combustibles. Por su parte, las expectativas de inflación son aquellos pronósticos de inflación provenientes de la encuesta mensual efectuada a un panel de analistas privados.

⁹ Actualmente se adiciona una variable adicional: el pronóstico de tasa de interés de los modelos macroeconómicos de pronóstico. Asimismo, los pronósticos de los agregados monetarios y el ICM ya no forman parte de las variables indicativas.

C. El nuevo esquema monetario: 2005-2018

En este apartado se detallan los cambios en materia institucional, jurídica, técnica y operativa que fueron relevantes en la implementación del EMEI en Guatemala.

1. Marco jurídico e institucional

En 2005, con el propósito de aumentar la eficiencia de la política monetaria se introdujeron modificaciones graduales con el objeto de realizar las operaciones de estabilización monetaria en condiciones de mercado. Dentro de estas reformas se pueden mencionar la fijación de una sola tasa de interés líder para las operaciones de estabilización monetaria equivalente a la tasa de interés de referencia para los Certificados de Depósitos a 7 días plazo (CD-7).¹⁰ De igual forma se eliminó el establecimiento de cupos en colocaciones a dicho plazo y se redujo el número de licitaciones y el monto de cupos para las captaciones de CDs a otros plazos.

En los años siguientes, el EMEI evolucionó tomando como referencia la experiencia adquirida por bancos centrales que adoptaron este esquema antes que Guatemala. Los principales avances se llevaron a cabo en aspectos relacionados con el mercado de dinero y el mercado cambiario. En junio de 2011, se hizo un cambio más profundo con el propósito de contribuir a la modernización, desarrollo y profundización del mercado

de valores y de elevar la efectividad del mecanismo de transmisión de la política monetaria, estableciéndose como tasa de interés líder de política monetaria la tasa de interés de referencia de los depósitos a plazo de un día (*overnight*), CDP-1 en sustitución de la tasa de interés en certificados de depósito a siete días, CDP-7. La tasa de interés al plazo de un día ha permitido un manejo más eficiente de la liquidez por parte de los bancos del sistema, debido a que estos tienen la certeza de que el banco central está dispuesto diariamente a procurar que la liquidez bancaria sea la apropiada, al poner a su disposición facilidades permanentes, tanto de inyección como de neutralización de liquidez.

En ese contexto, como resultado del proceso de consolidación del EMEI, la Junta Monetaria determinó una meta de inflación de mediano plazo, a partir de 2013, de 4.0% +/- 1 punto porcentual, la cual persigue la materialización del proceso de convergencia de la inflación a dicha meta, mediante un anclaje efectivo de las expectativas de inflación de los agentes económicos.

2. Instrumentos de política monetaria

Los tres principales instrumentos de política monetaria con que cuenta el Banco de Guatemala son: la tasa de interés líder, las operaciones de estabilización monetaria y la tasa de encaje bancario. A continuación se presenta una breve descripción de los mismos.

i. La tasa de interés líder de política monetaria.

Como se indicó, la tasa líder equivale a la tasa de interés de referencia para los certificados de depósito a plazo con vencimiento a un día (*overnight*), CD-1. El valor de esta tasa lo determina la Junta Monetaria del Banco de Guatemala en fechas predeterminadas, usualmente ocho veces al año, en función de las condiciones macroeconómicas internas y externas. Es importante mencionar que el valor de la tasa de interés líder se utiliza como parámetro para establecer el valor de las tasas de interés de referencia para la colocación de recursos en certificados de depósito, CDs, a plazos mayores.

ii. **Operaciones de estabilización monetaria.** Este es el nombre con que se conoce a las operaciones de mercado abierto que lleva a cabo el Banco de Guatemala, las cuales consisten en operaciones de neutralización o de inyección de liquidez mediante subastas diarias de certificados de depósito (CD) a distintos plazos. Usualmente estos certificados se emiten a una fecha de vencimiento de corto plazo que no supera los dos años.

iii. **Encaje bancario.** El encaje bancario es la proporción de determinados pasivos bancarios (denominados obligaciones encajables) que los bancos del sistema deben de mantener depositados en el Banco de Guatemala. Actualmente la proporción o tasa de encaje bancario se encuentra establecida en 14.6% de las obligaciones encajables tanto en moneda nacional, como en moneda extranjera. Este valor ha permanecido estable desde la década de 1990.

¹⁰ La tasa de interés de referencia es la tasa máxima de corte en las subastas de operaciones de estabilización monetaria que lleva a cabo el Banco de Guatemala. Por ejemplo, asumamos que la Junta Monetaria del Banco de Guatemala establece como tasa de referencia para los CD-7 un valor de 3%. En un día particular, diversos bancos del sistema le indicarán al banco central que desean colocar un monto de recursos en CD-7 (y otros montos en CDs a mayor plazo), para lo cual demandan que dicho monto sea colocado a una tasa X (este valor puede ser mayor o menor que la tasa de referencia de 3%). Por lo tanto, el banco central solamente aceptará como CD-7 las posturas de aquellos bancos cuyas tasas de interés X sean iguales o inferiores a 3%. Si bien, el monto que los bancos pueden colocar en CD-7 es ilimitado, el Banco de Guatemala establece un cupo máximo para CDs a plazos mayores. Por lo tanto, en estos plazos, los bancos tienen que competir entre ellos, ofreciendo colocar sus recursos a tasas de interés más atractivas (más bajas) que las tasas de referencia para cada plazo (usualmente las tasas de colocaciones históricas a dichos plazos).

3. El tipo de cambio y la política cambiaria

Desde su establecimiento en 1924, el sistema cambiario de Guatemala consistía de un sistema de tipo de cambio fijo, donde el quetzal, la moneda nacional, tenía un valor de paridad con el dólar norteamericano (Q1 = US\$1). Durante los primeros cincuenta años de su establecimiento, este sistema funcionó sin mayor inconveniente. Sin embargo, el colapso del sistema de Bretton Woods a principios de la década de 1970, conjuntamente con los choques petroleros que se produjeron en 1973 y 1979 afectaron adversamente la demanda por bienes domésticos, lo que redujo los ingresos de divisas por exportaciones, al mismo tiempo que se incrementaba la demanda de divisas para pagar por las importaciones y para cubrir el servicio de la deuda externa. Estos factores produjeron una erosión de las reservas monetarias internacionales, lo que condujo a una serie de devaluaciones de la moneda a partir de 1986. No obstante, la falta de recursos para continuar sosteniendo la convertibilidad de la moneda propició que el banco central decidiera dejar flotar el quetzal, de manera administrada, a partir de 1989. Para finales de 1990, el valor del quetzal se había situado en alrededor de Q5 por dólar estadounidense. Durante los años siguientes, el banco central estableció diversos mecanismos para moderar la fluctuación cambiaria, principalmente, intervenciones directas y discrecionales en el mercado cambiario por medio de subastas de compra y venta de divisas. En marzo de 1996 se estableció el Sistema Electrónico de Negociación de Divisas (SINEDI) el cual dotó de mayor transparencia en las operaciones cambiarias y redujo la incertidumbre de los participantes en relación a los montos y a los tipos de cambio establecidos en cada transacción (Castillo, 2010).

La emisión de la Ley de Libre Negociación de Divisas, aunada a las reformas a la Ley Orgánica del Banco de Guatemala y a la Ley de Bancos y Grupos Financieros, en los años 2001 y 2002, respectivamente, trajo consigo una consolidación de la libre movilidad de capitales. El marco legal que regula la política cambiaria del banco central se materializó en 2005, mediante el establecimiento de una regla de participación cambiaria, cuyo objetivo primordial fue moderar la marcada tendencia hacia la apreciación que se venía registrando desde

2004. Dicha regla establecía tres niveles de intervención, denominados umbrales, los cuales estaban delimitados por tipos de cambio predeterminados. El Banco de Guatemala modificó la regla de participación en el mercado cambiario en enero de 2007, convirtiéndola en una regla simétrica, de tal forma que el banco central podía intervenir en el mercado cambiario comprando o vendiendo divisas (no solo comprando dólares). Adicionalmente, se trató de proporcionar una mayor flexibilidad al tipo de cambio. En esta segunda versión de la regla de participación, el objetivo explícito del banco central era moderar la volatilidad del tipo de cambio sin afectar su tendencia. El criterio para convocar a subastas para la compra (venta) de divisas era función del tipo de cambio promedio ponderado diario de las operaciones de compra (venta) de divisas del sistema bancario con el público en el SINEDI: cuando este tipo de cambio era igual o menor (mayor) a la media móvil de 5 días hábiles del tipo de cambio de referencia menos (más) cierto margen de fluctuación, el cual gradualmente fue ampliándose para permitir una mayor flexibilidad cambiaria. Asimismo, el número de subastas diarias y los montos máximos permitidos en cada subasta fueron incrementándose con los años, en función del crecimiento anual de las operaciones promedio diarias en el mercado cambiario.

A partir de 2014 el Banco de Guatemala empezó a darle seguimiento a las operaciones del mercado cambiario en "tiempo real". Por consiguiente, la regla de participación en el mercado cambiario fue modificada de tal forma que el banco central pudiera intervenir si alguna operación (de compra o de venta de divisas) sobrepasara el umbral del promedio de cinco días previos más un margen de fluctuación. De igual manera que la regla anterior, este margen de fluctuación se ha incrementado gradualmente para permitir una mayor flexibilidad al tipo de cambio. Actualmente la regla de intervención permite un número máximo de 5 subastas diarias, cada una por un monto máximo de US\$8.0 millones. Asimismo, la regla permite la intervención en montos discrecionales por volatilidad inusual, pero este tipo de participación debe ser debidamente fundamentado ante la Junta Monetaria.

4. Mecanismo de transmisión monetaria

El mecanismo de transmisión monetaria es el conjunto de canales por medio de los cuales las decisiones de política monetaria se transmiten al sector real, particularmente a la actividad económica y a los precios internos. Los diversos canales de transmisión no son independientes entre sí, sino más bien actúan de manera simultánea y complementaria; sin embargo, es necesario distinguirlos para poder analizarlos adecuadamente. Para el caso de Guatemala se considera que los tres principales canales de transmisión monetaria son los

siguientes: i) el Canal de Demanda Agregada o de Tasa de Interés; ii) el Canal del Tipo de Cambio; y iii) el Canal de Expectativas. Adicionalmente, las variables internas se encuentran condicionadas al comportamiento de un conjunto de variables externas, particularmente por las tasas de interés internacionales, por la inflación externa y por el crecimiento económico externo. Para establecer de manera cuantitativa la interrelación entre las principales variables macroeconómicas que pertenecen a los canales de transmisión mencionados, el Departamento

de Investigaciones Económicas del Banco de Guatemala desarrolló un modelo macroeconómico denominado Modelo Macroeconómico Semiestructural (MMS). Según este modelo, las variables que pertenecen al canal de transmisión de demanda agregada son: la tasa de interés de política monetaria, la emisión monetaria, el medio circulante, los medios de pago, las tasas de interés nominal y real de mercado, tanto activa como pasiva, el crédito bancario al sector privado, el gasto privado (consumo e inversión del sector privado netos de importaciones), el gasto público, los ingresos tributarios, la deuda pública (interna, externa y total), las exportaciones, la actividad económica interna y la inflación. La introducción de los agregados monetarios dentro del mecanismo de transmisión de la política monetaria permite modelar el Efecto Liquidez en la economía guatemalteca. Este efecto se encuentra ampliamente documentado en la literatura económica (Christiano, Eichenbaum y Evans, 1996; Leeper, Sims y Zha, 1996; y Bernanke y Mihov, 1998, entre otros) y también existe evidencia del mismo para Guatemala (Castillo, 2006). En efecto, cambios en la tasa de interés de política monetaria producen un efecto liquidez que se manifiesta por una reducción en la emisión monetaria, la cual se refleja en una disminución en el medio circulante (M1), en los medios de pago (M2), así como la oferta de fondos disponibles para el crédito al sector privado por parte de los bancos del sistema. Tanto los cambios en los medios de pago como en el crédito bancario al sector privado afectan las decisiones de consumo e inversión de los hogares y de las empresas, los que a su vez tienen un efecto en la actividad económica y en la inflación.

La interrelación entre estas variables se fundamenta en la teoría económica y en evidencia empírica. En efecto, de conformidad con la literatura económica, existe una relación positiva y significativa entre el desarrollo del sistema financiero y el crecimiento económico (Levine, Loayza y Beck, 2000; Bigden y Mizen, 1999; Hauser y Bridgen, 2002; Thomas, 1996, entre otros). Dicha relación también es identificada para el caso guatemalteco (Castillo, 2012). Adicionalmente, los cambios en la actividad económica también afectan la demanda de crédito bancario y los ingresos tributarios, lo cual refuerza los efectos producidos por el consumo y la inversión del sector privado en el crecimiento económico de corto plazo. Es importante mencionar que el gasto de gobierno depende de los ingresos tributarios y de las tasas de variación de la deuda pública interna y externa; estas dependen a su vez de la recaudación tributaria. En este sentido, se producen cambios en el gasto de gobierno cuando se presenta un aumento en sus principales fuentes de financiamiento. Cabe señalar que los cambios en la deuda interna afectan la oferta de crédito bancario al sector privado (efecto desplazamiento o crowding out). Por su parte, las exportaciones totales se ven afectadas principalmente por factores externos, tales como el tipo de cambio real y la demanda agregada externa

Para una economía pequeña y abierta el canal del tipo de cambio juega un rol importante dentro del mecanismo de transmisión de la política monetaria. Según el MMS, las variables que pertenecen a este canal de transmisión son las siguientes: la tasa de interés de política monetaria, el tipo de cambio nominal, el tipo de cambio real, las expectativas cambiarias, la inflación externa, la actividad económica y la inflación. En este sentido, los cambios en la tasa de interés de política monetaria activan el canal del tipo de cambio de dos maneras distintas. En primer lugar, se modifican las expectativas de depreciación, lo cual afecta directamente a la inflación. En segundo lugar, la variación en los precios internos afecta al tipo de cambio real y, por ende, a la actividad económica y a los precios internos. La literatura económica enfatiza la importancia de las expectativas de inflación (tanto adaptativas como racionales) como un factor fundamental dentro del mecanismo de transmisión monetaria (Lucas, 1972; Rogoff, 1985, Barro y Gordon, 1983, Kydland y Prescott, 1977; Ball y Croushore, 1995; Bernanke y Mishkin, 1997; y Woodford, 2007, entre otros). En este sentido, la efectividad de la transmisión de la política monetaria por medio del canal de expectativas es función de la credibilidad de los agentes económicos en las acciones del banco central. Por lo tanto, es importante mencionar que el canal de expectativas se divide, a su vez, en dos componentes: i) el Canal de Expectativas de Inflación; y ii) el Canal de Expectativas Cambiarias. Según el MMS, las variables que conforman el canal de expectativas de inflación son: la tasa de interés de política monetaria, las expectativas de inflación y la inflación observada. Este mecanismo asume que las expectativas de inflación de los agentes económicos reaccionan de forma inmediata ante cambios en la tasa de interés de política monetaria y por ello tienen un efecto directo sobre la inflación.

Por su parte, las variables que conforman el canal de expectativas cambiarias son: la tasa de interés de política monetaria, las expectativas cambiarias, el tipo de cambio nominal, el tipo de cambio real, la actividad económica interna y la inflación. El mecanismo de transmisión monetaria en Guatemala también toma en consideración los efectos generados por fluctuaciones en siete variables externas. La primera de ellas es la tasa de crecimiento económico de los Estados Unidos de América. Cabe indicar que se toma como referencia la tasa de crecimiento de este país, por ser el principal socio comercial de Guatemala. En efecto, el ciclo económico norteamericano tiene un efecto significativo en la demanda externa por los productos guatemaltecos de exportación, así como en los flujos de moneda extranjera (dólares estadounidenses) que ingresan al país por concepto de líneas de crédito del exterior, flujos que se convierten en capital de inversión, así como por concepto de remesas familiares. Por consiguiente, fluctuaciones en la actividad económica de dicho país también tienen un impacto en el tipo de cambio nominal. Asimismo, el

crecimiento económico de los Estados Unidos de América influye en la inflación externa, la cual se transmite a la inflación doméstica por medio de la inflación importada. La segunda variable externa es la tasa de interés internacional, la cual consiste en la tasa de interés Libor con madurez constante a un año plazo. De conformidad con la hipótesis de la paridad descubierta de tasas de interés, el diferencial de esta tasa respecto de la tasa de interés interna a un plazo similar de vencimiento (en este caso, la tasa de interés pasiva nominal de mercado) tiene también un efecto en las expectativas cambiarias y, por consiguiente, en el tipo de cambio nominal. La tercera variable externa es la prima de riesgo país, la cual fluctúa en función de la percepción de los agentes económicos externos, sobre aspectos políticos, económicos y sociales internos que pueden poner en riesgo el cumplimiento de las obligaciones crediticias del país.

Esta variable afecta directamente las expectativas de depreciación cambiaria. La cuarta variable externa es la tasa de inflación de los Estados Unidos de América, la cual tiene un efecto directo en los precios internos, debido a que la mayor proporción de bienes importados proviene de dicho país. Las siguientes variables externas corresponden a las tasas de variación interanual de los precios internacionales del petróleo (WTI) y de los precios internacionales de los alimentos (de conformidad con el Índice de la FAO). Estas dos variables son exógenas al modelo. Cabe indicar que dichas variables se combinan para conformar los precios de los bienes importados, los cuales tienen un efecto directo en la inflación doméstica. La última variable externa (y exógena) corresponde a las líneas de crédito provenientes del exterior las cuales tienen un impacto directo en el crédito bancario al sector privado.

D. El camino por delante

Guatemala enfrenta diversos retos para potenciar la eficiencia del EMEI; varios de ellos están asociados a las características intrínsecas de la economía, y otros basados en mejoras en el marco legal del país. El primero de ellos es el desarrollo del mercado de valores, el cual permitiría mejorar el canal de transmisión de la política monetaria. Los efectos de los cambios en la tasa de interés se harían más sensibles en la actividad económica interna. Un segundo aspecto podría ser la evaluación de la meta de inflación acorde con la dinámica de la economía tanto en el corto como en el largo plazo. En ese sentido, es importante determinar si los cambios en la dinámica de la inflación en una economía responden a un fenómeno coyuntural o más bien a un cambio estructural.

III. Evaluación de la efectividad del EMEI en Guatemala

Una manera simple de evaluar el desempeño de un Esquema de Metas Explícitas de Inflación (EMEI) es comparar la meta de inflación con la inflación observada, tomando como referencia el momento en que se adoptó formalmente dicho régimen. Este enfoque, sin embargo, es muy incompleto ya que deja fuera del análisis muchos factores de control que, junto con la inflación, son importantes para la estabilidad macroeconómica. En la presente sección se pretende evaluar el impacto de la adopción del régimen de metas explícitas de inflación en la economía guatemalteca. Para el efecto, el análisis

se dividió en dos períodos: el primero se refiere al período previo a la adopción del régimen de metas explícitas de inflación (pre-EMEI), que se utilizó como marco de referencia para evaluar el impacto de dicho esquema, y el segundo período inicia a partir de la adopción de dicho régimen de parte del Banco de Guatemala (EMEI). Esta sección consta de dos subsecciones: en la primera se explica brevemente la metodología y datos utilizados para evaluar el EMEI, y en la segunda se presentan los resultados empíricos obtenidos.

A. Metodología y datos

El enfoque metodológico de esta evaluación, se basó en los trabajos de Agénor y Pereira-Da Silva (2013), Jiménez y Leyva (2004) y Taguchi y Kato (2010). En este sentido, se realizó un análisis macroeconómico general, así como estimaciones de curvas de Phillips, reglas de

Taylor y modelos VAR con el objetivo de analizar la existencia de cambios estructurales, desde la introducción del régimen de metas explícitas de inflación en 2005.

1. Metodología

En este apartado se presenta cada una de las metodologías utilizadas, ampliando en cada una de ellas el desarrollo formal y los resultados teóricos esperados. Inicialmente se llevó a cabo un análisis macroeconómico general. La segunda metodología se basó en el trabajo de Jiménez y Leyva (2010), con el objetivo de analizar la persistencia inflacionaria. Los apartados (iii) y (iv) se basaron en la metodología propuesta por Taguchi y Kato (2010).

i. Análisis macroeconómico. El primer enfoque para la evaluación se centró en los resultados macroeconómicos luego de la adopción del régimen de metas explícitas (EMEI), comparado con el período previo (pre-EMEI). Se pretende determinar si la adopción de dicho régimen ha contribuido a obtener reducciones significativas en la inflación promedio, en su volatilidad y en la estabilidad macroeconómica en general. En este sentido, se analizó el comportamiento de cinco variables principales: Inflación interanual, expectativas de inflación a 12 meses, crecimiento económico, tipo de cambio nominal y tasa de interés líder de política monetaria. En el caso de la inflación interanual y de las expectativas de inflación a 12 meses, se comparó el comportamiento de cada una, con la meta de inflación y con su valor medio para cada uno de los períodos analizados. Asimismo, se analizó la desviación estándar del diferencial entre la inflación observada y la meta de inflación, y entre las expectativas inflacionarias y la meta de inflación,

para cada período. El crecimiento económico se comparó con el crecimiento potencial en los dos períodos mencionados y se analizó también el comportamiento de la desviación estándar del diferencial entre el crecimiento observado y su valor potencial para cada período. Una metodología similar se utilizó para el tipo de cambio nominal y para la tasa de interés líder, comparando ambas variables con sus respectivos valores medios para los períodos pre-EMEI y EMEI. Asimismo, se analizó la desviación estándar de los diferenciales respecto de sus valores medios para cada período. En términos cuantitativos, se realizaron pruebas de hipótesis para evaluar la igualdad de los valores medios y de la desviación estándar media de cada variable, en cada período de evaluación, con el objetivo de determinar cambios estructurales significativos en las principales variables de la economía guatemalteca, luego de la adopción del Esquema de Metas Explícitas de Inflación en 2005.

ii. Persistencia inflacionaria. El esquema de metas de inflación ofrece las condiciones necesarias para la reducción de la persistencia inflacionaria, anclando las expectativas inflacionarias mediante el anuncio público de objetivos de inflación. Bajo este régimen, dichos anuncios modifican la formación de las expectativas de los agentes, quienes tienden a construir sus expectativas de una forma más prospectiva (*forward-looking*), que adaptativa (*backward-looking*). Cuantitativamente, esto debiera observarse en una reducción del componente autorregresivo en la Curva de Phillips. En este sentido, la segunda aproximación en la evaluación, se realizó tomando como referencia la metodología propuesta

por Jiménez y Leyva (2004), en la cual se analiza la estabilidad de la Curva de Phillips y sus parámetros, para evaluar la persistencia inflacionaria y el impacto de choques internos y externos en la economía guatemalteca. El comportamiento de los parámetros de la Curva de Phillips puede ser ilustrativo al momento de estudiar el impacto de la adopción del régimen de metas explícitas de inflación para la conducción de la política monetaria. Inicialmente, se llevó a cabo una estimación preliminar de la Curva de Phillips, utilizando el método de mínimos cuadrados ordinarios, la cual se puede expresar de la siguiente forma funcional:

$$(\pi_t - \bar{\pi}) = A_0(\pi_{t-1} - \bar{\pi}) + B_0(\Delta y_t - \Delta \bar{y}) + C_0(\Delta z_t - \Delta \bar{z}) + \varepsilon_t \quad (1)$$

En donde, π es la tasa de inflación interanual, Δy es la tasa de variación interanual de crecimiento económico, incluido como indicador de los shocks domésticos, y Δz es la tasa de variación interanual del tipo de cambio real, como medida de los shocks externos. ε_t , es el término de error con media cero y varianza constante. Esta Curva de Phillips contiene un rezago como variable explicativa, para tomar en cuenta el efecto *backward-looking* en la formación de precios en la economía. Las variables $\bar{\pi}, \Delta \bar{y}, \Delta \bar{z}$, corresponden a la meta de inflación, el crecimiento potencial y la depreciación real de equilibrio, respectivamente.

Una vez obtenidos los parámetros iniciales $A_0, B_0, y C_0$, se llevó a cabo un test de estabilidad. Para esto se siguió la metodología desarrollada por Kim y Nelson (1989), la cual es útil para identificar quiebres estructurales continuos en la trayectoria de los parámetros. Siendo ε el término de error obtenido de la estimación lineal y σ_ε la varianza de dicho residuo, el test de estabilidad consiste en estimar la regresión de la razón $\frac{\sigma_\varepsilon}{\sigma_\varepsilon}$, sobre cada uno de los regresores. Luego, bajo la hipótesis nula de parámetros estables, la suma de cuadrados dividida dentro de 2 tiene una distribución chi-cuadrado con k grados de libertad. La identificación de quiebres estructurales refleja cómo la estructura subyacente de los parámetros

ha estado influenciada por factores como el cambio en la credibilidad de la política monetaria, la introducción de un nuevo régimen y, en general, cambios en los procedimientos operativos de un banco central. Al obtener evidencia de inestabilidad en los parámetros, el Filtro de Kalman ofrece una metodología adecuada para analizar el comportamiento de los coeficientes a lo largo de la muestra. Este método, por medio de un modelo estado-espacio, obtiene estimadores óptimos en cada período de tiempo, usando un proceso secuencial de estimación y actualización. La estimación por medio del Filtro de Kalman se llevó a cabo utilizando el siguiente sistema de ecuaciones:

$$(\pi_t - \bar{\pi}) = A_t(\pi_{t-1} - \bar{\pi}) + B_t(\Delta y_t - \Delta \bar{y}) + C_t(\Delta z_t - \Delta \bar{z}) + \varepsilon_t \quad (2)$$

$$A_t = A_{t-1} + \varepsilon_{a,t} \quad (3)$$

$$B_t = B_{t-1} + \varepsilon_{b,t} \quad (4)$$

$$C_t = C_{t-1} + \varepsilon_{c,t} \quad (5)$$

En este sistema de ecuaciones, escrito en notación estado-espacio, la ecuación (2) es la ecuación de observación, la cual describe la dinámica entre la variable de salida (π) y las variables de estado. Las ecuaciones (3), (4) y (5) son las ecuaciones de transición y describen la dinámica seguida por cada variable de estado. Para esta evaluación se consideró que los parámetros de la Curva de Phillips, considerados como las variables de estado, siguen un proceso de caminata aleatoria.

iii. Reacción del banco central. Otra forma de evaluar el régimen de metas explícitas de inflación, es evaluar cómo evoluciona el comportamiento del banco central, una vez adoptado oficialmente dicho esquema. El factor clave en este contexto es la determinación de hasta dónde la adopción del régimen ha cambiado, de forma sustancial, el comportamiento del banco central ante fluctuaciones en la inflación, ante shocks de demanda y ante shocks externos. La

metodología utilizada se basa en la estimación de reglas de Taylor, por medio de las cuales se analizará hasta qué punto las autoridades monetarias se han vuelto más, o menos, sensibles ante desviaciones de la meta y ante shocks internos y externos. En este sentido, en base a Taguchi y Kato (2010), se estimaron dos funciones de reacción para cada período en evaluación (pre-EMEI y EMEI), utilizando el método de variables instrumentales:

$$i_t = B_{0,j} + B_{1,j}i_{t-1} + B_{2,j}(\pi_t - \bar{\pi}) + B_{3,j}(\Delta y_t - \Delta \bar{y}) + B_{4,j}\Delta s_t + \varepsilon_t \quad (6)$$

$$i_t = F_{0,j} + F_{1,j}i_{t-1} + F_{2,j}(\pi_t - \bar{\pi}) + F_{3,j}(\Delta y_t - \Delta \bar{y}) + F_{4,j}\Delta s_t + \varepsilon_t \quad (7)$$

Donde $j=1,2$

En donde las ecuaciones (6) y (7), representan las expresiones Backward y Forward Looking, y $j=1$ corresponde al período pre-EMEI, y $j=2$ corresponde al período EMEI. Una vez obtenidas las cuatro estimaciones, se evaluaron los parámetros de largo plazo correspondientes:

$$B_{2,j}^L = \frac{B_{2,j}}{(1 - B_{1,j})} \quad (8)$$

$$B_{3,j}^L = \frac{B_{3,j}}{(1 - B_{1,j})} \quad (9)$$

$$B_{4,j}^L = \frac{B_{4,j}}{(1 - B_{1,j})} \quad (10)$$

$$F_{2,j}^L = \frac{F_{2,j}}{(1 - F_{1,j})} \quad (11)$$

$$F_{3,j}^L = \frac{F_{3,j}}{(1 - F_{1,j})} \quad (12)$$

$$F_{4,j}^L = \frac{F_{4,j}}{(1 - F_{1,j})} \quad (13)$$

Donde $j=1,2$

Una vez obtenidos los parámetros de largo plazo para ambos períodos, se realizaron pruebas de significancia estadística para cada uno de los coeficientes de largo plazo, utilizando el Test de Wald, con la hipótesis nula indicando que cada uno de dichos valores era igual a cero (doce en total, 6 para el período pre-EMEI y 6 para el período EMEI). Adicionalmente,

se realizaron pruebas de hipótesis para verificar la hipótesis nula: $H_0: B_{2,i}^L = B_{2,2}^L$ y $H_0: F_{2,i}^L = F_{2,2}^L$, para analizar si los coeficientes de largo plazo para la respuesta del banco central ante fluctuaciones inflacionarias han cambiado ante la adopción del Esquema de Metas Explícitas de Inflación.

iv. Choques de política monetaria. En este apartado se analizó la respuesta de los precios a choques de política monetaria en el contexto de un modelo VAR, durante cada uno de los períodos de análisis (pre-EMEI y EMEI). Este análisis se realizó con el propósito de estimar si la adopción de una regla de política sensible a variaciones de la inflación, bajo esquema de metas explícitas, ha tenido un efecto significativo para contener la inflación. En este sentido, se construyó un

modelo VAR sin restricciones para cada período, utilizando la tasa de interés líder de política monetaria, la inflación total interanual, el crecimiento económico interno, la tasa de variación interanual de la emisión monetaria y la inflación externa. El ordenamiento en ambos casos fue $\{\pi^*, \Delta em, \Delta y, \pi, i\}$ y el orden de los rezagos se verificó por medio de los test estándar: Akaike, Schwarz y Hannan-Quinn.

2 | Datos

En la presente evaluación se construyeron dos bases de datos: una en frecuencia anual y otra en frecuencia trimestral, con información de 1991 hasta 2017, utilizando como fuente la información publicada por el Banco de Guatemala. Las variables consideradas fueron: i) inflación total, ii) meta de inflación, iii) expectativas de inflación a 12 meses, vi) crecimiento económico, v) Tasa de interés líder de política monetaria, vi) tasa de depreciación nominal, vii) Tasa de depreciación real. La inflación total corresponde a la tasa de variación interanual del Índice de Precios al Consumidor (IPC). La meta de inflación se obtuvo de las resoluciones de Junta Monetaria en el período especificado. El crecimiento económico corresponde a la tasa de variación interanual de la suma móvil de cuatro trimestres del Producto Interno Bruto real. La tasa de apreciación nominal corresponde a la tasa de variación interanual del tipo de cambio nominal y la tasa de apreciación real corresponde a la tasa de variación interanual del inverso del índice de tipo de cambio efectivo real (ITCER).

En el caso de la tasa de interés líder de política monetaria, existe información para el período 1995Q1-2017Q4. Para los datos del período 1991Q1-1994Q4, se realizó una estimación, utilizando la tasa de interés activa prome-

dio del sistema bancario, el crecimiento económico y la depreciación real. Asimismo, el Banco de Guatemala da seguimiento al Índice de tipo de cambio efectivo real (ITCER), desde el año 1995, por lo que el período comprendido entre 1991Q1 y 2004Q4, se calculó en base a la teoría económica ($\Delta s + \pi^* - \pi$), utilizando la inflación de los Estados Unidos como inflación externa. El Banco de Guatemala publica los resultados de la encuesta de expectativas económicas al panel de analistas privados (EEE), desde diciembre de 2003. Por lo que las expectativas inflacionarias a 12 meses, para el período 2004-2017 se obtuvo de dicha publicación. Para el período comprendido entre 1991 y 2003, se llevó a cabo una estimación, utilizando la tasa de inflación interanual como referencia en un modelo ARIMA. Para la evaluación, se dividió el rango en dos períodos principales. El primero de ellos comprende los años 1991 a 2004, y es considerado el período pre-EMEI (1991Q1-2004Q4, en frecuencia trimestral). El segundo período comprende los años 2005 a 2017 (2005Q1 – 2017Q4), y se considera el período EMEI, ya que se toma el año 2005 como el año de adopción formal del régimen de metas explícitas de inflación de parte del Banco de Guatemala.

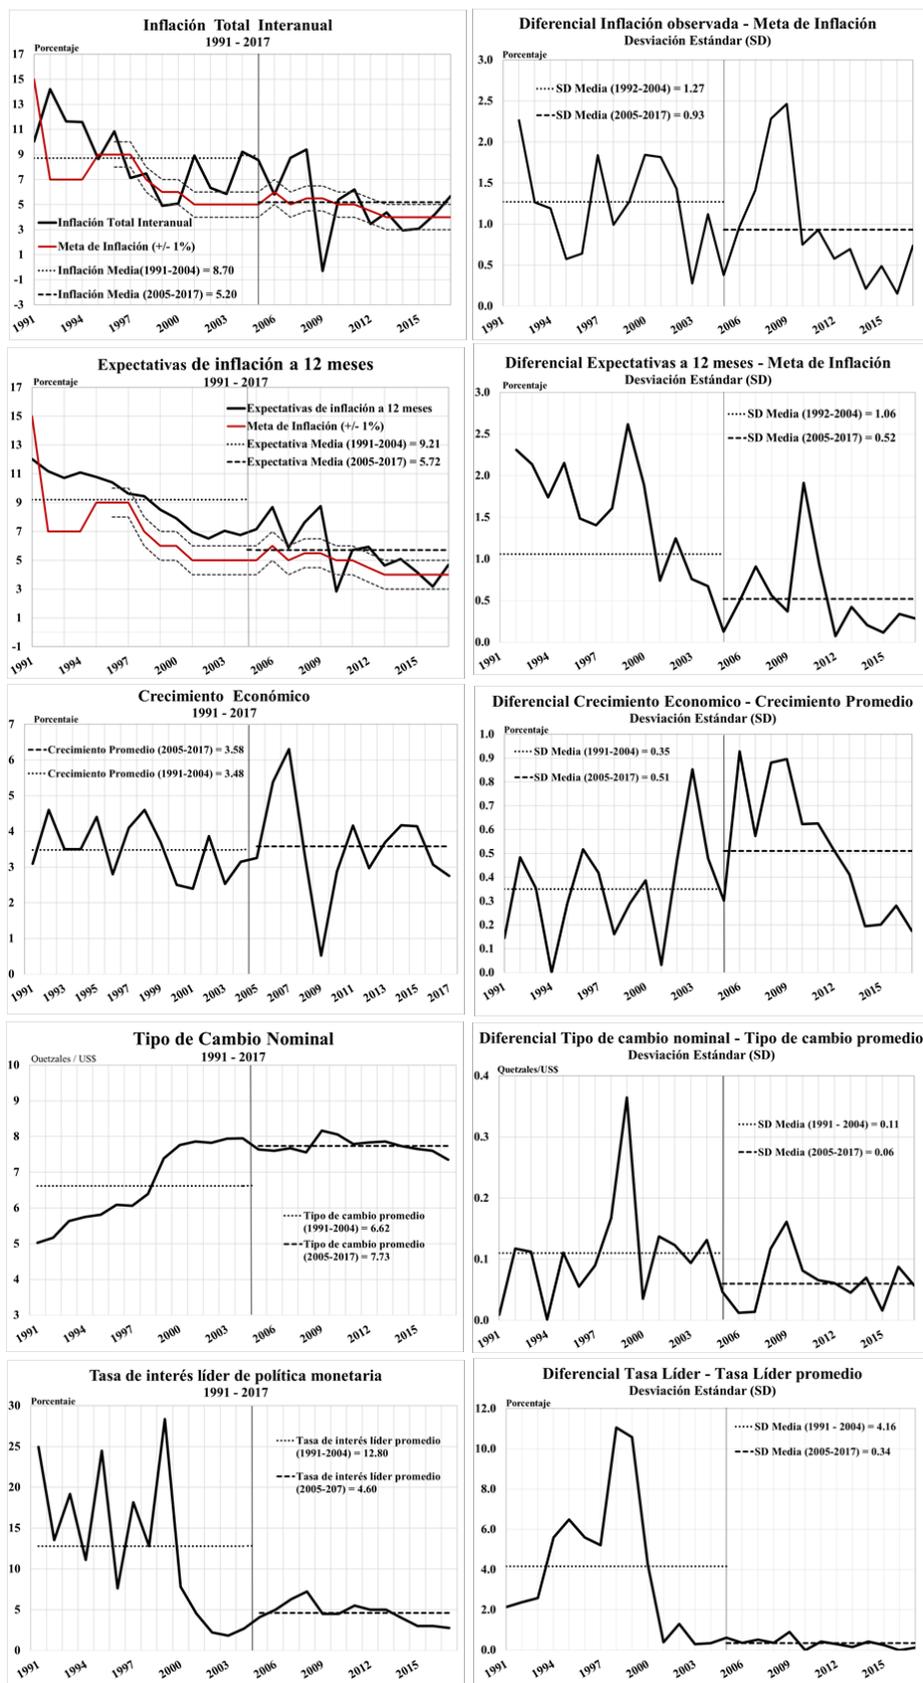
B. Evidencia empírica

La evaluación se enfocó en el análisis del desempeño de las metas explícitas de inflación como régimen de política monetaria. Se desarrollaron diferentes metodologías para determinar si la introducción de dicho régimen constituyó un cambio estructural dentro de la economía guatemalteca. En este sentido se evaluaron dos períodos, uno anterior a la adopción del régimen mencionado, y otro posterior, como se comentó en el apartado anterior.

I. Análisis macroeconómico. En cuanto a la inflación total interanual, la figura 1 muestra su trayectoria en todo el período de evaluación. Para el período pre-EMEI se observó un valor medio de 8.70%; y de 5.20%

para el período EMEI. Dichos valores medios se compararon por medio de una prueba de hipótesis para evaluar la diferencia entre ellos, la cual evidencia que la diferencia entre los valores medios de ambos períodos es significativa al 1% (cuadro 1).

Figura 1



Cuadro 1. Análisis macroeconómico

Estadístico	1991 - 2017	(A)	(B)	Δ (A-B)
		Pre - EMEI ¹ (1991 - 2004)	Con EMEI (2005 - 2017)	
Inflación				
Media	7.02	8.70	5.20	3.5***
Desviación Estándar	1.74	2.49	0.93	1.56
Expectativas de inflación				
Media	7.53	9.21	5.72	3.49***
Desviación Estándar	1.77	2.94	0.52	2.42*
Crecimiento económico				
Media	3.53	3.48	3.58	-0.10
Desviación Estándar	0.43	0.36	0.51	-0.15
Tipo de Cambio				
Media	7.15	6.62	7.73	-1.11***
Desviación Estándar	0.09	0.11	0.06	0.05*
Tasa de interés de política monetaria				
Media	8.86	12.80	4.61	8.19***
Desviación Estándar	2.32	4.16	0.34	3.82***
* Significativa al 10%				
** Significativa al 5%				
*** Significativa al 1%				
¹ / EMEI: Esquema de Metas Explícitas de Inflación				

En este sentido, podemos inferir que la introducción del Esquema de Metas Explícitas de Inflación no es inconsistente con una reducción de la inflación media. Adicionalmente, se analizó la desviación estándar del diferencial entre la inflación observada y la meta de inflación, lo cual se ilustra también en la figura 1. En dicha gráfica podemos observar la trayectoria de dicha desviación estándar en el período de análisis, teniendo valores medios de 1.27% y 0.93% para el período pre-EMEI y EMEI, respectivamente. En este caso, no se obtuvo significancia estadística para la diferencia entre los valores medios, lo cual es un indicativo de que, a pesar de que se ha reducido el nivel medio de inflación, la volatilidad de la misma no ha observado una diferencia significativa luego de la introducción del régimen mencionado. En la figura 1 también se muestra el comportamiento de las expectativas de inflación a 12 meses, así como sus valores medios para cada período en evaluación. En este sentido, podemos observar que los valores medios son de 9.21% y 5.72% para los períodos pre-EMEI y EMEI, respectivamente. En dicha figura se muestra también la desviación estándar del diferencial entre las expectativas inflacionarias y la meta de inflación, el cual tiene

valores medios de 1.06 y 0.52, para cada período mencionado. La diferencia entre los valores medios de las expectativas inflacionarias es significativa al 1%. Asimismo, los valores medios de desviación estándar muestran una significancia al 10% en su diferencia. Esto, en conjunto, podría indicar que la adopción del régimen de metas explícitas ha ayudado a anclar las expectativas de los agentes, reduciendo significativamente su nivel medio y su volatilidad. En cuanto a la evolución e impacto dentro del sector real, se muestra el comportamiento del crecimiento económico y de la desviación estándar del diferencial entre el crecimiento observado y su tasa de crecimiento potencial. En ambos casos, no se observan cambios significativos entre los valores medios, ni del crecimiento económico, ni de la desviación estándar del mencionado diferencial.

Adicionalmente se muestra el comportamiento del tipo de cambio nominal en el período en evaluación, así como el comportamiento de la desviación estándar del diferencial entre el tipo de cambio observado y el tipo de cambio promedio para los períodos pre-EMEI y EMEI.

En este sentido, se observó un aumento significativo (al 1%) entre los valores medios del tipo de cambio nominal entre los períodos pre-EMEI y EMEI. Por otro lado, la diferencia entre la desviación estándar del diferencial entre el tipo de cambio observado y el tipo de cambio promedio observó una reducción significativa al 10%. Esto indicaría que luego de la adopción del régimen de metas explícitas de inflación, el tipo de cambio nominal se estabilizó en un valor ligeramente superior al del período pre-EMEI, y que presentó una reducción significativa en su volatilidad.

En cuanto a la tasa de interés líder de política monetaria, se muestra el comportamiento de dicha tasa y del diferencial entre la tasa observada y su valor medio para cada período. En este sentido, puede observarse que

para el período pre-EMEI, el manejo de las tasas de política era mucho más volátil. Esto se confirma al realizar las pruebas de hipótesis, ya que tanto la diferencia entre los valores medios de la tasa líder, como los valores medios de la desviación estándar del mencionado diferencial, se reducen significativamente luego de la adopción del régimen de metas explícitas de inflación. El cuadro 1 muestra un resumen de los resultados de las pruebas de hipótesis realizadas. En este podemos observar que existen diferencias significativas en el comportamiento de la inflación, de las expectativas inflacionarias, del tipo de cambio nominal y de la tasa de interés líder de política monetaria. En este sentido, podríamos inferir que sí existe un cambio estructural en la economía guatemalteca, derivado de la introducción del régimen de metas explícitas de inflación en el año 2005.

II. Persistencia inflacionaria: En este apartado se siguió la metodología propuesta por Jiménez y Leyva (2014), en la que se llevó a cabo la estimación de una Curva de Phillips, para analizar la estabilidad de sus parámetros y cómo estos evolucionan en el tiempo. Los resultados de dicha estimación preliminar se presentan en el cuadro 2. Estos resultados confirman la alta persistencia inflacionaria presente en la economía guatemalteca, así mismo muestran la importancia de los shocks internos y externos en la formación de precios. Luego se llevó a cabo un análisis de estabilidad para cada parámetro utilizando el test de estabilidad propuesto por Kim y Nelson (1989). Se realizaron pruebas individuales para cada coeficiente y una prueba conjunta para determinar la estabilidad. Los resultados se muestran en el cuadro 3. En este sentido, se determinó que, en conjunto, los coeficientes estimados por medio del método de MCO no son estables. Asimismo, con excepción del coeficiente B, se rechaza la hipótesis nula de estabilidad, al 1% de significancia, para la persistencia inflacionaria (A) y para el coeficiente

C, que representa la sensibilidad de la inflación ante choques externos.

Posteriormente se llevó a cabo la estimación del sistema descrito por las ecuaciones (2), (3), (4) y (5) del apartado anterior. Las figura 2 muestra la trayectoria de los parámetros estimados utilizando el Filtro de Kalman. En el caso del parámetro A_t , se puede observar una trayectoria decreciente, lo cual es consistente con la reducción de la persistencia inflacionaria a través del tiempo, que es uno de los beneficios de la adopción del Esquema de Metas Explícitas de Inflación. Esto es un claro indicio de que existe un cambio estructural en la formación de los precios luego de la adopción del Esquema de Metas Explícitas de Inflación. Asimismo, el parámetro C_t muestra un comportamiento más estable en el período EMEI, lo cual nos da un indicio de que la adopción del Esquema de Metas Explícitas de Inflación ha hecho que la inflación guatemalteca se vea menos afectada por los shocks externos.

Cuadro 2. Estimación inicial Curva de Phillips

Estimación inicial: Curva de Phillips			
Método: Mínimos cuadrados ordinarios			
Variable dependiente: π_t			
$(\pi_t - \bar{\pi}) = A(\pi_{t-1} - \bar{\pi}) + B(\Delta y_t - \Delta \bar{y}) + C(\Delta z_t - \Delta \bar{z}) + \varepsilon_t$			
$(\pi_{t-1} - \bar{\pi})$	A		0.84***
$(\Delta y_t - \Delta \bar{y})$	B		0.31*
$(\Delta z_t - \Delta \bar{z})$	C		-0.06***
R^2			0.916
* Significativo al 10%			
** Significativo al 5%			
*** Significativo al 1%			

Cuadro 3. Test de Kim y Nelson

C_0	C_1	C_2	C_3	k	$\chi^2(k)$	p-value	R^2
0.94***	1.13×10^{-5} ***			1	12.19	0.000	0.06
1.06***		1.51×10^{-4}		1	0.08	0.777	0.00
0.754***			8.18×10^{-6} ***	1	91.86	0.000	0.47
0.71***	2.19×10^{-6}	0.0002	8.04×10^{-6} ***	3	92.49	0.000	0.48

Figura 2



III. Reacción del Banco Central. Utilizando como base la metodología de Taguchi y Kato (2010), se llevaron a cabo estimaciones de la Regla de Taylor, para los períodos pre-EMEI y EMEI. Por lo tanto, se realizaron dos estimaciones para cada período en evaluación, una *Backward Looking* y otra *Forward Looking*, tal y como se describe en las ecuaciones (6) y (7) del apartado metodológico. Dichas estimaciones analizan el vínculo entre la adopción del régimen de metas explícitas y la regla de política del banco central. El cuadro 4 muestra los parámetros de largo plazo, descritos en las expresiones (8) a (13), en los que los parámetros descritos con la letra B, representan estimaciones *Backward Looking* y los parámetros descritos con la letra F, representan estimaciones *Forward Looking*. La significancia de dichos parámetros se evaluó por medio del Test de Wald.

En este sentido, para el período pre-EMEI, puede observarse un claro comportamiento adaptativo de parte del banco central, ya que tanto los coeficientes de corto plazo, como los de largo plazo para la estimación *Backward Looking* son significativos, contrario a lo que se observa en la estimación *Forward Looking* para el mismo período. Para el caso del período EMEI, no hay un comportamiento de largo plazo definido, aun cuando los coeficientes de corto plazo para la inflación son significativos para ambas estimaciones. Adicionalmente, el cuadro 5 muestra los resultados del Test de Wald para evaluar la igualdad entre los coeficientes de largo plazo, entre las estimaciones correspondientes de cada período. Tanto para las estimaciones *Backward Looking*, como para las *Forward Looking*, no se encontró evidencia de que dichos parámetros de largo plazo fueran iguales en ambos rangos de análisis.

Cuadro 4. Coeficientes de largo plazo, Regla de Taylor

Parámetro de largo plazo	Período Pre-EMEI 1991Q1-2004Q4			Período EMEI 2005Q1-2017Q4		
	<i>Backward Looking</i>	<i>Forward Looking</i>	corto plazo	<i>Backward Looking</i>	<i>Forward Looking</i>	corto plazo
B_2^L	1.02**		π^*	1.87		π^{***}
B_3^L	4.08*		Δy^{**}	1.04		Δy
B_4^L	1.09***		Δs^{**}	0.14		Δs
F_2^L		1.66	π		1.42	π^{**}
F_3^L		8.64	Δy		0.58	Δy
F_4^L		1.89	Δs		0.89	Δs^{***}

*: Significativo al 10%
 **: Significativo al 5%
 ***: Significativo al 1%

Cuadro 5. Test de Wald para B^L y F^L

Wald Test	
$B_{2,1}^L = B_{2,2}^L$	$F_{2,1}^L = F_{2,2}^L$
--	--

*: Significativo al 10%
 **: Significativo al 5%
 ***: Significativo al 1%

IV. Choques de Política Monetaria: Siguiendo el abordaje de Taguchi y Kato (2010), en este apartado se analiza la respuesta de los precios a shocks de política monetaria en el contexto de un modelo VAR, con el fin de identificar el efecto de la política monetaria en la estabilización de los precios. En este sentido, se estimaron las funciones impulso-respuesta de los precios para los períodos pre-EMEI y EMEI, con el propósito de determinar si una regla de política más sensible a la inflación, en realidad ha tenido el efecto deseado para contener los shocks inflacionarios. De conformidad con la función impulso-respuesta obtenida para el período pre-EMEI, la cual se ilustra

en la figura 3, puede observarse que no hay efectos significativos de la inflación, ni del crecimiento económico, ante un shock en la tasa líder de política monetaria. Por otro lado, para el período EMEI, ante un shock de la tasa líder de política monetaria, se obtuvieron resultados significativos, conforme a la teoría, entre 4 y 8 trimestres posteriores al shock. En efecto, cuatro trimestres después del shock la inflación presentaría una desviación de -0.32% respecto de su valor de estado estacionario (4%); y una desviación de -0.40%, 8 trimestres después del choque. Los efectos acumulados en la inflación y el crecimiento económico se presentan en el cuadro 6.

Cuadro 6. Efecto acumulado de un shock de Política Monetaria

Períodos posteriores al choque	Efecto Acumulado		Tasa de crecimiento (%) ¹	
	Inflación Total	Crecimiento Económico	Inflación Total	Crecimiento Económico
1 - 4	-0.65	-0.16	-0.16	3.34
5 - 8	-2.49	-0.56	-0.56	2.94

¹/ Respecto de su estado estacionario

Figura 3



* Método de descomposición: Cholesky – dof adjusted

Conclusiones

A partir de su implementación, en Nueva Zelanda en 1990, el EMEI se ha convertido en una alternativa atractiva para la gestión de la política monetaria, tomando en consideración sus resultados positivos, tanto en términos de controlar el nivel inflacionario como su volatilidad, tal como sugieren diversos estudios para varias economías. En ese sentido, la evidencia empírica internacional señala también que este esquema trae consigo resultados favorables en el anclaje de las expectativas de inflación. Tomando en consideración estos antecedentes positivos, Guatemala adopta este esquema 15 años después de su gestación; obteniendo resultados análogos a los obtenidos por dichos países.¹¹

Los resultados empíricos muestran evidencia de un cambio estructural en la formación de precios en la economía guatemalteca. A pesar de no haber evidencia

de reducción en la volatilidad de la inflación, se encontró evidencia de reducciones significativas en su valor medio y en su persistencia luego de la adopción del EMEI. Asimismo, la preferencia del banco central por una regla de política backward looking, comprobada para el período pre-EMEI, no se pudo comprobar para el período EMEI, en el cual, a pesar de no presentar una preferencia contundente y significativa hacia una regla prospectiva en el largo plazo (forward looking), sí hay indicios de preferencia hacia dicha regla en el corto plazo. Adicionalmente, puede observarse un cambio en la respuesta de la inflación ante choques de política monetaria, dando un indicio de mayor efectividad del régimen de metas explícitas de inflación, en el corto y mediano plazo, respecto del régimen monetario previamente vigente.

Referencias

- Agénor, Pierre-Richard y Pereira da Silva, Luiz A. "Inflation Targeting and Financial Stability: A Perspective from the Developing World". Inter-American Development Bank. 2013, pp 35-45.
- Arestis, P., de Paula, L. F. y Ferrari-Filho, F. "Inflation targeting in Brazil", The Levy Economics Institute Working Paper N° 544, 2008.
- Ball, Laurence y Dean Croushore. "Expectations and the Effects of Monetary Policy". Journal of Money, Credit and Banking, Vol. 35, No. 2003. 1995.
- Banco de Guatemala. "Política Monetaria: Aspectos Teóricos y Evidencia Empírica en un Esquema de Metas Explícitas de Inflación". Área Económica. Diciembre 2006, pp. 1-43.
- Banco de Guatemala, Departamento de Investigaciones Económicas, Sección de Modelos Macroeconómicos. Model Book Modelo Macroeconómico Semiestructural Versión 4.0. Octubre 2015, pp. 13-17.
- Barbosa-Filho, N. H. "Inflation targeting in Brazil: 1999-2006", International Review of Applied Economics, Vol. 22 (2); 187-200, 2008.
- Barro, R. y David Gordon. "A Positive Theory of Monetary Policy in a Natural Rate Model". The Journal of Political Economy, Vol. 91, No. 4, pp: 589-610, 1983.
- Barros-Campero, Esther, Carlos Pateiro, J. Venancio Salcines, Carlos Pateiro. El esquema de objetivos de inflación: Evidencia para América Latina (1999-2015). Estudios de Economía Vol. 44. No. 2, Diciembre 2017, pp 223-250.
- Bernanke, Ben y Frederic Mishkin. "Inflation Targeting: A New Framework for Monetary Policy?" The Journal of Economic Perspectives. American Economic Association. 1997, pp 97-116.
- Bernanke, Ben y Ilian Mihov. The Liquidity Effect and Long-Run Neutrality. NBER Working Papers Series No. 6608, National Bureau of Economic Research, 1998.
- Bridgen, A., y P. Mizen. "Money, Credit and Investment in the UK Corporate Sector". Bank of England Working Paper No. 100, 1999.
- Cabrera, N., Bejarano, E., & Savino Portugal, M. (2011). Preferences of the Central Reserve Bank of Peru and optimal monetary policy rules in the inflation targeting regime (No. 2011-010).
- Castillo, Carlos. "The Liquidity Effect and the Long Run Neutrality of Money in Guatemala". Banca Central, Vol. 51, Enero-Junio, 2006.

¹¹ Aunque es posible que los resultados favorables observados durante la vigencia del EMEI puedan ser atribuidos, en alguna medida, a factores externos y ajenos al régimen de política monetaria, sí es posible afirmar que el EMEI ha sido consistente con los resultados macroeconómicos favorables experimentados por la economía guatemalteca que son documentados en este trabajo.

- Castillo, Carlos. Efectividad de la intervención cambiaria en Guatemala. El trimestre económico. Vol. LXXVII, número 307, julio-septiembre, 2010, pp 557-583.
- Castillo, Carlos. Un modelo macroeconómico para Guatemala estimado por métodos Bayesianos. Serie de Documentos de Trabajo del Banco de Guatemala, Documento de Trabajo No. 124, 2012.
- Christiano, Lawrence, Martin Eichenbaum y Charles Evans. "The Effects of Monetary Policy Shocks: Some Evidence from the Flow of Funds". NBER Working Papers Series No. 4699, National Bureau of Economic Research. 1994.
- Dancourt, O. (2014). "Inflation Targeting in Peru: the Reasons for the Success", Documento de Trabajo N° 386. Departamento de Economía. Pontificia Universidad Católica del Perú.
- De Dios, J., y Salazar, C. "Explaining Inflation and Output Volatility in Chile: an Empirical Analysis of Forty Years", Universidad Carlos III de Madrid. Working Paper 07-15. Statistic and Econometric Series 05, 2007.
- Echavarría, J. J., Rodríguez, N. y Rojas, L. E. "La Meta del Banco Central y la persistencia de la inflación en Colombia", Ensayos sobre Política Económica, Vol. 29 (65); 2011, 198-222.
- FMI (2017). Annual Report on Exchange Arrangements and Exchange Restrictions. Fondo Monetario Internacional.
- García Lara, Mario. Presentación "De Metas Monetarias a Metas de Inflación". Guatemala, agosto 2005.
- Hammond, G. (2012). State of the Art of Inflation Targeting. Handbooks, Centre for Central Banking Studies, Bank of England, Edition 4, Number 29.
- Hauser, Andrew, y Andrew Bridgen. "Money and Credit in an Inflation Targeting Regime". Bank of England Quarterly Bulletin, Otoño, 2002.
- Hiroyuki Taguchi y Chizuru Kato. "Assesing the Performance of Inflation Targeting in East Asian economies" Asian-Pacific Economic Literature, 25(1), 93-102 (2010).
- Hiroyuki Taguchi y Woong-Ki Sohn. "Inflation Targeting and Pass-through Rate in East Asian Economies," Macroeconomics Working Papers 23115, East Asian Bureau of Economic Research, 2010.
- Jiménez, Gustavo y A. Leyva. "Evaluating inflation targeting in Latin America." Unpublished paper. Universidad Nacional Agraria La Molina. Lima-Perú. 2004.
- Johnson, David R. "The effect of inflation targeting on the behavior of expected inflation: evidence from an 11 country panel" Journal of Monetary Economics, 2002, pp 1521-1538.
- Kim, C-J y C. Nelson. "The Time-Varying-Parameter Model for Modeling Changing Conditional Variance: The Case of the Lucas Hypothesis". Journal of Bussiness and Economic Statistics. 1989, pp 17-23.
- Kydland, F. E. y Edward Prescott. "Rules Rather Than Discretion: The Inconsistency of Optimal Plans". The Journal of Political Economy, Vol. 85, No. 3, pp: 473-492, 1977.
- Landerretche, O., Morandé, F., & Schmidt-Hebbel, K. (1999). Inflation targets and stabilization in Chile (No. 55). Banco Central de Chile.
- Leeper, Eric, Christopher Sims y Tao Zha. "What Does Monetary Policy Do?". The Brookings Institute, pp. 1-48, Noviembre, 1996.
- Levine, R., N. Loayza y T. Beck. "Financial intermediation and growth: Causality and Causes". Journal of Monetary Economics 46 (1), 31:77, 2000.
- Londoño, A. F., Tamayo, J. A. y Velásquez, C. A. "Dinámica de la política monetaria e inflación en Colombia: Una aproximación FAVAR", Ensayos sobre Política Económica, Vol. 30 (68); 2012, 12-71.
- Lucas, Robert. "Expectations and the Neutrality of Money". Journal of Economic Theory, Vol. 4, No. 2, pp: 103-124, 1972.
- Ramos-Francia, M., & Torres, A. (2005). Reducción de la inflación a través de un esquema de objetivos de inflación: la experiencia mexicana. Documento de trabajo, (2005-01).
- Rogoff, Kenneth. "The Optimal Degree of Commitment to an Intermediate Monetary Target". The Quarterly Journal of Economics, Vol. 100, No. 4, Noviembre, pp: 1169-1189, 1985.
- Svensson, Lars. "Inflation Targeting". National Bureau of Economic Research. Working Paper 16654. December 2010, pp. 1-33.
- Thomas R. "Understanding broad money". Bank of England Quarterly Bulletin, Vol. 36, 1996.
- Urrutia, M., Hofstetter, M., & Hamann, F. (2014). Inflation Targeting in Colombia, 2002-2012.
- Woodford, Michael. "Interest and Prices". Princeton University Press, 2007.

Pronóstico del tipo de cambio utilizando redes neuronales convolucionales*

David José Gabriel Maselli

Este trabajo tuvo como objetivo evaluar si redes neuronales convolucionales, en particular la red neuronal WaveNet, son capaces de superar el poder predictivo del modelo de caminata aleatoria. El trabajo se dividió en dos partes, la primera utilizó datos diarios entre 2013 y 2016; y la segunda, datos mensuales entre 2013 y 2019. Se realizaron pruebas tanto con la red WaveNet no condicional univariada, como la condicional multivariada. Los resultados fueron comparados con los de los modelos de caminata aleatoria, modelo ARIMA y modelo de corrección de error. Las medidas para evaluar el poder predictivo de cada modelo fueron el promedio de errores cuadráticos, el promedio de errores absolutos, el promedio de errores porcentuales absolutos, la precisión direccional y el estadístico de Pesaran y Timmermann. Para los datos diarios, con el modelo WaveNet no condicional se obtuvo el mejor ajuste tanto adentro como afuera de la muestra. Para los datos mensuales, el modelo WaveNet condicional tuvo el mejor ajuste adentro de la muestra, y el modelo de corrección de error afuera de la muestra. A pesar que no se cuenta con una prueba de hipótesis para demostrar que los pronósticos hechos por las redes neuronales son estadísticamente diferentes, la prueba de Pesaran y Timmeramann revela que el modelo WaveNet contiene información de la dirección del cambio para los datos diarios, a diferencia del modelo de caminata aleatoria.

Abstract

The goal of this work is to evaluate if neural networks, specifically the WaveNet architecture, are capable of outperforming the random walk model in forecasting capabilities. It was divided in two parts, the first used daily data from 2013 to 2016, and the second used monthly data from 2013 to 2019. Both versions of the neural network were implemented, that is, the univariate unconditional WaveNet and the multivariate conditional WaveNet. Results were then compared with the random walk model, ARIMA model, and error correction model. The measures for evaluating the performance of a model were the mean squared errors, the mean absolute errors, the mean absolute percentage errors, the directional accuracy, and the Pesaran and Timmermann statistic. For daily data, the unconditional WaveNet provided the best fit both in and out of sample. For monthly data the conditional WaveNet had the best fit in sample and the error correction model outside of sample. Even though there is no hypothesis test to prove that neural networks are statistically different to the random walk, the Pesaran-Timmermann test reveals that the WaveNet model contains information of the direction of change for daily data, unlike the random walk model.

* Investigación presentada por el autor para optar al título de Magíster en Economía y Finanzas Aplicadas, asesorado por el Dr. Nicholas Virzi y MSc. Manuel Castro, Guatemala, 2020. Universidad Rafael Landívar, Banco de Guatemala, Centro de Estudios Monetarios Latinoamericanos, Programa de Estudios Superiores.

1 | Introducción

¿Existe algún método para pronosticar el tipo de cambio que supere a la caminata aleatoria? Históricamente, la caminata aleatoria (*Random Walk*) ha sido difícil de superar cuando se intenta pronosticar el tipo de cambio [13]. La simple idea detrás de este modelo es que el valor esperado para una variable es el último valor que tuvo, es decir, para una variable x_t :

$$x_{t+1} = x_t + \varepsilon_{t+1} \quad (1)$$

donde ε es ruido blanco con valor esperado cero. Otra pregunta importante es si existen variables que ayuden a mejorar el pronóstico o si es simplemente mejor utilizar los valores pasados del tipo de cambio. Una compilación de múltiples trabajos fue realizada por Barbara Rossi [15] con el objetivo de contestar esta pregunta.

Este trabajo se divide en dos partes, ambas con el mismo objetivo: pronosticar el tipo de cambio para Guatemala “one-step ahead”, es decir, pronosticar el tipo de cambio en $t + 1$ utilizando información disponible hasta t . En la primera parte se intenta pronosticar el tipo de cambio diario utilizando la red neuronal WaveNet, con observaciones entre 2013 y 2016 (más detalles en la sección 3). Luego este procedimiento se repite, pero agregando los datos del diferencial de las tasas de interés, para evaluar si esta información mejora o no el pronóstico. Estos resultados se comparan con otros tres modelos utilizados como “benchmark”. El primero es la caminata aleatoria, el segundo es un modelo ARIMA, y el tercero es un modelo de corrección de error (ECM) de una ecuación.

En la segunda parte, se repite el procedimiento de la primera parte, pero utilizando datos de frecuencia mensual desde enero de 2013 hasta diciembre de 2019. Adicionalmente, se incorporó el diferencial de inflaciones en los modelos multivariados.

Con la finalidad de responder estas dos preguntas, se utilizaron cinco medidas para evaluar el desempeño de cada pronóstico. Las primeras tres son bastante conocidas, siendo estas el promedio de errores cuadráticos (MSE), el promedio de errores absolutos (MAE) y el promedio de errores porcentuales absolutos (MAPE).

En la sección 6 se introducen las otras dos medidas: la precisión direccional (DA) y el estadístico de Pesaran y Timmerman (PT). Esta prueba nos puede indicar si un pronóstico contiene o no información sobre la dirección del cambio de la variable que está pronosticando. De ser rechazada la hipótesis nula, podremos concluir que el modelo estudiado, en efecto contiene dicha información. Esta es una diferencia fundamental con el modelo de caminata aleatoria, el cual no contiene esa información. Los resultados de todos los pronósticos se encuentran en las tablas de la sección 7.

La red neuronal WaveNet fue desarrollada originalmente por un equipo de Google [17] para producir audio, pero adaptada exitosamente por Borovykh, *et al* [1] para pronosticar el índice SP500. El principio de su funcionamiento se encuentra en la sección 4. El código de esta fue escrito en el idioma de programación Python. Este se encuentra en el anexo A.

2 | Determinantes del tipo de cambio

Una de las primeras teorías sobre los determinantes del tipo de cambio se origina con Irving Fisher en 1896 [5]. A esta se le conoce como paridad de interés. Sean i la tasa de interés asociada a la moneda local, e i^* la tasa de interés de moneda extranjera, es necesario imponer la restricción que después de un período determinado de tiempo se tenga la misma cantidad de dinero sin importar si los intereses fueron generados utilizando moneda local o extranjera. En palabras más sencillas, si una moneda presenta una tasa de interés más atractiva, esta se apreciará debido a que tendrá mayor demanda. Escrita en forma de ecuación, tenemos:

$$1 + i_{t+1} = \frac{E_t(S_{t+1})}{S_t} (1 + i_t^*) \quad (2)$$

Para un tipo de cambio S_t . Tomando el logaritmo natural en ambos lados de la ecuación, y recordando que $\log(a/b) = \log a - \log b$, y $\log(1+a) \approx a$, tenemos:

$$i_{t+1} \approx E_t(s_{t+1}) - s_t + i_{t+1}^* \quad (3)$$

donde $s_t = \log S_t$. Reordenando los términos, se puede crear un modelo lineal para el tipo de cambio basado en el diferencial de intereses:

$$\Delta \hat{s}_{t+1} = \alpha + \beta(i_{t+1} + i_{t+1}^*) \quad (4)$$

Experimentos conducidos por Meese y Rogoff [10] utilizando el tipo de cambio real y el diferencial de intereses reales muestran que este modelo no pronostica mejor que la caminata aleatoria. Por otro lado, Molodtsova y Papell [11] encontraron lo contrario para algunos países.

Análogo al modelo de Fisher, encontramos el de Cassel [2], quien fue el pionero de otra teoría, llamada paridad de poder adquisitivo. Esta sigue la misma lógica que Fisher, pero con los precios reales de las canastas básicas de distintos países. Escrito en forma logarítmica, este modelo es:

$$s_t = \alpha + \beta(p_t + p_t^*) \quad (5)$$

donde p corresponde al logaritmo natural para el nivel de precios. Dado que $\Delta \log x \approx \Delta x/x$, podemos interpretar $\Delta p/p$ como cambios porcentuales en el nivel de precios, es decir inflación. Por lo que el modelo puede reescribirse como:

$$\Delta s_t = \beta(\pi_t + \pi_t^*) \quad (6)$$

Estudios realizados por Cheung, *et al* [3] revelan que este modelo tiene mayor poder predictivo a largo plazo que la caminata aleatoria, pero sucede lo contrario en horizontes cortos de tiempo.

Entre otros modelos, también se encuentra el modelo monetario que se basa en diferenciales de logaritmos de ofertas monetarias [19].

$$s_t = (m_t - m_t^*) + \alpha(i_t - i_t^*) + \beta(y_t - y_t^*) \quad (7)$$

La intuición detrás es que, a mayor o menor oferta de dinero relativa a la de otro país, la moneda debe devaluarse o apreciarse respecto a la otra. No obstante, Meese y Rogoff [9] encontraron que la caminata aleatoria pronostica mejor afuera de la muestra. Adicionalmente, Cheung, *et al* [3] encontraron que no pronostica bien para horizontes cortos ni largos.

Finalmente, el modelo de Taylor:

$$\Delta \hat{s}_{t+1} = \hat{\mu} + \hat{\lambda}(\pi_t - \pi_t^*) + \hat{\gamma}(y_t^g - y_t^{g*}) \quad (8)$$

que se basa en las brechas de productos y_t^g . Moldotsova y Papell [11] han encontrado que la ecuación 8, pronostica significativamente mejor que la caminata aleatoria para algunos países.

3 | Datos utilizados

3.1. Datos diarios

Para los modelos que utilizan datos de frecuencia diaria se incorporan dos variables. La primera es s_t , la cual es el logaritmo natural del tipo de cambio entre quetzales y dólares de Estados Unidos. La segunda variable es el diferencial de tasas de interés, $i_t - i_t^*$. Para la tasa de interés de Guatemala, i_t se utilizó la tasa de reportos de operaciones interbancarias.¹ En el caso de Estados Unidos, i_t^* , se utilizó la tasa de Bonos del Tesoro a diez años.² Estas variables fueron normalizadas (se les resta su media y se dividen dentro su desviación estándar) para que se encuentren dentro de la misma escala.

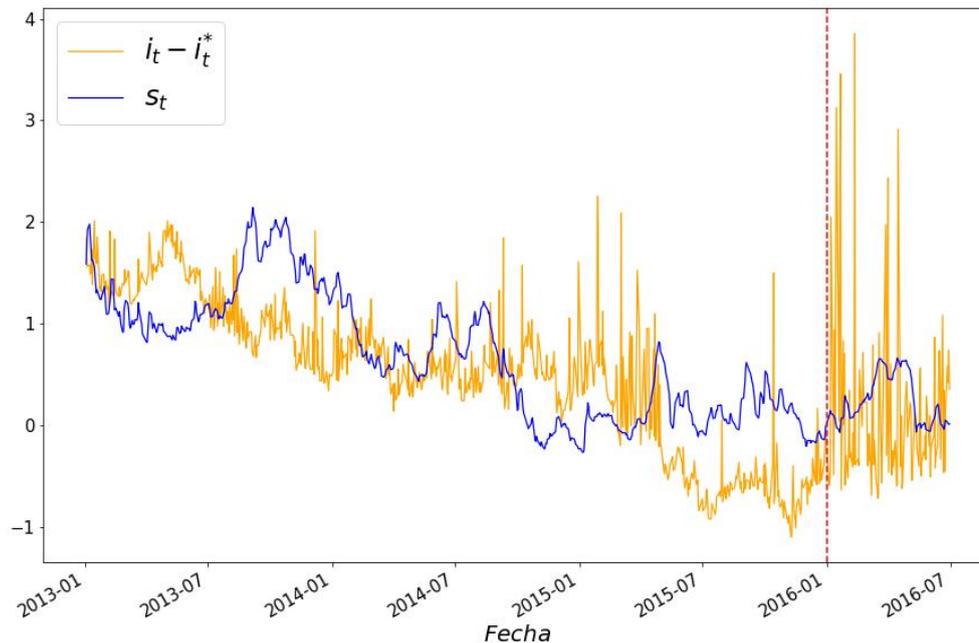
El rango de las fechas utilizadas para calibrar los modelos es desde 2013-01-01 hasta 2015-12-31, con un total de 720 observaciones. Adicionalmente se utilizaron 120 observaciones desde 2016-01-01 hasta 2016-06-30, para poner a prueba el poder predictivo de los modelos. La figura 1 nos muestra estos datos. La línea roja nos indica donde terminan las observaciones que se utilizaron para calibrar todos los modelos.

3.2. Datos mensuales

En el caso de los modelos que utilizan observaciones de frecuencia mensual, se utilizaron las dos variables anteriores y se agregó una tercera, $\pi_t - \pi_t^*$, en donde π_t es la inflación interanual de Guatemala, la cual fue obtenida directamente del Banco de Guatemala,³ y π_t^* es la inflación interanual de Estados Unidos, que fue calculada a partir de variaciones interanuales del índice de precios al consumidor.⁴ Dado que s_t , e $i_t - i_t^*$ son de frecuencia diaria, estas fueron convertidas a variables mensuales, tomando la última observación de cada mes. Al igual que en el caso de variables diarias, estas también fueron normalizadas.

Figura 1: Datos diarios utilizados.

La línea roja separa los datos adentro y afuera de la muestra.



1 [https://www.banguat.gob.gt/opinterb/param combinado.asp](https://www.banguat.gob.gt/opinterb/param%20combinado.asp)

2 <https://fred.stlouisfed.org/series/DGS10>

3 <https://www.banguat.gob.gt/es/page/inflacion-subyacente-interanual>

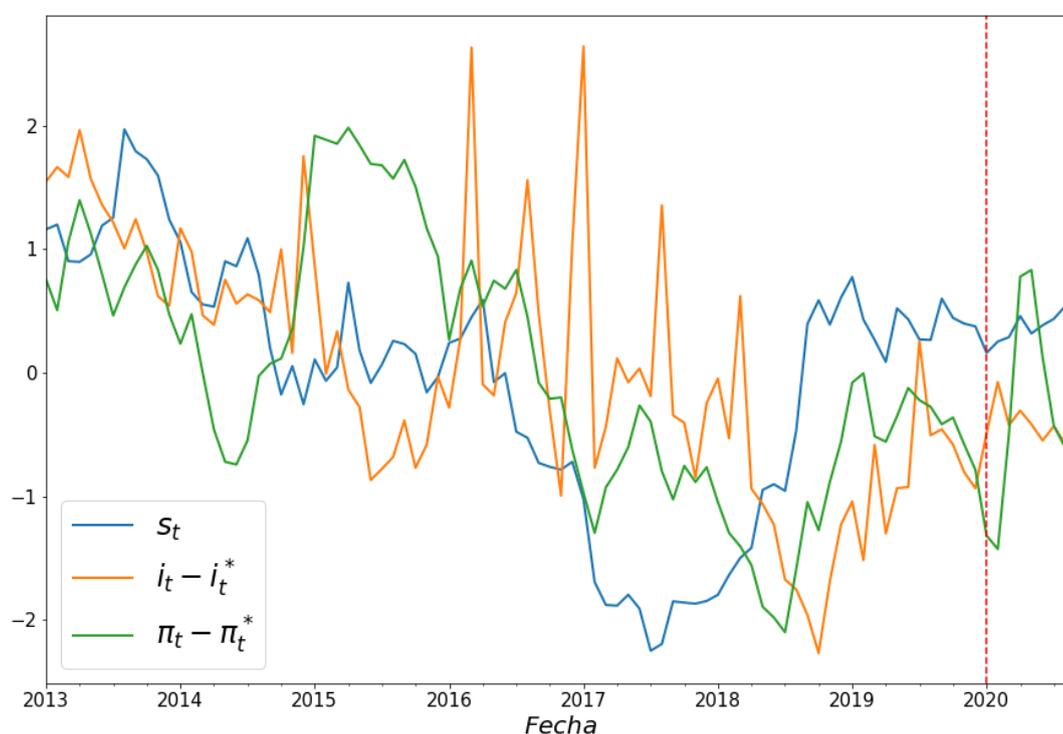
4 <https://fred.stlouisfed.org/series/CPIAUCSL>

El rango de fechas utilizadas para calibrar los modelos es desde enero de 2013 hasta diciembre de 2019, con un total de 84 observaciones. Adicionalmente se utilizaron

observaciones desde enero hasta septiembre de 2020 para ponerlos a prueba. En la figura 2 podemos visualizar los datos.

Figura 2: Datos mensuales utilizados.

La línea roja separa los datos adentro y afuera de la muestra.



4 | Redes Neuronales Convolucionales

4.1. ¿Qué es una Red Neuronal?

Actualmente la Real Academia Española no cuenta con una definición para una red neuronal, pero según el diccionario Merriam-Webster,⁵ una red neuronal es “una arquitectura de computadora en el que un número de procesadores están interconectados en una manera similar a la de las neuronas en el cerebro humano y que es capaz de aprender a través de prueba y error”. En palabras más sencillas, una red neuronal es un conjunto de “neuronas” interconectadas entre sí, en donde cada neurona recibe un conjunto de datos y produce otro

conjunto de datos como salida, basándose en una función. A una red neuronal se le puede imponer los datos que tiene que producir de salida, dado un conjunto de datos de entrada y esta ajustara sus parámetros de manera iterativa y automática para alcanzar el resultado. Esto las convierte en poderosas herramientas para diversas tareas, como detección de patrones, clasificación de imágenes o tareas de regresión no lineal, entre otras. Su flexibilidad y capacidad de aprendizaje hace que sean fáciles de implementar en economía y finanzas.

⁵ <https://www.merriam-webster.com/dictionary/neural%20network>

4.2 ¿Qué es una neurona?

La neurona es el elemento fundamental de una red neuronal. Esta consiste en un objeto que recibe múltiples datos a los cuales les aplica una transformación y produce datos de salida. Uno de los tipos de neurona más sencillos se conoce como un perceptrón. Esta neurona recibe como entrada un vector \mathbf{x}_t y produce un solo número de salida, \mathbf{y} , a través de la siguiente transformación:

$$y = f\left(\sum_t (\omega_t x_t) + b\right) \quad (9)$$

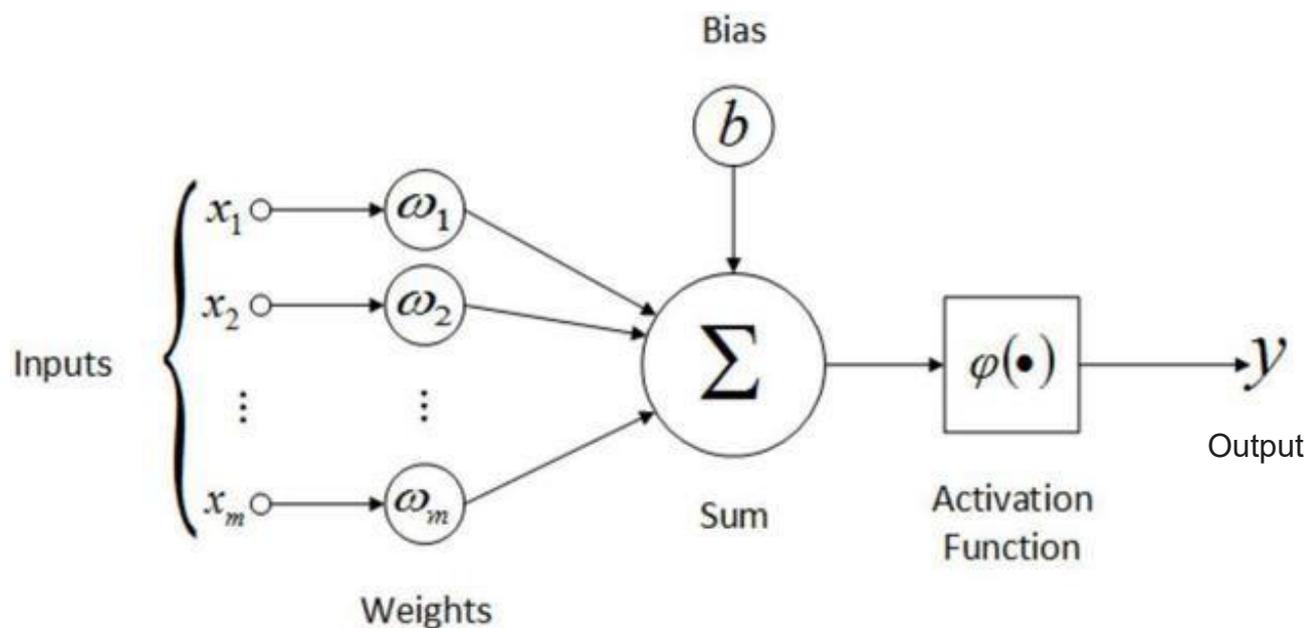
donde el vector de pesos, ω_t , y el sesgo, b , son parámetros que se ajustan de manera automática, y f es la "función de activación", la cual es elegida por el usuario.

Existe mucha flexibilidad respecto a qué tipo de funciones se pueden elegir. Estas no necesitan ser lineales, y no necesitan tener una derivada continua. Es la función de activación la que le permite a las redes neuronales aprender relaciones no lineales entre los datos. La función de activación utilizada en todas las redes creadas para este trabajo es la función ReLU. Esta se define como:

$$\text{ReLU}(x) = \max(0, x) \quad (10)$$

Su nombre es un acrónimo para "Rectified Linear Unit". La figura 3 es una representación visual de lo que realiza un perceptrón.

Figura 3: El perceptrón



Fuente: <https://medium.com/@aborundiya/activation-function-for-multi-layer-neural-networks-a07ac473f69e>

No obstante, el perceptrón no es el tipo de neurona que se utiliza en las redes neuronales convolucionales. En estas su unidad análoga se conoce como “capa convolucional”. La estructura de una capa convolucional es similar a la de un perceptrón. La diferencia es que, en lugar de realizar una suma, realiza una convolución. Y en lugar de tener un vector como entrada, esta es capaz de recibir una matriz y su salida puede ser desde un solo número hasta una matriz. Recordemos que para dos vectores u_t y v_t una convolución se define como:

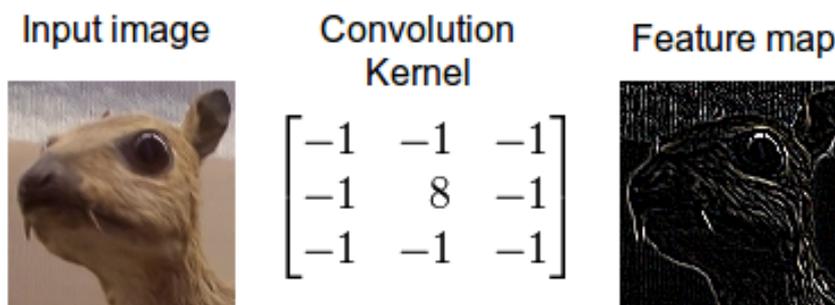
$$(u * v)_t = \sum_{\tau} u_{t-\tau} v_{\tau} \quad (11)$$

Si u_t es el vector de entrada, entonces al vector v_t se le conoce como “filtro” o “kernel”. En una red neuronal convolucional, son los valores que pertenecen al filtro los que son ajustados. En el caso que u y v sean matrices, la definición es:

$$(u * v)_{t,s} = \sum_{\tau} \sum_{\sigma} u_{t-\tau, s-\sigma} v_{\tau, \sigma} \quad (12)$$

Las convoluciones son particularmente útiles para detectar patrones. En la figura 4 podemos ver cómo se implementan para la detección de bordes en las imágenes.

Figura 4: Convolución para detectar bordes



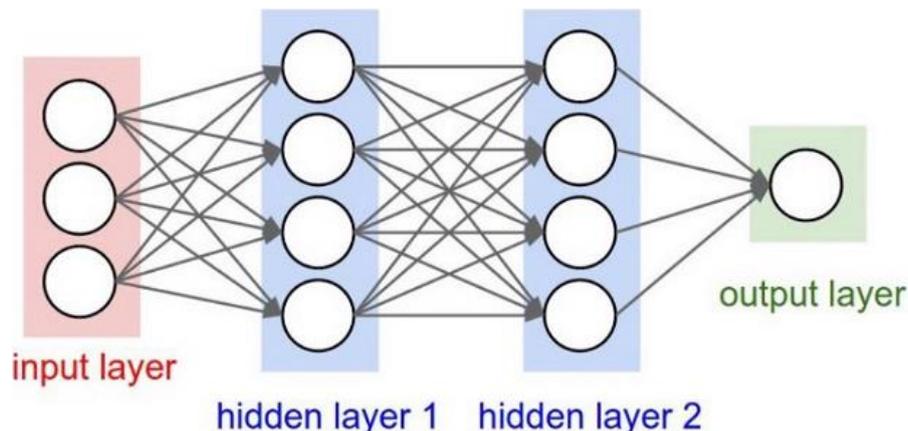
Fuente: <https://developer.nvidia.com/discover/convolution>

4.3. Estructura de una red neuronal

Sabiendo ahora lo que es una neurona, podemos explicar cómo se estructura una red neuronal. Esta es una serie de “capas” de neuronas en donde los datos de entrada de cada neurona son los datos de salida de las neuronas de la capa anterior. Las neuronas que comparten la misma capa no se conectan entre sí. En la figura 5 se observa un conjunto de perceptrones interconectados entre sí para formar una red llamada perceptrón multicapa. En cada capa, se realiza una media ponderada y luego se aplica la función de transformación, y el resultado es alimentado a la siguiente capa. El número de capas y el número de neuronas en cada capa es algo que decide el usuario. En

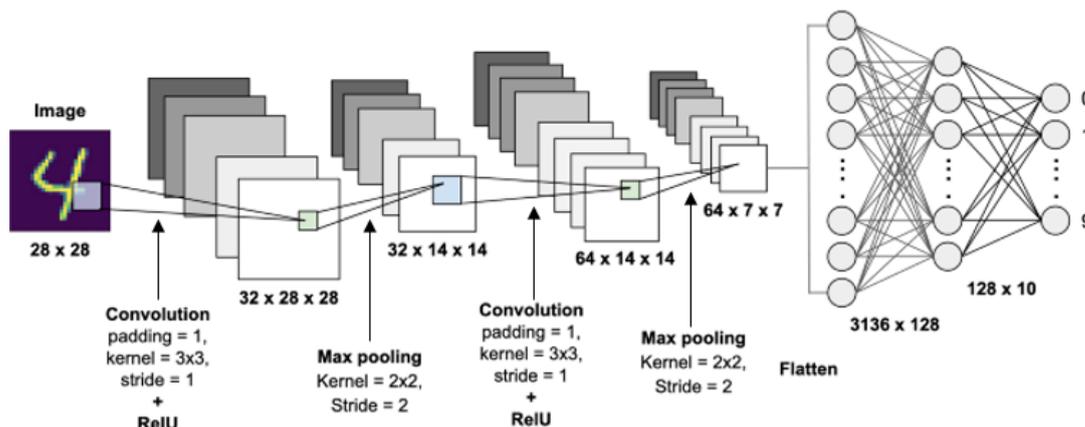
una red neuronal convolucional, en lugar de aplicar una media ponderada en cada capa, se aplica una convolución y luego la función de activación a cada elemento de la convolución. **En un perceptrón multicapa, todas las neuronas de una capa tienen parámetros diferentes para el mismo input, mientras que, en una red convolucional, los parámetros del filtro son los mismos sin importar el input. Esto les permite a las redes convolucionales tener menos parámetros.** Lo que puede variar en una capa convolucional es el tamaño del filtro y el número de filtros (figura 6).

Figura 5: El Perceptrón multicapa



Fuente: <https://medium.com/analytics-vidhya/multi-layer-perceptron-using-keras-on-mnist-dataset-for-digitclassification-problem-re-lu-a276cbf05e97>

Figura 6: Red neuronal convolucional



Fuente: <https://becominghuman.ai/building-a-convolutional-neural-network-cnn-model-for-image-classification-116f77a7a236>

4.4 ¿Por qué utilizar una red neuronal?

Las redes neuronales son excepcionalmente versátiles en el número de tareas que pueden cumplir. Entre ellas, se encuentra la tarea de regresión. Asumamos que queremos estimar \hat{y} en donde $y = f(x_1, x_2, \dots, x_n)$ para alguna función desconocida f . Por lo tanto, podemos entrenar una red neuronal utilizando todos los valores conocidos de x_1, x_2, \dots, x_n en la capa de entrada y todos los valores

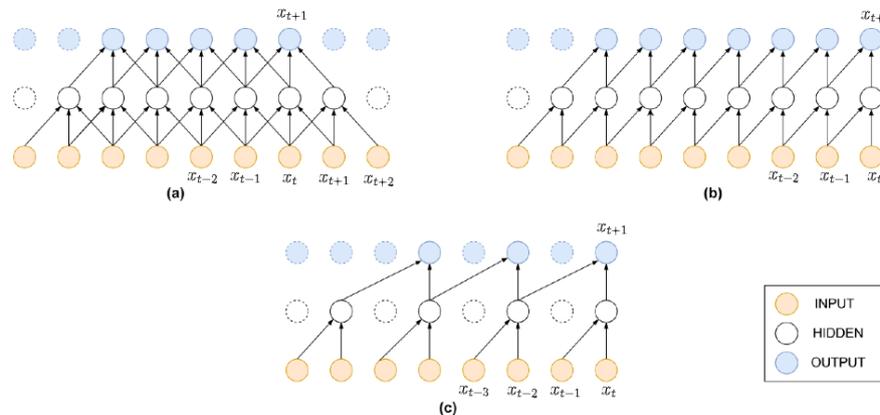
conocidos de y en la capa de salida para realizar una regresión. La red neuronal, de forma automática e iterativa modificara sus parámetros para minimizar la función de pérdida, la cual mide qué tan bueno o malo es el ajuste. La función de pérdida es especificada por el usuario: en nuestro caso es el promedio de errores cuadráticos, pero en casos como tareas de clasificación es algo diferente, como la entropía cruzada.

4.5 El Modelo WaveNet

En la figura 7 se observan tres distintas arquitecturas para una red neuronal convolucional unidimensional. La entrada de esta red, el *input*, es una serie de tiempo x_t , y su salida, el *output*, es lo que intentamos pronosticar, x_{t+1} .

Figura 7: Distintas arquitecturas para redes neuronales unidimensionales

(a) Una red neuronal convolucional. (b) Una red neuronal causal. (c) Una red neuronal causal dilatada.



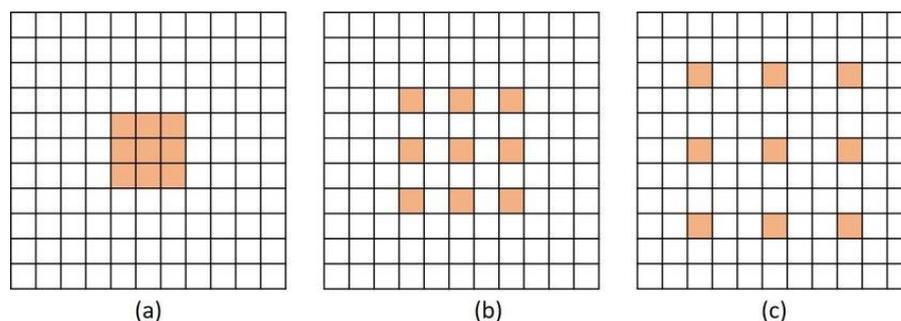
Fuente: Shivam, K., et al [16]

La arquitectura (a) presenta un grave problema: podemos observar que para cada x_{t+1} (cada elemento del *output*), el *input* es $x_{t-2}, x_{t-1}, \dots, x_{t+2}$. En el caso de series de tiempo, no tiene mucho sentido pronosticar variables utilizando sus valores futuros. Esto es arreglado en la red neuronal (b), llamada red causal. Sin embargo, esta presenta dos problemas nuevos. El primero es que cada elemento del *input* es recogido múltiples veces. En este ejemplo en particular, podemos apreciar que x_{t-1} es analizado dos veces en la red. El segundo problema es que si queremos ampliar el campo receptivo (el número de elementos del *input* que se utilizan para cada elemento del *output*), es necesario incrementar drásticamente el número de capas. Si deseamos un campo receptivo de tamaño r , el número de capas intermedias (también llamadas capas ocultas) es $r-2$.

Ambos problemas son solucionados con la red (c), llamada red dilatada. En esta podemos apreciar que el filtro se va separando o “dilatando” en cada capa (figura 8). En la figura 9 se observa lo que es la esencia de la red WaveNet. En esta la dilatación del filtro se duplica en cada capa. Esto le permite tener un amplio campo receptivo manteniendo un número bajo de capas (y por lo tanto de parámetros). **De hecho, la relación entre el campo receptivo y el número de capas es lineal en (b), pero exponencial en (c).** En forma de ecuación una convolución con dilatación d , es:

$$(u * v)_t = \sum_{\tau} u_{t-d\tau} v_{\tau} \tag{13}$$

Figura 8: Dilatación del filtro



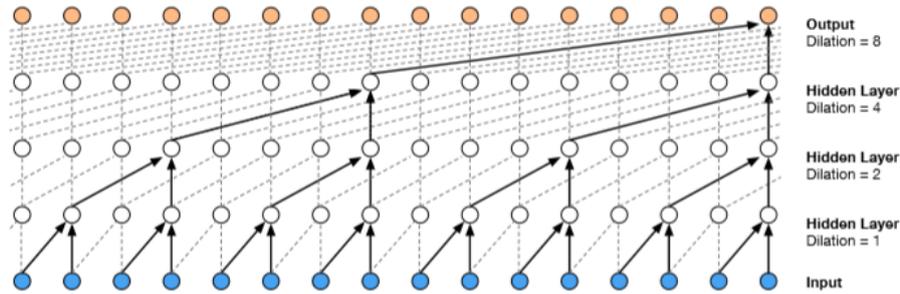
Fuente: Jeong, Y., et al [8].

4.5.1 Conexiones residuales

La red WaveNet incorpora algunas técnicas adicionales. Una de ellas es la creación de conexiones residuales en cada capa. Sea x el vector *input* de una capa, y $F(x)$ su

vector *output*, normalmente, $F(x)$ sería el *input* de la siguiente capa, pero al crear una conexión residual, hacemos que el siguiente input sea $H(x) = F(x) + x$.

Figura 9: Red neuronal WaveNet.



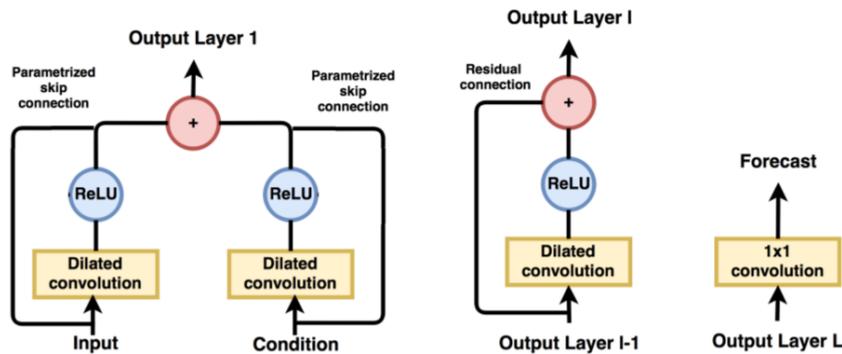
Fuente: van der Oord, A., et al [17].

4.5.2 WaveNet Condicional

Hasta ahora solo hemos cubierto una red WaveNet que pronostica el valor futuro de una variable utilizando los valores pasados de la misma. A esto se le conoce como WaveNet no condicional (uWN). Sin embargo, es posible crear una red que no solo utilice los valores pasados de la misma variable, sino que también los de otras variables. A esto se le llama una red WaveNet condicional (cWN). El procedimiento para condicionar una red utilizado por Borvykh, *et al* es una variante más simple del

original [18]. En la figura 10 vemos una representación visual de lo que sucede. Si x es la variable que queremos pronosticar y nuestra condición es la variable y , entonces el *output* de la primera capa es $F(x) + G(y) + cx + dx$, donde F y G son mapeos (convoluciones dilatadas seguidas por una función de activación) y c y d son convoluciones 1×1 . Condiciones adicionales tan solo se suman. Para las demás capas simplemente se aplican las conexiones residuales y en la última se aplica una convolución 1×1 .

Figura 10: Condicionamiento de una red WaveNet



Fuente: Borovykh, A., et al [1].

En la tabla 1 se puede ver escrito el modelo general en donde el *input* pasa por una secuencia de transformaciones antes de ser devuelto como *output*. Este toma como *input* la serie de tiempo a pronosticar $\mathbf{x}(t)$ (escrito como $\mathbf{x}(t)$ en lugar de \mathbf{x}_t por conveniencia) y una condición $\mathbf{y}(t)$, y su output será $\mathbf{x}(t+1)$. En esta tabla denota ℓ

número de capa, k el número de filtro (se utilizaron dos filtros en este trabajo), y τ la posición adentro del filtro (el ancho de todos los filtros fue 2). A \mathcal{F}_ℓ^k se le conoce como mapeo, y $d_\ell=2^{\ell-1}$ es la dilatación correspondiente de cada capa. Los parámetros entrenables son $g_\ell^k(\tau)$, b_ℓ^k , c^k , β^k , a^k y m^k .

Tabla 1: Modelo WaveNet General

ℓ (Capa)	\mathcal{F} (Mapeo)
0 (input)	$x(t), y(t)$
1	$\mathcal{F}_1^k(t) = \text{ReLU}\left(\sum_{\tau} x(t - d_1\tau)g_1^k(\tau) + b_1^k\right) + c^k x(t)$ $+ \text{ReLU}\left(\sum_{\tau} y(t - d_1\tau)h_1^k(\tau) + \beta^k\right) + a^k y(t)$
2	$\mathcal{F}_2^k(t) = \text{ReLU}\left(\sum_{\tau} \mathcal{F}_1^k(t - d_2\tau)g_2^k(\tau) + b_2^k\right) + \mathcal{F}_1^k(t)$
⋮	⋮
$L - 1$	$\mathcal{F}_{L-1}^k(t) = \text{ReLU}\left(\sum_{\tau} \mathcal{F}_{L-2}^k(t - d_{L-1}\tau)g_{L-1}^k(\tau) + b_{L-1}^k\right) + \mathcal{F}_{L-2}^k(t)$
L (output)	$x(t + 1) = \sum_k m^k \mathcal{F}_{L-1}^k(t)$

4.6. Especificaciones de los Modelos Implementados

En total se implementaron 4 distintas redes neuronales para este trabajo: dos para los datos diarios y dos para los datos mensuales. Para cada frecuencia de datos se implementó una no condicional y una condicional. Algunos hiperparámetros (parámetros elegidos por el usuario) son los mismos para todos los modelos: la función de activación siempre es ReLU, los valores inicia-

les de los parámetros son aleatorios, inicializados con el inicializador 'HE_NORMAL' y su función de pérdida es MSE. No obstante, algunas diferencias existen entre modelos, las cuales se listan en la tabla 2. El diagrama de la red WaveNet condicional para datos mensuales se encuentra en la figura 13.

Tabla 2: Especificaciones de los modelos implementados

	uWN(d)	cWN(d)	uWN(m)	cWN(m)
Campo receptivo	512	1024	16	48
Parámetros entrenables	46	54	26	42

5 | Otros modelos

Aparte del modelo de caminata aleatoria, también se implementaron otros modelos como punto de comparación para nuestra red neuronal. Para las series univariadas se implementó el modelo ARIMA, y para las series multivariadas se implementó el modelo ECM.

5.1 ARIMA

Sea x_t una serie de tiempo univariada con comportamiento estocástico, podemos acudir al uso de modelos autorregresivos para el estudio de su comportamiento. Enders [4] define un proceso autorregresivo de media móvil ARMA(p, q) como:

$$\left(1 - \sum_{i=1}^p \alpha_i L^i\right) x_t = \alpha_0 + \left(1 + \sum_{i=1}^q \beta_i L^i\right) \varepsilon_t \quad (14)$$

en donde α_0 , α_i y β_i son parámetros, $\varepsilon_t \sim N(0, 1)$, $E[\varepsilon_t \varepsilon_{t-s}] = 0 \forall t, s$ y L es el operador rezago ($L^i x_t = x_{t-i}$). Sin embargo, es posible que la serie de tiempo no sea estacionaria, es decir, tenga una tendencia. Una forma de solventar este problema es aplicando una transformación a los datos. Entre las más comunes se encuentra el operador diferencia $\Delta x_t = (1 - L)x_t = x_t - x_{t-1}$. Si esto no alcanza para convertir a una serie en estacionaria, el operador diferencia se puede aplicar múltiples veces, $\Delta^d x_t = (1 - L)^d x_t$. Podemos apreciar que si aplicamos el operador diferencia una o más veces

en ambos lados de (14), el término constante desaparecerá. Los demás parámetros permanecerán, no obstante. Luego de aplicar esta transformación, podemos llegar a la ecuación que describe el modelo ARIMA(p, d, q):

$$\left(1 - \sum_{i=1}^p \alpha_i L^i\right) (1 - L)^d x_t = \left(1 + \sum_{i=1}^q \beta_i L^i\right) \varepsilon_t \quad (15)$$

Una vez ajustados los valores de los parámetros, podemos utilizar este modelo para pronosticar el valor de x en $t+1$, es decir, \hat{x}_{t+1} . Realizando la prueba ADF, se determinó que s_t no es una serie estacionaria, pero Δs_t sí. Por lo que se eligió un orden $d = 1$. p y q se determinaron utilizando los criterios de información. Los criterios de información se pueden apreciar en las tablas 3 y 4 para los datos diarios y mensuales, respectivamente. Estos fueron utilizados para seleccionar el orden de los modelos. Para los datos diarios se implementó un modelo ARIMA(2,1,0) y para los mensuales un modelo ARIMA(1,1,0).

Tabla 3: Criterios de información para datos diarios

p	q	AIC	BIC	HQIC	p	q	AIC	BIC	HQIC
1	0	-2330.09	-2320.94	-2326.56	3	2	-2357.96	-2330.49	-2347.35
1	1	-2352.5	-2338.77	-2347.2	4	0	-2358.4	-2335.51	-2349.56
1	2	-2356.86	-2338.55	-2349.79	4	1	-2363.25	-2335.78	-2352.65
2	0	-2360.37	-2346.64	-2355.07	4	2	-2360.61	-2328.57	-2348.24
2	1	-2359.97	-2341.66	-2352.9	5	0	-2356.85	-2329.38	-2346.24
2	2	-2359.26	-2336.37	-2350.42	5	1	-2355.93	-2323.89	-2343.56
3	0	-2360.18	-2341.87	-2353.11	5	2	-2360.61	-2323.99	-2346.47
3	1	-2358.37	-2335.48	-2349.53					

El ajuste para los datos utilizados en este proyecto se llevó a cabo en Python, utilizando la librería statsmodels. Los resultados del ajuste se pueden encontrar en

las tablas 9 y 10. Los resultados del error de pronóstico se presentan en la sección 7.

Tabla 4: Criterios de información para datos mensuales

p	q	AIC	BIC	HQIC	p	q	AIC	BIC	HQIC
1	0	30.745	35.583	32.688	3	2	36.398	50.911	42.228
1	1	32.675	39.932	35.591	4	0	36.449	48.543	41.308
1	2	33.441	43.116	37.328	4	1	38.542	53.055	44.373
2	0	32.679	39.936	35.595	4	2	36.93	53.862	43.732
2	1	34.672	44.347	38.559	5	0	38.42	52.933	44.25
2	2	30.809	42.903	35.667	5	1	40.371	57.303	47.174
3	0	34.645	44.32	38.532	5	2	42.315	61.666	50.089
3	1	36.549	48.644	41.408					

5.2 ECM

De los 40 modelos de una sola ecuación estudiados por Rossi [15], 17 eran modelos de corrección de error (ECM). Por lo tanto, se optó por utilizar dicho modelo para las series multivariadas. De acuerdo con Enders [4], para

una variable endógena z_t y un conjunto de variables débilmente exógenas x_t^i (i es un índice, no un exponente), el ECM se define como:

$$\Delta z_t = \alpha_0 + \alpha_1 z_{t-1} + \beta \Delta z_{t-1} + \sum_i \beta_i x_{t-1}^i + \sum_i \gamma_i \Delta x_t^i + \sum_i \delta_i \Delta x_{t-1}^i \quad (16)$$

Para el modelo de frecuencia diaria se realizó una regresión multilineal para Δs_t utilizando las siguientes variables: s_{t-1} , Δs_{t-1} , $(i_{t-1} - i_{t-1}^*)$, $\Delta(i_{t-1} - i_{t-1}^*)$, $\Delta(i_{t-1}^* - i_{t-1}^*)$. Para el modelo que utiliza frecuencia mensual, también se realizó una regresión multilineal para Δs_t utilizando las mismas variables que el modelo anterior. Sin embargo, también se

agregaron otras variables, siendo estas: $(\pi_{t-1} - \pi_{t-1}^*)$, $\Delta(\pi_{t-1} - \pi_{t-1}^*)$, $\Delta(\pi_{t-1}^* - \pi_{t-1}^*)$. Para estos modelos, los resultados de sus regresiones se encuentran en las tablas 11 y 12. Las medidas de error se presentan en la sección 7.

6 Medidas alternativas de precisión de pronóstico

Entre las medidas más conocidas para el ajuste se encuentran: el promedio de errores cuadráticos (MSE), el promedio de errores absolutos (MAE), y el promedio de errores porcentuales absolutos (MAPE). Estas medidas no solo no son las únicas, sino que tampoco son las más útiles, especialmente desde el punto de vista de alguien como un inversionista, quien busca predecir si el precio

de un activo subirá o bajará. En este contexto, predecir si el tipo de cambio subirá o bajará es de particular relevancia para alguien que invierte en divisas. A continuación introducimos dos medidas que evalúan qué tan bien se puede pronosticar la dirección del cambio. Estas son la precisión direccional y la prueba de Pesaran y Timmermann.

6.1 Precisión direccional

La precisión direccional (DA) es una medida sencilla, simplemente cuenta la fracción de veces que un modelo pronostica correctamente la dirección del cambio en una variable, es decir, si esta incrementará o caerá. Esta se define como:

$$DA = \frac{1}{n} \sum H(\Delta \hat{x}_t \Delta x_t) \quad (17)$$

donde:
$$H(x) = \begin{cases} 0 & x \leq 0 \\ 1 & x > 0 \end{cases}$$

es la función Heaviside, $\Delta \hat{x}_t = \hat{x}_{t+1} - x_t$ y n es el número de observaciones.

6.2. Prueba de Pesaran y Timmermann

Hashem Pesaran y Allan Timmermann [14] construyeron una simple prueba para determinar si una serie de tiempo pronostica realmente la dirección del cambio de otra. Esta prueba funciona incluso cuando se desconoce la distribución de las variables incorporadas y es capaz de

generalizarse para más de dos variables. En esta prueba la hipótesis nula es que una serie no es capaz de pronosticar el cambio de la otra y, por lo tanto, idealmente buscamos rechazarla. El estadístico de la prueba se define como:

$$PT = \frac{\hat{P} - \hat{P}^*}{\sqrt{\widehat{Var}(\hat{P}) - \widehat{Var}(\hat{P}^*)}} \sim N(0,1) \quad (17)$$

donde:

$$\hat{P} = DA$$

$$\hat{P}^* = P_x P_y + (1 - P_x)(1 - P_y)$$

$$\widehat{Var}(\hat{P}) = \frac{\hat{P}^*(1 - \hat{P}^*)}{n}$$

$$\widehat{Var}(\hat{P}^*) = (2P_x - 1)^2 q_y + (2P_y - 1)^2 q_x + 4q_x q_y$$

$$P_x = \frac{1}{n} \sum H(\Delta \hat{x}_t)$$

$$P_y = \frac{1}{n} \sum H(\Delta x_t)$$

$$q_x = \frac{p_x(1 - p_x)}{n}$$

$$q_y = \frac{p_y(1 - p_y)}{n}$$

Una gran ventaja de este estadístico es que se distribuye asintóticamente como una distribución normal estándar, por lo que es fácil interpretarlo. Por ejemplo, si tiene un valor de 1.64 o mayor, basta para rechazar la hipótesis

nula a un nivel de significancia de 10%. Tanto la prueba PT como la DA fueron incorporadas en este proyecto, los resultados finales son presentados en la sección 7.

7 | Resultados

7.1. Datos diarios

Podemos apreciar en la tabla 5 que para los pronósticos adentro de la muestra, el modelo de caminata aleatoria (RW) es superado por todos los demás. Aparte de eso, todos los modelos resultaron aproximadamente en lo mismo. En general, el modelo que tuvo el mejor desempeño fue la red WaveNet no condicional (uWN).

Para los pronósticos afuera de la muestra (tabla 6), podemos ver que los modelos ARIMA, ECM y uWN superan

la caminata aleatoria. No obstante, el modelo WaveNet condicional (cWN) es muchísimo peor que cualquiera de los demás modelos. Es probable que esto se deba a la muy alta volatilidad que presenta el diferencial de tasas de interés a principio de 2016. Por otro lado, el resto tiene un desempeño similar, siendo el modelo uWN el que tiene el mejor desempeño en general. En la figura 11 se aprecian los residuos.

Tabla 5: Medidas de precisión para datos diarios adentro de la muestra

Los mejores resultados para cada medida de precisión fueron resaltados en **negrilla**.

MODELO	MSE	MAE	MAPE	DA	PT
RW	0.0031	0.0415	1.0302	0	0
ARIMA	0.0022	0.0357	0.6746	0.6982	10.5961
ECM	0.0022	0.0357	0.6713	0.6769	9.4276
uWN	0.0021	0.0351	0.5995	0.7038	10.9286
cWN	0.0022	0.0356	0.6867	0.6829	9.7641

Tabla 6: Medidas de precisión para datos diarios afuera de la muestra

Los mejores resultados para cada medida de precisión fueron resaltados en **negrilla**.

MODELO	MSE	MAE	MAPE	DA	PT
RW	0.0019	0.0324	0.7958	0	0
ARIMA	0.0013	0.0267	0.8113	0.7083	4.5928
ECM	0.0013	0.027	0.7944	0.7583	5.6945
uWN	0.0013	0.026	0.7474	0.7667	5.8728
cWN	0.1135	0.0758	1.5389	0.725	4.9741

7.2. Datos mensuales

Para los datos mensuales adentro de la muestra (tabla 7), la red WaveNet condicional obtuvo por mucho el mejor ajuste, seguido cercanamente por la red no condicional. Esto se puede apreciar de manera más fácil en el estadístico PT, que nos dice que estos modelos son capaces de pronosticar la dirección de cambio (adentro de la muestra), mientras que los demás modelos son incapaces.

Todo cambia en el caso de los datos afuera de la muestra (tabla 8), en donde el modelo ECM es por mucho el

mejor modelo, con el mejor ajuste y la mayor capacidad predictiva. Vale la pena mencionar que los datos afuera de la muestra consisten en tan solo nueve observaciones, por lo que el estadístico PT puede que no revele mucho sobre la capacidad predictiva de los modelos, debido a que este se basa bajo la premisa que es asintóticamente igual a una distribución normal estándar, y nueve observaciones puede que no sean suficientes. La figura 12 muestra una gráfica de los residuos.

Tabla 7: Medidas de precisión para datos mensuales adentro de la muestra

Los mejores resultados para cada medida de precisión fueron resaltados en **negrilla**.

MODELO	MSE	MAE	MAPE	DA	PT
RW	0.0817	0.2134	1.0879	0	0
ARIMA	0.0808	0.2117	1.4166	0.5663	1.1201
ECM	0.0757	0.2097	1.3288	0.5854	1.5404
uWN	0.0572	0.1889	0.7378	0.7229	3.9953
cWN	0.038	0.1465	0.6679	0.759	4.8784

Tabla 8: Medidas de precisión para datos mensuales afuera de la muestra

Los mejores resultados para cada medida de precisión fueron resaltados en **negrilla**.

MODELO	MSE	MAE	MAPE	DA	PT
RW	0.0269	0.1353	0.388	0	0
ARIMA	0.027	0.1371	0.3979	0.6667	0.6013
ECM	0.0253	0.1349	0.3785	0.6667	1.5213
uWN	0.053	0.1742	0.3869	0.3333	0.6013
cWN	0.0916	0.2617	0.6471	0.2222	-1.136

Figura 11: Residuos para modelos diarios

La línea roja separa las observaciones adentro y afuera de la muestra. El modelo WaveNet condicional muestra residuos inusualmente grandes afuera de la muestra.

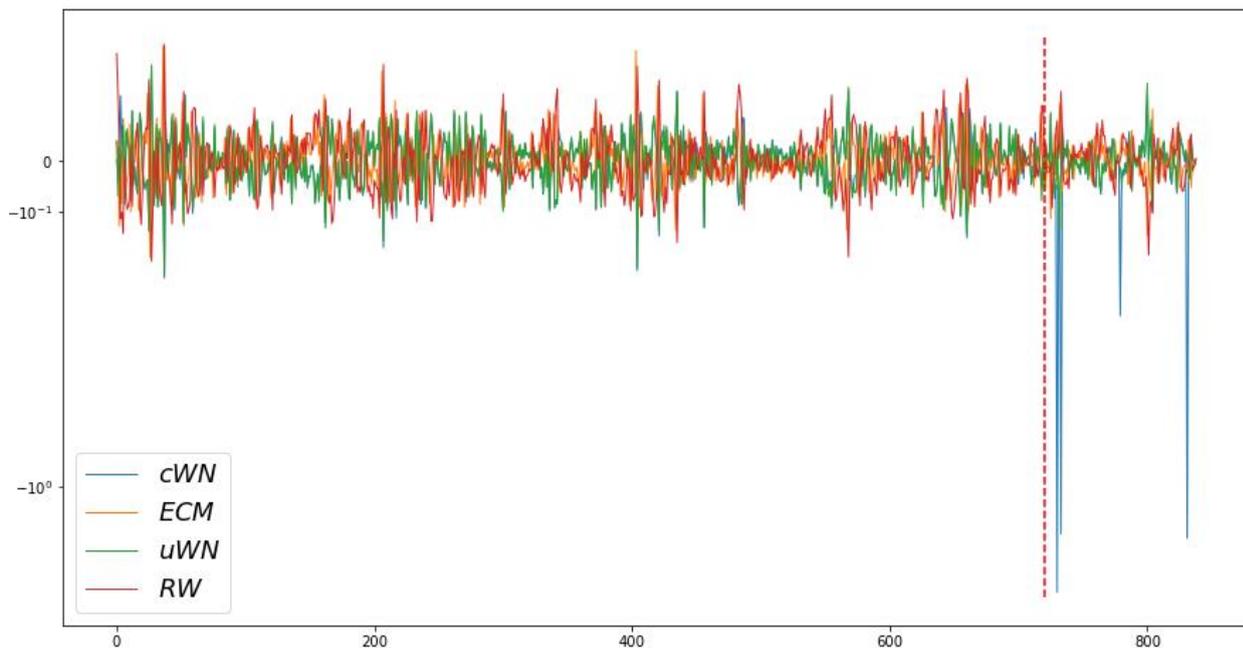
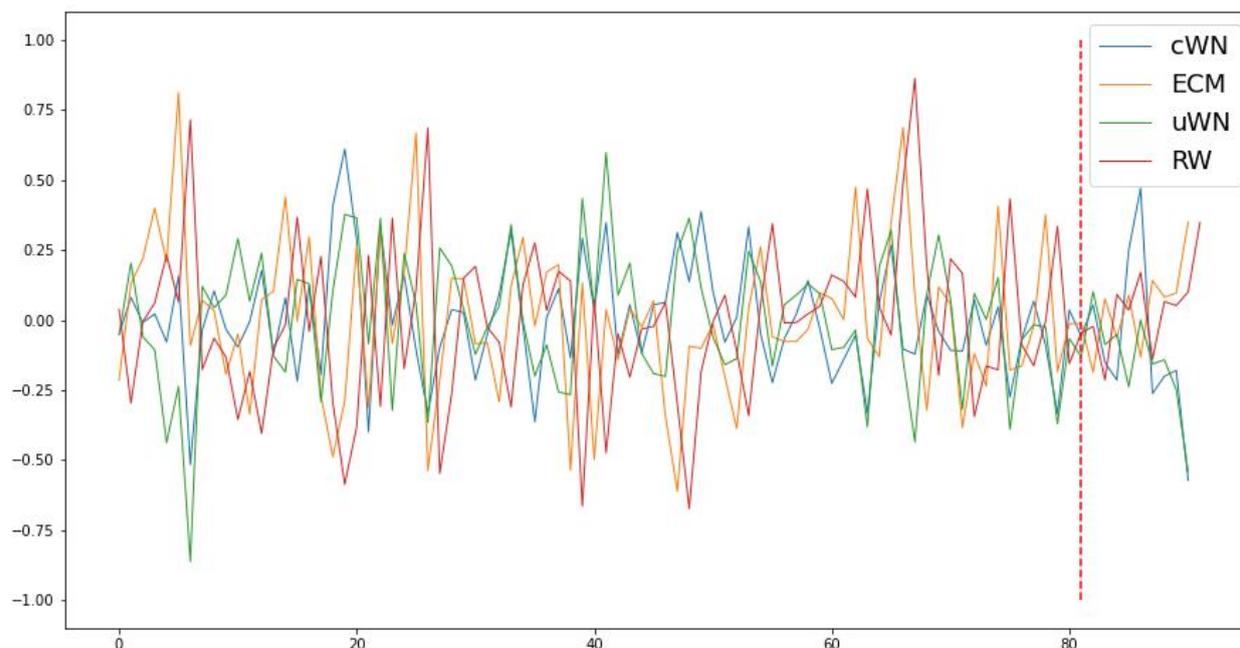


Figura 12: Residuos para modelos mensuales

La línea roja separa las observaciones adentro y afuera de la muestra.



8 | Análisis de resultados y discusión

Hemos visto que el modelo red neuronal WaveNet es capaz de igualar (si no es que superar) a los demás modelos en tres de las cuatro situaciones, siendo este superado por el modelo ECM para datos mensuales afuera de la muestra. La red WaveNet condicional fue la peor entre todos los modelos para datos afuera de la muestra. En la figura 11 se ve que esta exhibe residuos mucho más grandes que el resto. Es posible que esto sea causado por la alta volatilidad que presenta el diferencial de tasas de interés a partir del inicio de 2016 (figura 1). No obstante, no es posible realizar una prueba para demostrar que este es estadísticamente diferente, ya que la prueba de Diebold y Mariano está específicamente diseñada para horizontes de pronóstico mayores a uno. La prueba de Clark y West tampoco es útil, ya que requiere que los modelos a comparar sean anidados.

Por otro lado, la red WaveNet tiene la ventaja de ser fácil de implementar y ser extremadamente flexible. Esta es capaz de tomar el lugar tanto de modelos univariados, como el ARIMA, y multivariados, como el ECM. Con unos

pocos cambios a su código también podrá tomar el lugar de modelos con múltiples variables endógenas como un modelo VAR. Tampoco es necesario desestacionalizar ni eliminar tendencia, por lo que puede tomar el lugar de modelos como SARIMA, etc.

El modelo WaveNet también es engañosamente parsimonioso. Para ilustrar esto, tomemos como ejemplo el modelo WaveNet condicional para datos mensuales. Este es el que tiene el mayor número de parámetros entre todos los modelos en este trabajo, teniendo 54. Sin embargo, este abarca 1024 variables. Por lo que en términos de cuantos parámetros se tienen en relación al número de variables, este es el segundo más sencillo, únicamente detrás del modelo de caminata aleatoria, el cual no tiene parámetros. Otra ventaja extremadamente importante que tienen las redes neuronales es su capacidad de aprender relaciones no lineales entre las variables. Esto es algo que ni el modelo ARIMA ni el ECM pueden hacer.

En el otro extremo, la máxima desventaja es que estas redes son lo que comúnmente se conoce como una “caja negra”. Esto quiere decir que no nos permiten aprender nada sobre cómo se relacionan las variables si es que intentamos examinar su interior. Son capaces de cumplir su objetivo, pero no aprenderemos nada de cómo lo hacen. Otra desventaja es que es necesario asignar valores iniciales a los parámetros. Estos valores iniciales normalmente son aleatorios, y es posible que la red encuentre convergencia en un mínimo local en lugar del mínimo global y, por lo tanto, el pronóstico no será el óptimo.

Para futuros proyectos, en lugar de pronosticar en $t + 1$, podemos pronosticar en $t + h$. Esto es verdaderamente sencillo de implementar en la red WaveNet, y nos permitirá realizar la prueba de Diebold y Mariano. También podemos implementar otros cambios. Por ejemplo, en este proyecto la función de pérdida es el promedio de errores cuadráticos. No obstante, la red es tan versátil, que podemos cambiar la función de pérdida por cualquier otra. Esta puede ser la precisión direccional o incluso el estadístico de Pesaran y Timmerman.

9 | Conclusiones

Los modelos WaveNet presentan el mejor ajuste en la mayoría de los casos, a excepción del período afuera de la muestra para los datos mensuales.

En los mismos tres períodos, se rechaza la hipótesis nula de la prueba de Pesaran y Timmermann para los modelos WaveNet. Por lo tanto, sus pronósticos son diferentes al del modelo de caminata aleatoria debido a que contienen información sobre la dirección del cambio del tipo de cambio.

Referencias

- [1] Borovyk, A., Bohte, S., Oosterlee, C. W. (2018). Conditional Time Series Forecasting with Convolutional Neural Networks. arXiv:1703.04691v5 [stat.ML]
- [2] Cassel, G. (1918). Abnormal Deviations in International Exchanges. *Economic Journal*, 28, 413-15.
- [3] Cheung, Y., Chinn, M. D., Pascual, A. (2005). Empirical Exchange Rate Models for the Nineties: Are Any Fit to Survive? *Journal of International Money and Finance*. 24(7), 1150-75.
- [4] Enders, W. (2014). *Applied Econometric Time Series*, 4a. edición. John Wiley & Sons, Inc.
- [5] Fisher, I. (1896). *Appreciation and Interest*. Nueva York. The Macmillan Company.
- [6] Gerón, A. (2019). *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow*. 2a. edición O'Reilly Media, Inc.
- [7] He, K., Zhang, X., Ren, S., Sun, J. (2015). Deep Residual Learning for Image Recognition. arXiv:1512.03385v1 [cs.CV]
- [8] Jeong, Y., et al (2019). Dilated Saliency U-Net for White Matter Hyperintensities Segmentation Using Irregularity Age Map. *Frontiers in Aging Neuroscience*, 11, 150.
- [9] Meese, R. A., Rogoff, K. S. (1983a), Empirical Exchange Rate Models of the Seventies: Do They Fit Out of Sample? *Journal of International Economics*. 14(1- 2), 3-24.
- [10] Meese, R. A., Rogoff, K. S. (1988). Was It Real? The Exchange Rate-Interest Differential Relation over the Modern Floating-Rate Period. *Journal of Finance*. 43(4). 933-48. 30.
- [11] Molodtsova, T., Papell, D. (2009). Out-of-Sample Exchange Rate predictability with Taylor Rule Fundamentals. *Journal of International Economics*. 77(2), 167-80.
- [12] Moosa, I. A. (2013). Why is it so difficult to outperform the random walk in exchange rate forecasting? *Applied Economics*, 45(23), 3340-46.
- [13] Moosa, I. A., Burns, K. (2014). The Unbeatable Random Walk in Exchange Rate Forecasting: Reality or Myth? *Journal of Macroeconomics*, 40, 69-81.
- [14] Pesaran, M. H., Timermann, A. (1992). A Simple Nonparametric Test of Predictive Performance. *Journal of Business & Economic Statistics*, 10(4), 461-65.
- [15] Rossi, B. (2013). Exchange Rate Predictability. *Journal of Economic Literature*, 51(4), 1063-119.
- [16] Shivam, K., Tzou, J., Wu, S. (2020). Multi-Step Short-Term Wind Speed Prediction Using a Residual Dilated Causal Convolutional Network with Nonlinear Attention. *Energies*, 13(7), 1172.
- [17] van der Oord, A., et al (2016). WaveNet: A Generative Model for Raw Audio. arXiv:1609.03499v2 [cs.SD]
- [18] van der Oord, A., et al (2016). Conditional Image Generation with PixelCNN Decoders. arXiv:1606.05328v2 [cs.CV]
- [19] Zang, S., Lowinger, T. C., Tang, J. (2007). The Monetary Exchange Rate Model: Long-Run, Short-Run, and Forecasting Performance. *Journal of Economic Integration*, 22(2), 397-40.

Anexos

A Código de Python para red neuronal WaveNet

sea r el campo receptivo y sea n_cond el número adicional de series de tiempo que queremos agregar a la red para condicionarla, el código utilizado en este trabajo es:

```
from keras.models import Model
from keras.layers import Input, Activation
from keras.layers import Add
from keras.optimizers import Adam
from keras.layers.convolutional import Conv1D
X_input = {}
X_skip = {}
X_conv = {}
for i in range(n_cond + 1):
    X_input[str(i)] = Input(shape=(None, 1))
    X_skip[str(i)] = Conv1D(1, 1, padding='causal',
        kernel_initializer='he_normal')(X_input[str(i)])
    X_conv[str(i)] = Conv1D(filters=1, kernel_size=2,
        padding='causal',
            dilation_rate=1)(X_input[str(i)])
    X_conv[str(i)] = Activation('relu')(X_conv[str(i)])
z = Add()(list(X_conv.values())+list(X_skip.values()))
for rate in [2**i for i in range(1,int(np.log2(r/2)+1))]:
    z_d = Conv1D(filters=1, kernel_size=2, padding='causal',
        dilation_rate=rate, kernel_initializer='he_normal')(z)
    z_d = Activation('relu')(z_d)
    z = Add()([z_d, z])
z = Conv1D(1, 1, padding='causal', kernel_initializer
='he_normal')(z)
wavenet = Model(inputs=list(X_input.values()), outputs=z)
wavenet.compile(Adam(), loss='mse')
```

Para utilizar este código es necesario transformar los datos para que tengan forma de tensores (arreglos de datos en tres dimensiones). Si nuestra serie de tiempo es \mathbf{x}_t^1 con n observaciones de longitud, debemos “cambiarle la forma”:

```
X1 = x1.reshape(1,n,1)[0, :-1, 0]
```

De manera similar, la red se tiene que ajustar al valor que trata de pronosticar (en nuestro caso \mathbf{x}_{t+1}). Si y es \mathbf{x}_{t+1} , esta serie también tiene que ser transformada:

```
Y = y.reshape(1,n,1)[0, 1:, 0]
```

En el caso de $X1$ podemos ver que se excluye la última observación y en el caso de Y , se excluye la primera. Esto es intencional para que exista un desfase entre las series. Para ajustar el modelo se utiliza el siguiente código:

```
wavenet.fit(X,Y, epochs=N_ITER)
```

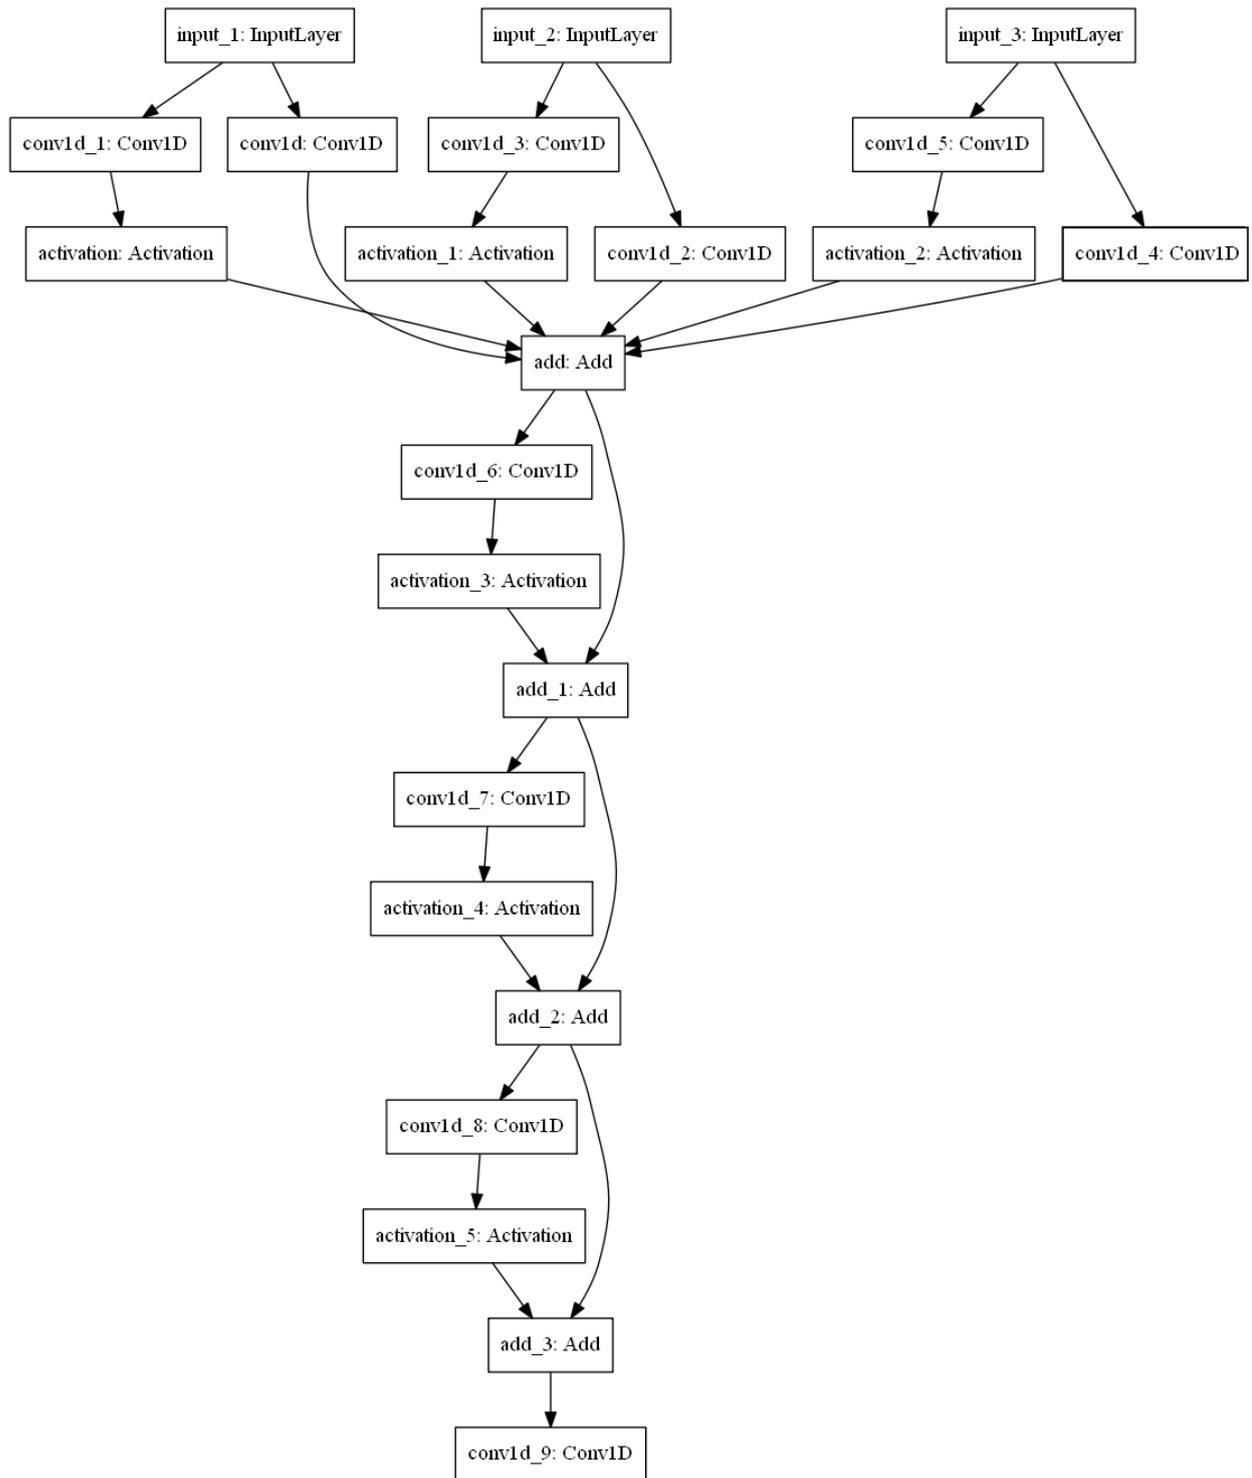
en donde N_ITER es el número de iteraciones que deseamos (20,000 en este trabajo) y $X = [X1, X2, \dots, XN]$, donde $X2, \dots, XN$ son las series de tiempo adicionales a las que se desea condicionar la red. Para realizar un pronóstico:

```
wavent.predict(X)
```

donde X es el conjunto de las series para las cuales queremos pronosticar en $t+1$.

B Diagrama del modelo WaveNet

Figura 13: Diagrama de WaveNet condicional para datos mensuales



C Tablas de resultados para modelos ARIMA y ECM

Tabla 9: Resultados de regresión ARIMA para datos diarios

ARMA Model Results						
Dep. Variable:	y	No. Observations:	719			
Model:	ARMA(2, 0)	Log Likelihood	1183.186			
Method:	css-mle	S.D. of innovations	0.047			
Date:	Tue, 27 Oct 2020	AIC	-2360.372			
Time:	23:25:19	BIC	-2346.639			
Sample:	0	HQIC	-2355.070			
	coef	std err	z	P> z	[0.025	0.975]
ar.L1.y	0.6146	0.037	16.717	0.000	0.543	0.687
ar.L2.y	-0.2120	0.037	-5.747	0.000	-0.284	-0.140
Roots						
	Real	Imaginary	Modulus	Frequency		
AR.1	1.4495	-1.6173j	2.1717	-0.1337		
AR.2	1.4495	+1.6173j	2.1717	0.1337		

Tabla 10: Resultados de regresión ARIMA para datos mensuales

ARMA Model Results						
Dep. Variable:	y	No. Observations:	719			
Model:	ARMA(2, 0)	Log Likelihood	1183.186			
Method:	css-mle	S.D. of innovations	0.047			
Date:	Tue, 27 Oct 2020	AIC	-2360.372			
Time:	23:25:19	BIC	-2346.639			
Sample:	0	HQIC	-2355.070			
	coef	std err	z	P> z	[0.025	0.975]
ar.L1.y	0.1049	0.108	0.967	0.334	-0.108	0.318
Roots						
	Real	Imaginary	Modulus	Frequency		
AR.1	9.5350	+0.0000j	9.5350	0.0000		

Tabla 11: Resultados de ECM para datos diarios

OLS Regression Results						
	coef	std err	t	P> z	[0.025	0.975]
Dep. Variable:	ds			R-squared:	0.262	
Model:	OLS			Adj. R-squared:	0.257	
Method:	Least Squares			F-statistic:	50.67	
Date:	Tue, 27 Oct 2020			Prob (F-statistic):	5.95e-45	
Time:	21:58:32			Log-Likelihood:	1177.3	
No. Observations:	718			AIC:	-2343.0	
Df Residuals:	712			BIC:	-2315.0	
Df Model:	5					
Covariance Type:	nonrobust					
const	0.0037	0.003	1.386	0.166	-0.002	0.009
s-1	-0.0109	0.004	-2.924	0.004	-0.018	-0.004
i-1	0.0046	0.003	1.473	0.141	-0.002	0.011
di	0.0065	0.006	1.103	0.271	-0.005	0.018
ds-1	0.5029	0.032	15.719	0.000	0.440	0.566
di-1	0.0012	0.006	0.208	0.836	-0.01	0.013
Omnibus:	42.272			Durbin-Watson:	1.797	
Prob(Omnibus):	0.000			Jarque-Bera (JB):	88.740	
Skew:	0.355			Prob (JB):	5.38e-20	
Kurtosis:	4.569			Cond. No.:	26.3	

Tabla 12: Resultados de ECM para datos mensuales

OLS Regression Results						
	coef	std err	t	P> z	[0.025	0.975]
Dep. Variable:	ds			R-squared:	0.084	
Model:	OLS			Adj. R-squared:	-0.016	
Method:	Least Squares			F-statistic:	0.8373	
Date:	Tue, 27 Oct 2020			Prob (F-statistic):	0.573	
Time:	19:03:45			Log-Likelihood:	-10.509	
No. Observations:	82			AIC:	39.02	
Df Residuals:	73			BIC:	60.68	
Df Model:	5					
Covariance Type:	nonrobust					
const	-0.0072	0.032	-0.223	0.824	-0.072	0.057
s-1	-0.0404	0.037	-1.086	0.281	-0.114	0.034
i-1	-0.0549	0.042	-1.322	0.19	-0.138	0.028
pi-1	0.0033	0.043	0.078	0.938	-0.082	0.088
di	-0.0042	0.044	-0.094	0.926	-0.093	0.084
dpi	0.0929	0.119	0.784	0.436	-0.143	0.329
ds-1	0.0764	0.119	0.644	0.522	-0.16	0.313
di-1	0.052	0.044	1.184	0.24	-0.036	0.14
dpi-1	-0.0215	0.118	-0.182	0.856	-0.257	0.214
Omnibus:	3.020			Durbin-Watson:	1.937	
Prob(Omnibus):	0.221			Jarque-Bera (JB):	2.276	
Skew:	0.336			Prob (JB):	0.320	
Kurtosis:	3.465			Cond. No.:	5.88	

Estimación de pobreza a nivel municipal en Guatemala mediante la utilización de “machine learning”*

*Walter Figueroa‡
Mark Peñate†
Paolo Marsicovetere‡*

En países como Guatemala, la medición de la pobreza es una práctica poco común y frecuente; de hecho, el país es el único en Latinoamérica donde la pobreza se mide aun quinquenalmente. Además de ello, la medición de la pobreza en Guatemala cuenta con poca representatividad territorial, desagregando información solo a nivel de departamento. La última medición se realizó en 2014 mediante la Encuesta de Condiciones de Vida (Encovi), mientras que la última medición de pobreza a nivel municipal se efectuó en 2002. En este sentido, debido a los altos índices de pobreza del país, la política pública requiere de datos actualizados, precisos y desagregados territorialmente. El avance de métodos computacionales, como el aprendizaje de máquinas (“machine learning”), ha permitido disponer de herramientas potentes, algunas de las cuales pueden ser aplicables a la medición de pobreza. La aplicación de estos méto-

dos contribuye en sobremanera a reducir los altos costos que podría implicar una eventual medición de pobreza municipal. En virtud de ello, el presente estudio realiza una medición de pobreza municipal, mediante el método de algoritmos supervisados “random forest”, los cuales han sido entrenados con información de la Encovi 2014 y para así poder predecir la pobreza mediante los resultados del XII Censo Nacional de Población y VII de Vivienda. Los hallazgos señalan una reducción en la pobreza general de 59.3% reportado en la Encovi 2014 a un 54.1% estimado con el Censo 2018, así como una mejora en los niveles de pobreza extrema, de 23.4% a 20.6%, respectivamente. Sin embargo, en su distribución geográfica, la pobreza continúa siendo un flagelo que afecta principalmente al noroccidente del país, habitado principalmente por personas indígenas, donde la pobreza supera inclusive el 70%.

‡ Economista de la Universidad de San Carlos de Guatemala, con estudios de Maestría en Métodos Cuantitativos de la Banca Central de Guatemala y la Universidad Rafael Landívar.

† Economista de la Universidad de San Carlos de Guatemala, con estudios de Maestría en Política Fiscal para el Desarrollo de la Universidad Rafael Landívar

‡ Físico de la Universidad del Valle de Guatemala

* Versión preliminar

Introducción

La medición de la pobreza es una práctica poco común en países en vías de desarrollo. Según datos del CEDLAS y del Banco Mundial, Guatemala es el único país latinoamericano que realiza mediciones de pobreza quinquenales, pues en la mayoría de países restantes, la medición de la pobreza posee una frecuencia anual. La última Encuesta de Condiciones de Vida realizada en 2014 (Encovi 2014) muestra que al menos 59.3% de la población total se encontraba en pobreza y 23.4% en pobreza extrema, pero esta información solo puede ser desagregada a nivel departamental, dificultando así el diseño de políticas públicas en aquellos municipios donde la pobreza es sumamente severa. En este sentido, resulta necesario contar con mayor precisión y detalle en la medición de la pobreza, con la finalidad que la política pública sea diseñada con mayor nivel de precisión. De hecho, la última medición de pobreza municipal en Guatemala data de 2002, mediante un esfuerzo realizado por la Secretaría de Planificación y Programación de la Presidencia (Segeplan) y el Instituto Nacional de Estadísticas (INE), con apoyo de organismos internacionales.

En este sentido, el avance de los métodos computacionales implica una ventana de oportunidades, a fin de contar con que impliquen un menor costo y una mayor riqueza de desagregación territorial, entre estos los municipios y, en el mejor de los casos, lugares poblados.

De esa cuenta, el presente estudio es un esfuerzo de medición de pobreza municipal mediante un método de “machine learning” de algoritmos supervisados denominado “random forest”. En términos generales, el método consiste en un entrenamiento de algoritmos realizado con la Encovi 2014 que posteriormente es utilizado para estimar la pobreza según la información del Censo 2018. Los resultados muestran que, a nivel nacional, la pobreza general disminuye de un 59.3%, según lo reportado por la Encovi, a un 54.1%, según lo estimado mediante el censo 2018. Los resultados además evidencian que el noroccidente del país, cuyos habitantes son en mayoría indígenas, continúa siendo el lugar donde la pobreza se manifiesta con mayor severidad, con niveles por arriba del 70% de pobreza general.

En este sentido, el primer apartado de la investigación muestra los principales antecedentes y situaciones que han servido de motivación para la elaboración de este estudio. Seguidamente, se realiza una exposición de la metodología utilizada. Posterior a ello, se muestran los principales resultados derivados del estudio, desagregados a nivel nacional, departamental y municipal. Finalmente, se exponen una serie de reflexiones y conclusiones derivadas de lo anterior.

1 | Antecedentes

En países en desarrollo, la medición de la pobreza se caracteriza por tener una frecuencia temporal bastante baja. En el caso particular de Guatemala, la referida medición se realiza con un espacio temporal de, aproximadamente, cinco años. En la actualidad, la más reciente información sobre mediciones de pobreza corresponde a 2014, la cual se efectuó mediante la Encuesta de Condiciones de Vida (Encovi).

Según información de la base de datos de indicadores socioeconómicos del Centro de Estudios Distributivos, Laborales y Sociales (CEDLAS) y del Banco Mundial, Guatemala es el único país latinoamericano donde la medición de la pobreza se realiza quinquenalmente, a diferencia de los países restantes con mediciones anuales, bianuales y trianuales (ver tabla 1).

Tabla 1. Medición de la pobreza en América Latina (países seleccionados)

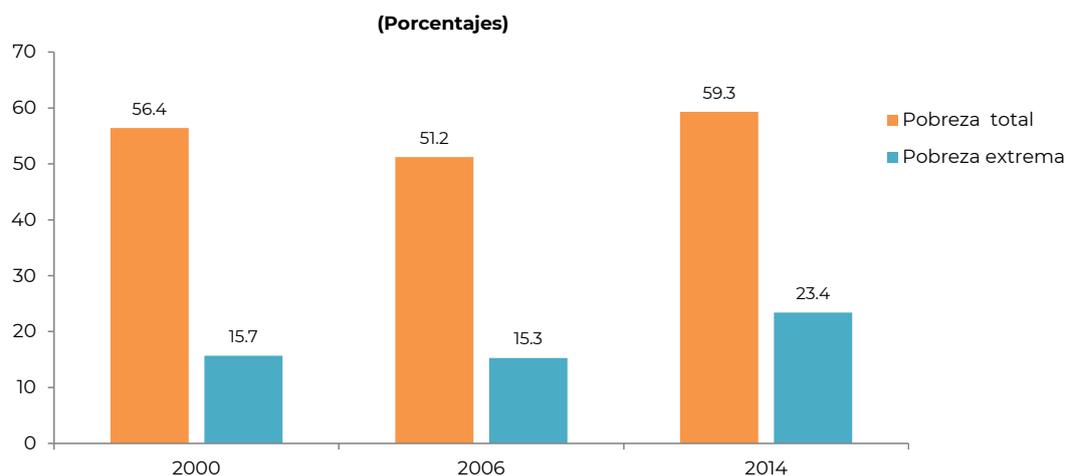
País	Encuesta	Periodicidad
Argentina	Encuesta Permanente de Hogares - Continua	Bianual
Bolivia	Encuesta de hogares	Anual
Brasil	Encuesta Nacional de Hogares	Anual
Chile	Encuesta de Caracterización Socioeconómica Nacional	Bianual - trianual
Colombia	Gran Encuesta Integrada de Hogares	Anual
Costa Rica	Encuesta Nacional de Hogares	Anual
Ecuador	Encuesta de Empleo, Desempleo y Subempleo	Anual
El Salvador	Encuesta de Hogares de Propósitos Múltiples	Anual
Guatemala	Encuesta Nacional de Condiciones de Vida	Quinquenal
Honduras	Encuesta Permanente de Hogares de Propósitos Múltiples	Anual
México	Encuesta Nacional de Ingreso y Gasto de Hogares	Bianual
Panamá	Encuesta de Hogares	Anual
Paraguay	Encuesta Permanente de Hogares	Anual
Perú	Encuesta Nacional de Hogares	Anual
República Dominicana	Encuesta Nacional de Fuerza de Trabajo	Anual
Uruguay	Encuesta Continua de Hogares	Anual
Venezuela	Encuesta de Hogares por Muestreo	Anual

Fuente: Elaboración propia con información de Socio-Economic Database for Latin America and the Caribbean (CEDLAS and The World Bank).

De acuerdo con la Encovi 2014, los niveles de pobreza en el país son altos, ya que de cada 10 guatemaltecos, aproximadamente 6 se encuentran en situación de pobreza;

y 2 en situación de pobreza extrema. Desafortunadamente, las mediciones reflejan que en los últimos 15 años la pobreza ha aumentado (ver gráfica 1).

Gráfica 1. Incidencia de la pobreza total y extrema, años 2000, 2006 y 2014

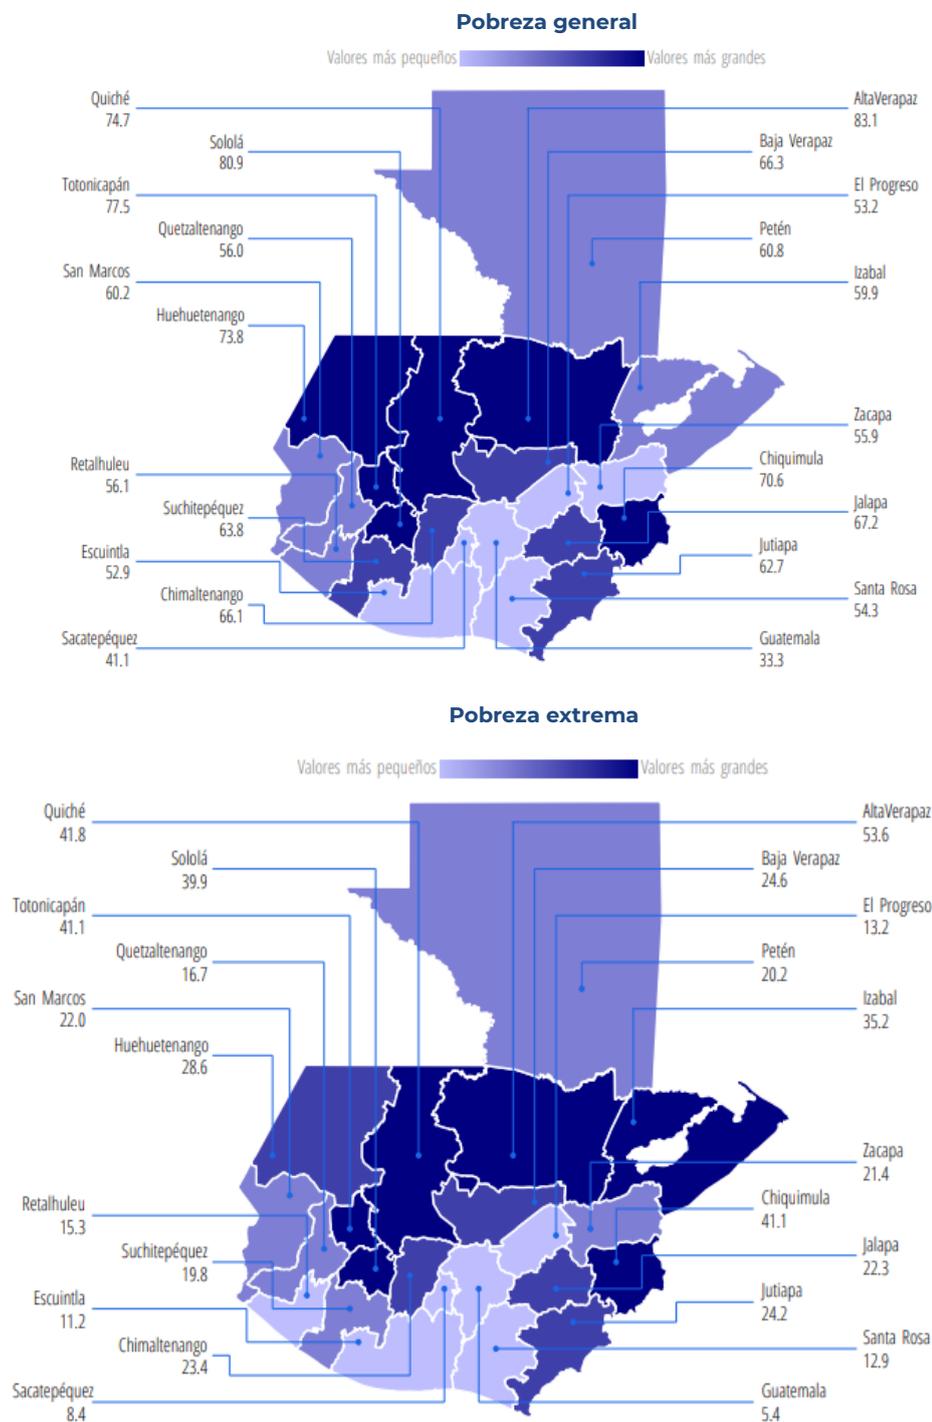


Fuente: Elaboración propia con información del INE / Encovi 2014.

A la limitación relativa a la frecuencia de la medición de pobreza en Guatemala, se une el hecho que la misma solamente cuenta con representatividad a nivel departamental. Ambas limitaciones implican restricciones en la revisión, reforma, monitoreo, evaluación y construcción de políticas públicas, sobre todo de aquellas diseñadas

para luchar contra la pobreza. Por ello, la falta de precisión en las mediciones de pobreza juega un papel adverso ante la efectividad y eficiencia de las intervenciones en materia de pobreza que, dicho sea de paso, perjudican mayormente a la niñez, grupos indígenas y zonas rurales del país.

Mapa 1: Incidencia de la pobreza total y extrema, año 2014



Fuente: Encuesta Nacional de Condiciones de Vida, 2014. Instituto Nacional de Estadística (INE).

La Encovi 2014 señala, además, que el área del altiplano occidental es donde la pobreza (sea en términos de pobreza total o pobreza extrema) golpea con más intensidad a las personas. Por ejemplo, en el departamento de Alta Verapaz se registran los niveles más alarmantes: más de la mitad de sus habitantes se encontraba en pobreza extrema y más del 80% en situación de pobreza. Si bien la información a nivel departamental podría reflejar asimetrías importantes y valiosas para la política pública (y las intervenciones que de esta pueden derivarse), resulta conveniente contar con mayor detalle de información, toda vez que al interior de los departamentos –entiéndase municipios y lugares poblados– existen también asimetrías y, consecuentemente, espacios en los que se requiere de intervenciones urgentes y con mayor intensidad.

Teniendo en consideración lo anterior, en Guatemala se han realizado esfuerzos para contar con mapas de pobreza a nivel municipal. Uno de ellos fue realizado en 2002, cuando el Banco Mundial, el Instituto Nacional de Estadística (INE) y la Secretaría de Planificación

y Programación de la Presidencia (Segeplan), usando información de la Encovi del año 2000 y del XI censo de población y VI de vivienda, estimaron los niveles de pobreza total y de pobreza extrema para los municipios existentes en ese entonces (331). En adición, en el año 2013 se publicó otro esfuerzo de esa naturaleza, esta vez concentrado en áreas rurales, utilizando la Encovi del año 2011 y los censos municipales rurales del período 2008-2011.

Desde entonces no han sido publicados mapas de pobreza, principalmente debido a la falta de información a nivel municipal actualizada. No obstante, la reciente publicación de los resultados del XII Censo Nacional de Población y VII de vivienda, ha provisto información actualizada a nivel municipal, relativa al año 2018; la cual, conjuntamente con la de la última Encovi (2014), hace posible la realización de un nuevo ejercicio sobre estimación de pobreza y actualización de mapas de pobreza municipal en Guatemala, permitiendo el cruce de una gran riqueza de información.

2 | Metodología

Con el propósito de construir los mapas de pobreza a nivel municipal, se ha utilizado la información contenida en el XII Censo Nacional de Población, así como la contenida en la última Encuesta de Condiciones de Vida (Encovi) del año 2014.¹ El primer paso a seguir es establecer las variables coincidentes, de tal manera que se pueda construir un modelo a través del cual se realice una predicción de la pobreza para cada uno de los registros del censo. Aunque para este efecto se pueden utilizar distintos marcos metodológicos, en este caso se ha optado por utilizar un instrumento de aprendizaje de máquina o “machine learning” conocido como bosque aleatorio o “random forest”. Este método ha demostrado ser exitoso en la predicción en distintos campos, constituyéndose en un buen predictor de la pobreza y, en algunos casos, ha permitido realizar mejores estimaciones en comparación a los métodos comúnmente aplicados² (Sohnesen y Stender, 2016: 14).

El método de “random forest” parte de la generación de árboles de decisión o “decision trees”. Sea un conjunto de datos (x) expresados por variables $p_1, p_2, p_3, \dots, p_n$ que conforman un espacio de predictores P y una variable respuesta q ; un árbol de decisión es un algoritmo que pretende construir un predictor preciso de q por medio de segmentaciones en P (Breiman *et al*, 1984: 20-22). En esencia, el algoritmo divide recursivamente el conjunto de datos en regiones según criterios en los predictores $p_1, p_2, p_3, \dots, p_n$, con el objetivo de que cada región resultante P_r tenga valores de q lo más “puros” o semejantes posibles (James *et al*, 2013; 311). El algoritmo luego genera predicciones uniformes de q por cada P_r ; en casos como el presente donde la variable respuesta es cualitativa, a cada P_r se le asigna la moda de q de los datos $x \in P_r$. Para lograr óptimas clasificaciones, cada división de P debe ser aquella que optimice la pureza del conjunto de datos, dada por una función como “log-loss” o “cross-entropy” (James *et al*, 2013: 312):

$$D = - \sum_{r=1}^R \sum_{k=1}^K \hat{p}_{rk} \log \hat{p}_{rk},$$

¹ Correspondiente a la línea de pobreza monetaria vinculada al consumo.

² Sohnesen y Stender (2016) sostienen que en una estimación de pobreza realizada en 6 países, entre los que se incluyen Etiopía, Malawi, Uganda, Albania, Tanzania y Ruanda, el error cuadrático medio de los modelos basados en “random forest” fue menor (aproximadamente 2.58) en comparación a métodos convencionales (entre 8.41 y 9.45).

Donde \hat{p}_{rk} significa la proporción de datos en la región resultante r con clase k . De esta forma, el árbol de decisión es entrenado³ para que este pueda dar una óptima valoración de q a nuevas entradas de datos igualmente caracterizados por $p_1, p_2, p_3, \dots, p_n$.

Algunas desventajas de los modelos de árbol de decisión es que son susceptibles a alta variabilidad (James *et al*, 2013: 315-316) o que las segmentaciones se realizan sin considerar las iteraciones, razones por las que los árboles pueden ignorar la estructura predictiva esencial en conjuntos de datos. Para contrarrestar estas debilidades, se pueden generar k árboles de decisión distintos entre sí y hacer una única predicción basada en la moda de las k predicciones de cada árbol. Se le denomina bosque aleatorio o “random forest” a un ensamble de árboles de decisiones, donde cada árbol se crea con un subconjunto distinto de las variables predictores y tiene una capacidad de predicción significativamente mayor a la de un único árbol de decisión (Breiman, 2001). Para predecir el nivel de pobreza en cada registro del XII Censo Nacional de Población, se genera un modelo de “random forest” con la Encovi 2014 empleando variables predictores que comparten ambos conjuntos de datos.

Como primer paso para la implementación del “random forest” se ha realizado un análisis de selección de atributos (“features selection”). A pesar de que las variables coincidentes entre el citado censo y la encuesta referida no son abundantes, resulta útil aplicar este análisis para evitar un sobreajuste (es decir, obtener un modelo demasiado complejo capaz de captar toda la información pero con alta variabilidad, con lo cual se obtienen predicciones subóptimas); sin embargo, en el presente caso, la potencial presencia de sobreajuste es mínima, puesto que no existe una cantidad significativa de variables.

Concretamente, para la selección de variables se ha utilizado un algoritmo basado en “random forest” como algoritmo subyacente. La idea es generar en cada iteración una serie de variables sombra a partir de los predictores, realizando una copia de cada uno de ellos y permutando entre sí los elementos de cada nueva columna. Luego, se ajusta un modelo por “random forest” y se calculan las importancias relativas de cada variable.

Si una variable sistemáticamente queda por debajo de las sintéticas (ruido), es un indicativo de que su aportación al modelo es dudosa y, por tanto, puede descartarse. El proceso continúa hasta que todas las variables son aceptadas, rechazadas o se alcanza un número de iteraciones límite (Guerrero, 2016: 23). La elección de este algoritmo para tamizar las variables a utilizar en el modelo “random forest” se fundamenta en que se han mostrado ventajas para este efecto. Moreno *et al* (2020: 19) refieren que, debido a “su poder predictivo y estabilidad, elegimos a Boruta como el algoritmo de referencia para estudiar la importancia relativa de los predictores”. Así, para minimizar el riesgo de caer en un sobreajuste, del total de variables coincidentes entre el censo de 2018 y la Encovi 2014, el algoritmo Boruta desechó una sola variable.⁴

Una vez seleccionadas las variables se aplicó un “random forest” de clasificación con la intención de identificar las personas en condición de no pobreza, pobreza no extrema y pobreza extrema. Debe señalarse que el “random forest” posee una serie de parámetros⁵ que se desconocen *a priori*, de modo que una elección errónea de los mismos puede llevar a un rendimiento subóptimo del modelo. Del mismo modo, para advertir una potencial amenaza de sobreentrenamiento (“overfitting”), asegurando la generalización del mismo, se segmentó la base de datos en un 70% para entrenamiento, 15% para validación y 15% para evaluación. En ese sentido, dada la posibilidad de contar con un bosque integrado por un árbol de decisión hasta un número muy cercano a infinito, se realizó una búsqueda de hiperparámetros (“grid search”), cuyo resultado indicó que el número óptimo de árboles era 1,100.

Las métricas de los datos reservados para validación dan cuenta de un error promedio de clasificación bajo (3%). Según la matriz de confusión –que mide el nivel de aciertos y desaciertos comparando los datos reales y las predicciones realizadas– el error al clasificar la categoría “no pobre” es de 1.7%; en la categoría “pobre no extremo” es de 3.3%; y en categoría “pobre extremo” es de 3.9%. Otras métricas vinculadas al conjunto de datos de validación, cuyos valores dan cuenta de un buen rendimiento del modelo son:

Tabla 1. Métricas para el conjunto de entrenamiento y validación

Descripción	Entrenamiento	Validación
MSE	0.0426618	0.0428721
RMSE	0.2065473	0.2070559
Logloss	0.1725912	0.1731742
Media del error por clase	0.0326090	0.0300306
R2	0.9440591	0.9437638

Fuente: Elaboración propia con información del INE/Encovi 2014.

³ O bien, se ha ajustado un modelo de árbol de decisión al conjunto de datos x .

⁴ La variable PPA2 o “sexo de la persona”

⁵ En particular, la cantidad de árboles de decisión en el ensamble y la cantidad de variables predictores con las que se entrena cada árbol.

Después de haber entrenado el bosque y obtenido métricas satisfactorias para el conjunto de datos de validación, se debe de confirmar que el modelo no se encuentra sobre entrenado, pudiendo ser generalizado a otros conjuntos de datos, que es precisamente lo que se pretende realizar al aplicar el modelo, entrenado

con la Encovi 2014, a los datos del XII censo de población y VII de vivienda. Para ello se realiza una predicción, utilizando el conjunto de datos reservados para la evaluación. Los resultados de este ejercicio se recogen a través de la matriz de confusión siguiente:

Tabla 2. Matriz de confusión para la predicción realizada con los datos de evaluación

		Predicción con modelo de "random forest"				
		Descripción	No pobre	Pobre extremo	Pobre no extremo	Error
Valor real	No pobre		2,996	10	101	0.03572578
	Pobre extremo		5	1,935	22	0.01376147
	Pobre no extremo		81	52	2,929	0.04343566
	Total		3,082	1,997	3,052	0.03332923

Fuente: Elaboración propia con información del INE/Encovi 2014.

La evaluación realizada permite concluir que el bosque elegido es capaz de generalizarse (aplicarse con buena precisión a nuevos datos), puesto que, tal como se observa en la matriz anterior (derivada de la información reservada para la prueba), tiene un buen desempeño,

en términos de predicción, para cada una de las etiquetas o categorías. En este sentido, se tienen una precisión alta (mayor al 95%), así como una concordancia alta, puesto que el valor del Kappa⁶ es casi perfecto.

Tabla 3. Métricas vinculadas a la predicción con datos de evaluación

Descripción	Valores		
Accuracy	0.9667		
Kappa	0.94		
	No pobre	Pobre extremo	Pobre no extremo
Sensitivity	0.9721	0.969	0.9597
Specificity	0.978	0.9956	0.9738
Pos Pred Value	0.9643	0.9862	0.9566
Neg Pred Value	0.9829	0.9899	0.9757
Prevalence	0.379	0.2456	0.3754
Detection Rate	0.3685	0.238	0.3602
Detection Prevalence	0.3821	0.2413	0.3766
Balanced Accuracy	0.9751	0.9823	0.9668

Fuente: Elaboración propia con información del INE/Encovi 2014.

Una vez se confirma que el "random forest" elegido puede ser generalizado, al tiempo que refleja alta precisión, el modelo se extiende a todos los datos del XII censo de población y VII vivienda de 2018 con la finalidad de obtener una predicción para las categorías o etiquetas antedichas (no pobre, pobre extremo y pobre no extremo), de modo que sea posible realizar una actualización del

mapa de pobreza municipal en Guatemala. Otra ventaja de utilizar herramientas de la inteligencia artificial para construir los mapas de pobreza se encuentra vinculada a que la implementación de la metodología no resulta onerosa en término de costos y tiempo. En efecto, la metodología es de implementación relativamente rápida.

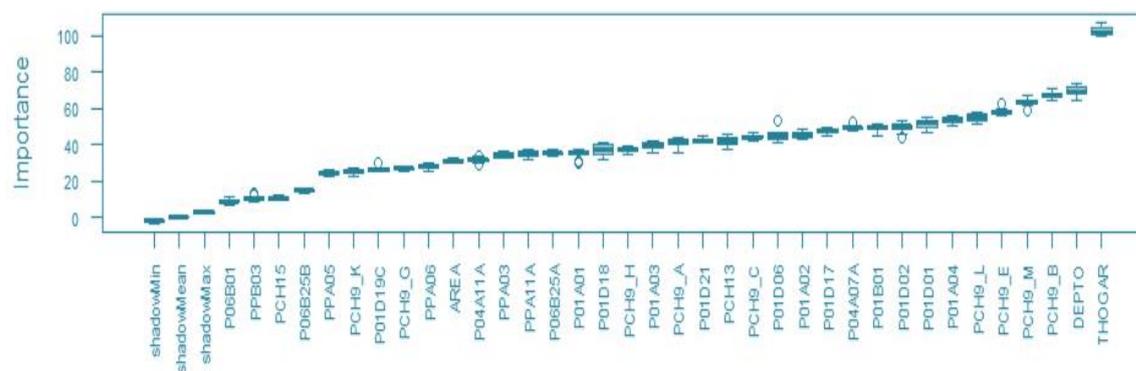
⁶ El índice Kappa mide la concordancia, es decir, mide los resultados de la clasificación, tratando de no tomar en cuenta las etiquetas clasificadas correctamente por el azar. Mientras más cercano a uno, mayor es la concordancia y a la inversa.

3 | Resultados

Como se indicó, el primer paso para la implementación del “random forest” fue asegurarse que las variables a incluir tuvieran relevancia. El algoritmo utilizado, de las 38 variables coincidentes entre el censo 2018 y la Encovi 2014, excluyó solamente una (la variable “sexo de

la persona”). El algoritmo utilizado, del mismo modo, muestra que las variables con mayor poder para la predicción de la pobreza son, en orden de importancia: i) el tamaño de hogar; ii) la tenencia en el hogar de automóvil; iii) de estufa; iv) refrigeradora; entre otras.

Gráfica 2: selección de variables mediante el algoritmo Boruta



Fuente: Elaboración propia con información de la Encovi 2014.

Nota: el significado de cada una de las variables se encuentra detallado en el anexo.

Habiendo determinado las variables de importancia en la predicción de pobreza en Guatemala, se procedió a buscar los hiperparámetros óptimos (cantidad de árboles por ensamble y cantidad de variables predictores por cada uno). Como se refirió, la cantidad de árboles óptimo para el bosque aleatorio fue de 1100, de tal cuenta que el modelo ejecutado para realizar una predicción de la pobreza usando el XII censo de población y VII de vivienda, además de corresponder a un problema de clasificación (no pobre, pobre no extremo y pobre extremo), considera 36 variables predictores; 1100 árboles y 28 variables en cada nodo. Como se indicó, los registros de la base de datos de la Encovi 2014 se repartieron en: el 70% para entrenamiento; 15% para validación y el resto para la evaluación.

Los resultados relativos al conjunto de métricas para los datos de validación muestran que este “random forest” tiene alta precisión para los efectos propuestos. Como ya se refirió en el apartado relativo al método, la matriz de confusión asociada con los datos de validación muestra un error de clasificación bajo (aproximadamente el 3%); esto es, de cada 100 predicciones 3 fueron erradas. Por ejemplo, en el caso de la categoría de no pobre, de cada 100 predicciones, aproximadamente 1 fue errónea; en el caso de la pobreza no extrema de esos 100, 4 estuvieron

erradas. En adición, las métricas relativas al conjunto de datos reservados para la prueba, como se observa en las tablas respectivas, refieren que el modelo es capaz de ser generalizado. Una vez probado, validado y evaluado el “random forest” se procedió a realizar la predicción de la pobreza con las variables contenidas en las bases de datos del XII censo de población y VII de vivienda. Debe advertirse que, en adición al ejercicio de clasificación se realizó un ejercicio para la predicción del consumo agregado, de tal cuenta que este fuese comparado con el umbral, tanto de pobreza, así como de pobreza extrema. Siguiendo los pasos expuestos, los resultados, en este caso, siguen mostrando una caída de los niveles de pobreza y pobreza extrema.

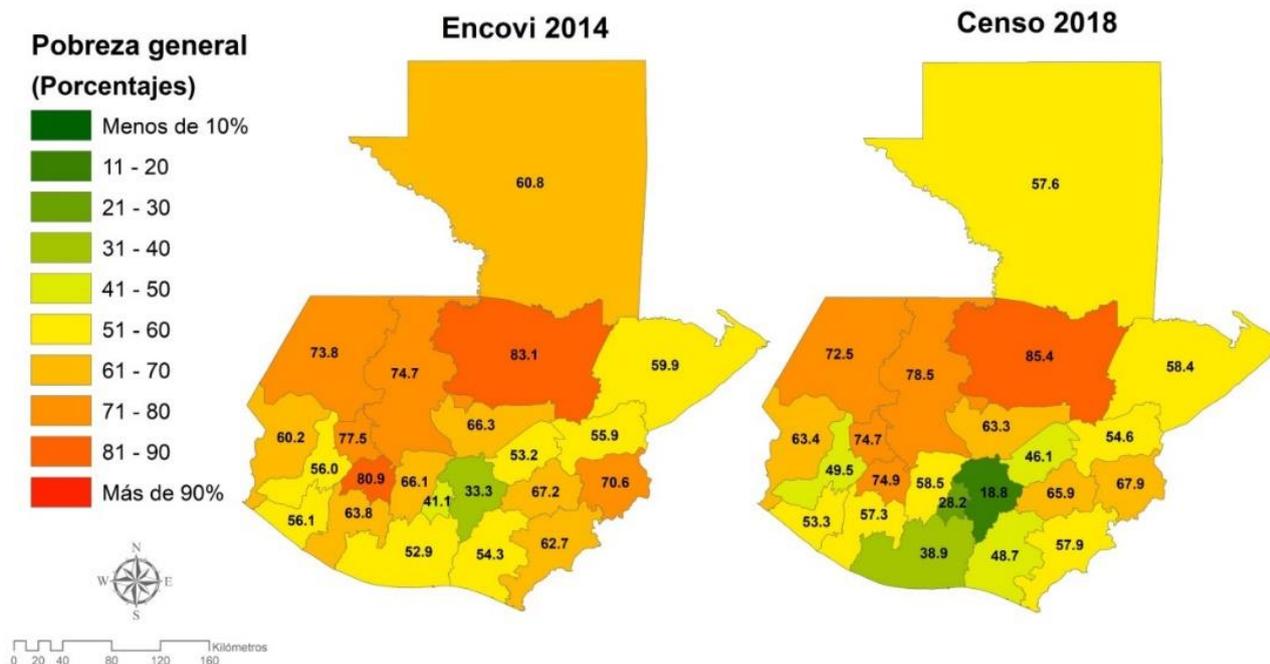
Los resultados obtenidos, en cuanto al modelo construido en torno a etiquetas, muestran una reducción de los niveles de pobreza total, pasando de 59.3%, de acuerdo con la última medición, a 54.1% para el año 2018. Por su parte, la predicción realizada arroja, del mismo modo, una mejora en relación a la pobreza extrema, la cual pasa de 23.4%, según la Encovi 2014, a 20.6%, según el ejercicio de predicción realizado. Este efecto se debe, fundamentalmente, a la mejora en la posesión de activos por parte de los hogares guatemaltecos.

En adición el ejercicio muestra la persistencia de altos niveles de pobreza en el altiplano guatemalteco, preocupando el hecho de que en Alta Verapaz y Quiché, el grave deterioro que se mostraba en 2014, continúa en ascenso.

Por otra parte, los resultados resaltan la evidencia en los departamentos de Guatemala, Sacatepéquez y Escuintla, en los que se registran reducciones considerables en términos de pobreza. Santa Rosa y El Progreso muestran reducciones, aunque no tan significativas, sí importantes.

Mapa 2: Incidencia de la pobreza general según departamento, 2014 y 2018

(Porcentajes)

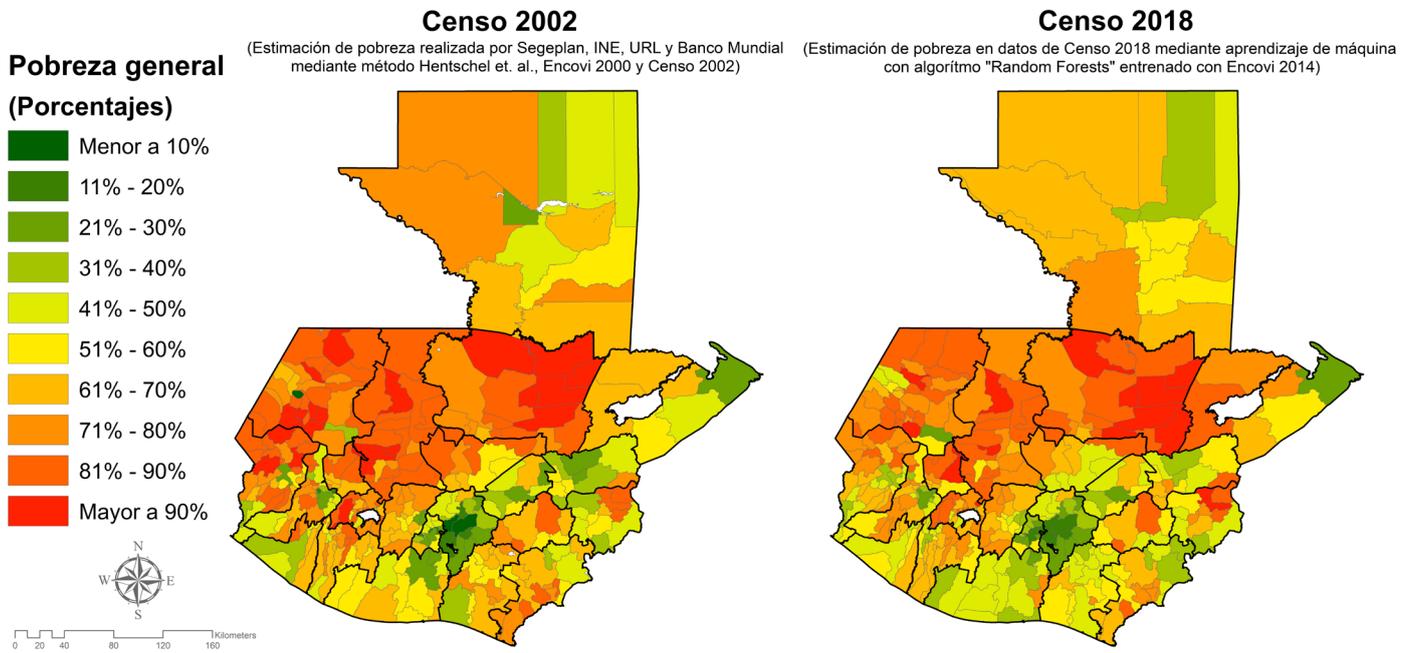


Fuente: Elaboración propia con información de la Encovi 2014 y Censo 2018.

Tal como se advirtió, la pobreza es mayor en el altiplano guatemalteco; sin embargo, al interior de los departamentos existen asimetrías que merece la pena tener en consideración para evaluar, modificar, reformar y construir las políticas públicas en el país. Después de transcurridos tres lustros, la situación de pobreza en algunos municipios no se modificó positivamente sino, al contrario, son reflejo de la ineffectividad de la política pública para combatir de manera integral este flagelo para la sociedad guatemalteca.

Se debe advertir también la importancia de las asimetrías. Si bien, a nivel departamental, en Alta Verapaz y Quiché la escalada de la pobreza continuó, en algunos municipios de estos departamentos se detuvo e incluso mostró un comportamiento inverso. Observando la otra cara de la moneda, en los departamentos donde hubo una reducción significativa, tal el caso de Sacatepéquez y Escuintla, algunos de sus municipios quedaron rezagados en cuanto al ritmo de mejora, e incluso mostraron cierto retroceso (ver mapa 3).

Mapa 3: Incidencia de la pobreza general según municipios, 2002 y 2018
(Porcentajes)

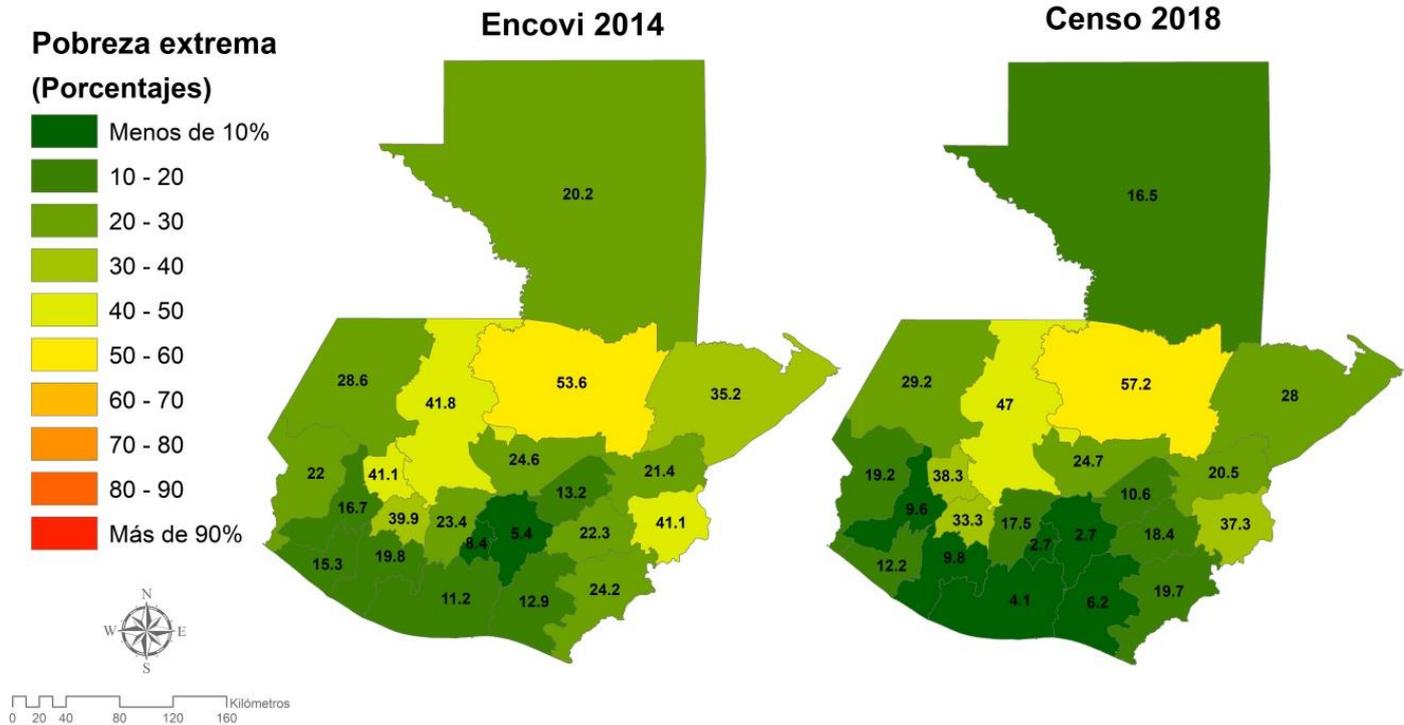


Fuente: Elaboración propia con información de la Encovi 2014 y Censo 2018.

En lo que respecta a la pobreza extrema, el comportamiento es similar al registrado por la pobreza general. Algunos de los departamentos del altiplano guatemalteco sufrieron incrementos importantes, en tanto que en los departamentos de Guatemala, Sacatepéquez, Escuintla y otros que colindan con el océano Pacífico experimentaron disminuciones. Al igual que la pobreza total o general,

la pobreza extrema resulta golpear con más intensidad las zonas geográficas en las que se asientan, en su mayoría, población perteneciente a pueblos mayas; de manera contraria, estos flagelos suelen golpear con menor intensidad a aquellas áreas geográficas en las que se asientan en mayor proporción de poblaciones no indígenas.

Mapa 4: Incidencia de la pobreza extrema según departamento, 2014 y 2018
(Porcentajes)



Fuente: Elaboración propia con información de la Encovi 2014 y Censo 2018.

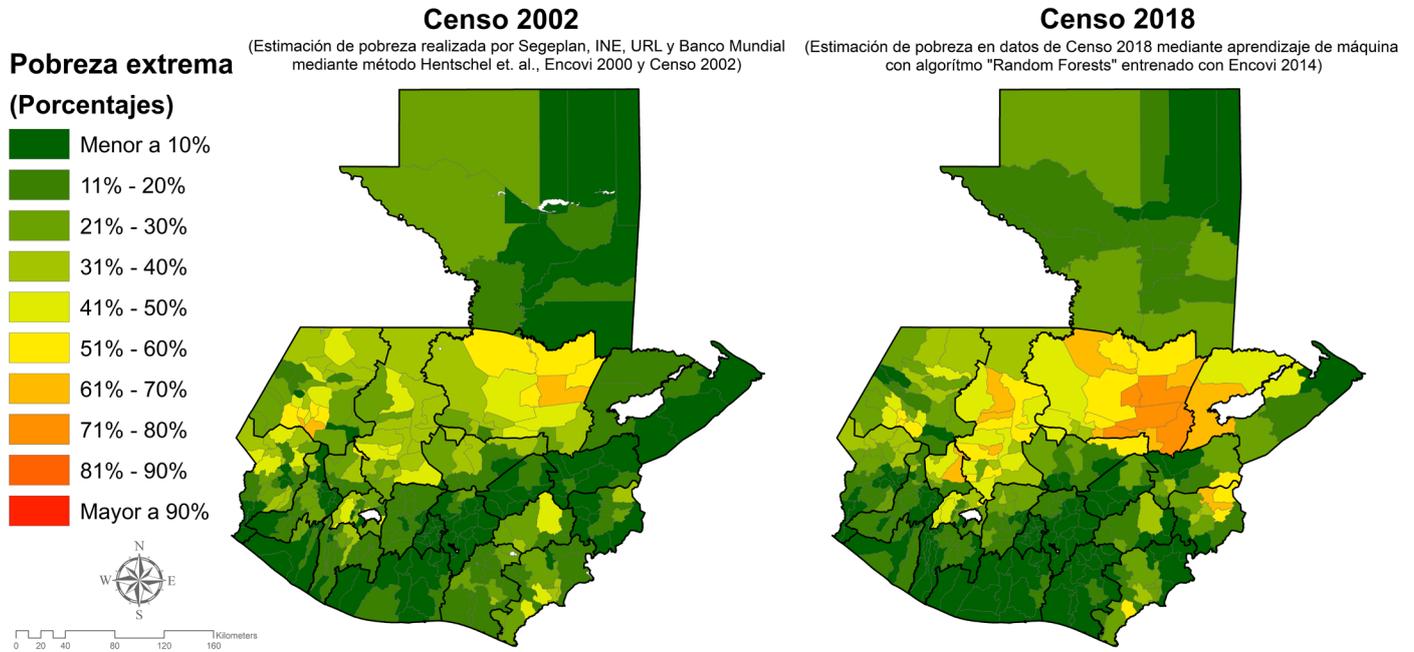
Explorando con mayor detalle, en Quiché y Alta Verapaz es en donde se tiene una incidencia alarmante y, tal como puede observarse en el mapa 5, de 2002 a 2018, la situación empeoró. En ambos departamentos aproximadamente la mitad de sus municipios reflejó una situación adversa en cuanto a pobreza extrema.

En Quiché, los municipios de Nebaj, Chajul, San Luis Ixcán, Uspantán, San Juan Cotzal, Sacapulas, San Bartolomé Jocotenango y Chicamán reflejaron incrementos. Del mismo modo, en Alta Verapaz, algunos municipios que mostraron retrocesos en este aspecto fueron Chisec, Lanquín, Santa María Cahabón, Senahú, Panzós y Tukurú.



Mapa 5: Incidencia de la pobreza extrema según municipios, 2002 y 2018

(Porcentajes)



Fuente: Elaboración propia con información de la Encovi 2014 y Censo 2018.

Conclusiones

En términos más generales, la pobreza y pobreza extrema en Guatemala se ha caracterizado por su persistencia y alta incidencia en ubicaciones geográficas en las que se asientan poblaciones indígenas, contrariamente a lo que caracteriza a los territorios en los que se ubican poblaciones no indígenas, en las que parece, con el transcurrir del tiempo, existen mejoras. El ejercicio de predicción y construcción de mapas municipales de pobreza a 2018, reflejan que esa caracterización no ha cambiado ni siquiera mínimamente. El altiplano guatemalteco sigue, pese a haber pasado un poco más de tres lustros, y ha seguido experimentando una escalada de pobreza y pobreza extrema, lo que denota el fracaso de la política pública en la lucha contra la pobreza y las acciones que de ella se derivan, durante la segunda mitad, hasta ahora, del período de vida democrática del país.

A lo largo de estas líneas se han visto, apenas, algunos elementos de análisis que permiten la actualización de los mapas de pobreza, los cuales podrían ser relevantes para la política pública, puesto que permite advertir asimetrías con cierto detalle, lo que puede permitir a los tomadores de decisión y hacedores de política pública ampliar la perspectiva para orientar esfuerzos con intensidad y urgencia en determinados espacios, así como para entrar a un análisis sobre las causas de por qué la pobreza y pobreza extrema no ceden en algunas regiones. Igualmente, el ejercicio es un punto de partida, puesto que ayuda a plantearse algunas hipótesis al respecto de esas asimetrías. Esas acciones derivadas pueden contribuir a una visión prospectiva sobre estos flagelos y, asimismo, fortalecer el ciclo de gestión y política pública, en especial lo relativo a planificación prospectiva y participativa.

También debe advertirse que el ejercicio, dado que va más allá de la dimensión espacial, permite un análisis de relacionamiento más profundo, el cual contribuye a aumentar la comprensión de la pobreza y pobreza extrema. En este sentido, se cita como ejemplo que pueden tenerse aproximaciones sobre la pobreza según ciclo de vida, lo cual, ante la oportunidad que el bono demográfico ofrece a Guatemala, es importante conocer.

Finalmente, puede traducirse como una herramienta importante para la revisión, reforma y construcción de la política pública, ante el compromiso del Estado guatemalteco relativo a la Agenda 2030 de Desarrollo Sostenible, fundamentalmente en lo que corresponde al Objetivo de Desarrollo Sostenible (ODS) 1: poner fin a la pobreza, de tal cuenta que exista mayor posibilidad de concretar las metas asociadas con este.

Bibliografía

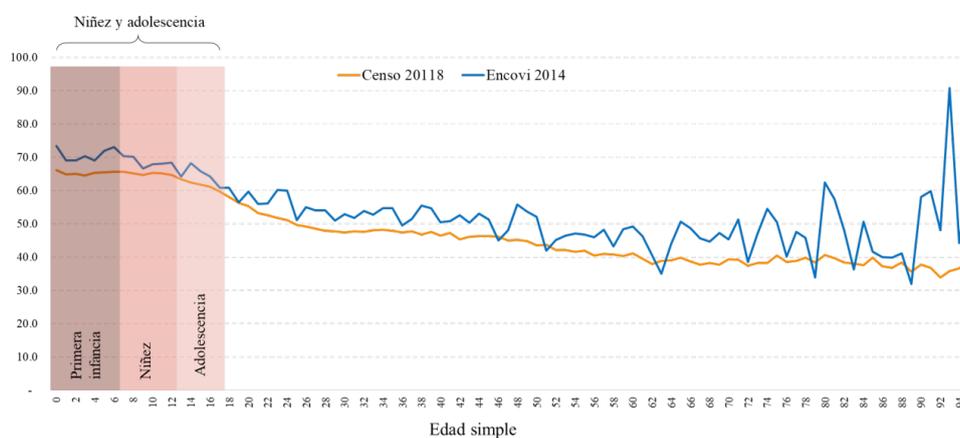
- Breiman, L., Friedman, F., Olshen, R. A., y Stone, C. J. (1984). "Classification and regression trees". En *Wadsworth Statistics / Probability Series*. Editorial CRC, Boca Raton.
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5-32. Springer Science and Business Media (LLC).
- Dunstan et al (2019). "Predicting Nationwide Obesity From Food Sales Using Machine Learning". *Health Informatics J*. 2020;26(1):652-663. doi:10.1177/1460458219845959.
- Guerrero, J. (2016). "El problema de la dimensionalidad". *Revista estadística y sociedad* No. 68: 22-24. Disponible en línea: <http://www.revistaindice.com/numero68/>.
- Hersh et al (2020). "Mapping Income Poverty in Belize Improving lives Using Satellite Features and Machine Learning" Inter-American Development Bank. Disponible en línea: https://www.researchgate.net/publication/341460141_Mapping_Income_Poverty_in_Belize_Improving_lives_Using_Satellite_Features_and_Machine_Learning_Alejandra_Mejia_Inter-American_Development_Bank.
- INE (2013). "Mapas de Pobreza Rural en Guatemala 2011". Disponible en línea: <https://www.ine.gob.gt/sistema/uploads/2014/01/10/ifRRpEnf0cjUfRZGhyXD7RQjf7EQH2Er.pdf>.
- INE (2014). Encuesta Nacional de Condiciones de Vida, principales resultados. Disponible en línea: <https://www.ine.gob.gt/sistema/uploads/2015/12/11/vjNVdb4iZswOj0ZtuivPlcaAXet8LZqZ.pdf>.
- Jean et al (2016). "Combining satellite imagery and machine learning to predict poverty". *Science*. 2016; 353(6301):790-794. doi:10.1126/science.aaf7894.
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). *An Introduction to Statistical Learning*. En Springer Texts in Statistics. Springer, New York.
- Kursa, M. y Rudnicki, W. (2010). "Feature Selection with the Boruta Package". *Journal of Statistical Software*, volume 36, issue 11. Disponible en línea: <file:///C:/Users/Usuario/Downloads/v36i11.pdf>.
- Mcbride, L. y Nichols, A. (2019). *Retooling Poverty Targeting Using Out-of-Sample Validation and Machine Learning*. World Bank Paper No. 7849 (Washington DC).
- Moreno et al (2020). "Debt is not free". IMF Working Paper No. 20/01 (Washington: International Monetary Fund).
- Segeplan (2006). *Mapas de pobreza en Guatemala al 2002*. Secretaría de Planificación y Programación de la Presidencia (Segeplan). Información en línea. Consultada en febrero de 2020. Disponible en línea: <https://www.segeplan.gob.gt/nportal/index.php/biblioteca-documental/file/609-mapas-de-pobreza-2002>.
- Segeplan (2020). *Sistema Nacional de Información Territorial (SINIT), Geoportal IDE*. Secretaría de Planificación y Programación de la Presidencia (Segeplan). Sistema en línea, consultado en abril de 2020. Disponible en: <http://ideg.segeplan.gob.gt/geoportal/>
- Sohnesen, T. y Stender, N. (2016). "Is Random Forest a Superior Methodology for Predicting Poverty". World Bank Paper No. 7612 (Washington DC).

Anexo

Listado de variables utilizadas

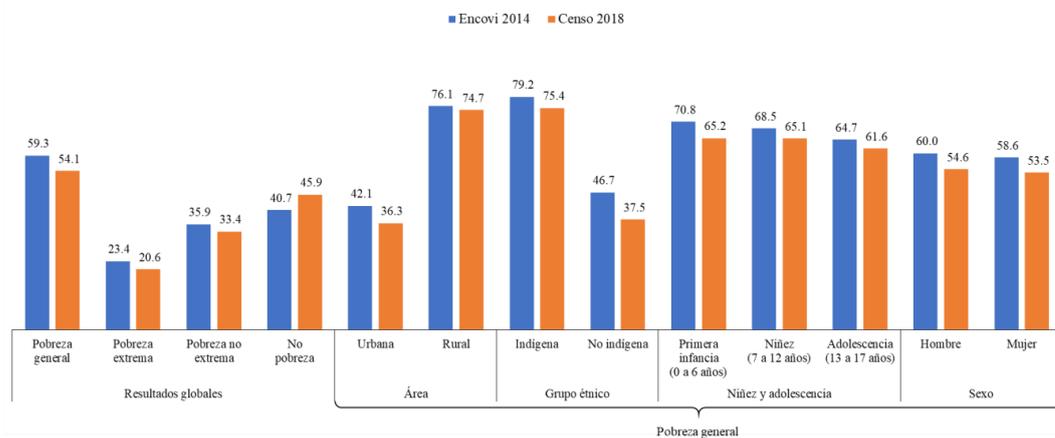
Variable	Definición
THOGAR	Tamaño del hogar
PCH9_M	Carro
PCH9_B	Estufa
PCH9_E	Refrigeradora
DEPTO	Departamento
P01D19C	Internet
P01D17	Servicio sanitario
PCH9_C	Televisor
PCH9_G	Lavadora de ropa
P01D06	Fuente de agua para consumo
PCH9_H	Computadora
PCH9_L	Moto
P01A04	Material predominante del piso
ÁREA	Área geográfica urbana o rural
PCH13	Cuarto exclusivo para cocinar
P06B25A	Nivel educativo
PCH9_A	Radio
P01B01	Situación de ocupación vivienda
P01D18	Servicio sanitario exclusivo
PPA11A	Emigró alguien en el hogar en los últimos 5 años
P01D02	Cantidad de dormitorios
P01A03	Material predominante del techo
P04A07A	Idioma que aprendió a hablar
P01D21	Forma de desechar basura
P04A11A	Etnia
PCH9_K	Agua caliente
P01A02	Material predominante de paredes
PPA06	Estado civil
PPA03	Edad
P01A01	Tipo de vivienda
PPA05	Parentesco a jefe de hogar
P01D01	Cantidad cuartos
P06B25B	Grado educativo
PPB03	Número de hogar
P06B01	Leer y escribir
PCH15	Recibe remesas
PPA02	Sexo

Comparativo de pobreza general por edad simple y fuente de medición



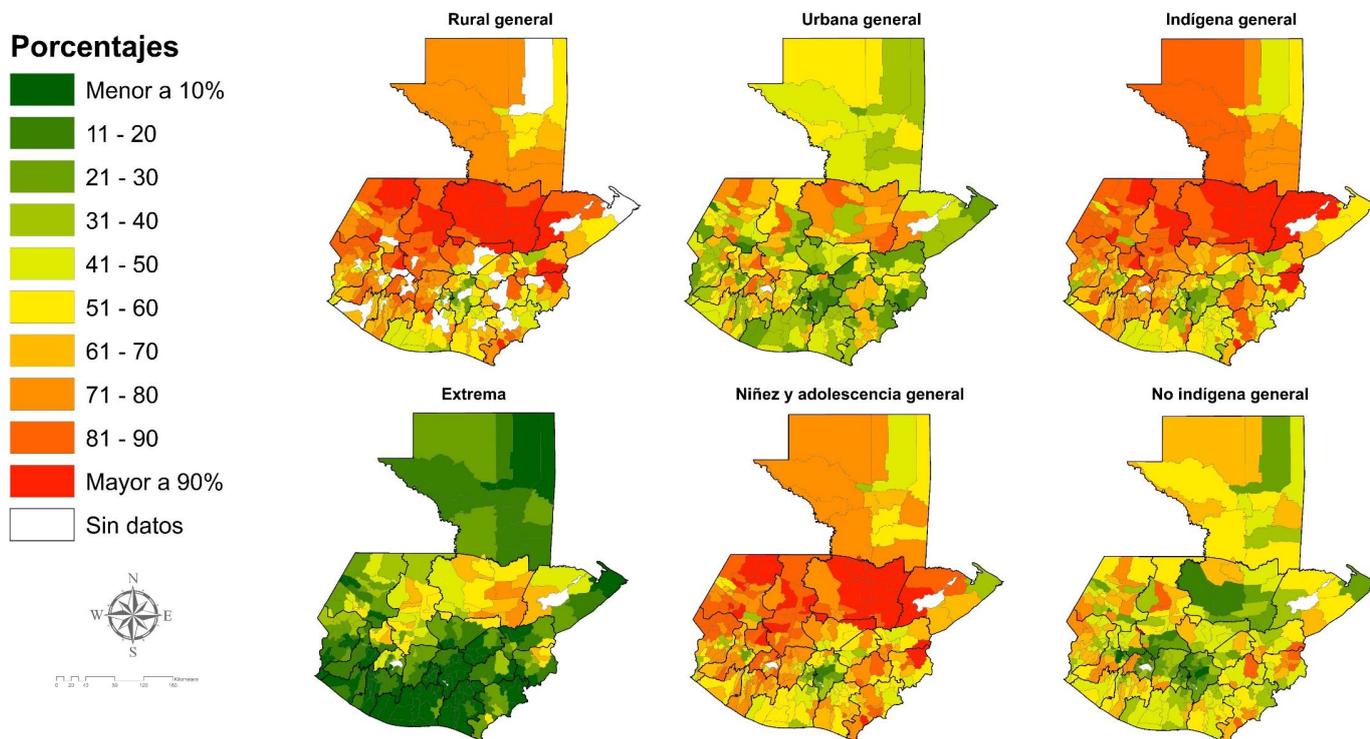
Fuente: Elaboración propia con información de la Encovi 2014 y Censo 2018.

Comparativo de pobreza general según categorías y fuente de medición



Fuente: Elaboración propia con información de la Encovi 2014 y Censo 2018.

Otros resultados derivados de la estimación de pobreza mediante Censo 2018



Fuente: Elaboración propia con información de la Encovi 2014 y Censo 2018.

Estimación del efecto diploma en Guatemala

Años 2002 y 2018

Guillermo Díaz Castellanos¹

Resumen

El presente trabajo de investigación aporta evidencia empírica sobre la existencia del efecto “sheepskin” o diploma en el mercado laboral guatemalteco, con el objetivo de conocer cuánto agrega en el retorno de la educación la obtención de un diploma académico en los niveles secundario, universitario y de posgrado. Con base en datos de Encuestas de Empleo e Ingresos de los años 2002 y 2018, se realizó una estimación de la ecuación de Mincer, en su forma “spline” discontinua. La estimación se realizó por los métodos de mínimos cuadrados ordinarios y de dos etapas de Heckman para control del sesgo de selección. Los resultados confirman la existencia del efecto diploma en los tres niveles educativos investigados. También aportan evidencia de una devaluación de los títulos académicos en 2018 comparado con 2002.

Abstract

This research work provides empirical evidence on the existence of the sheepskin effect in the Guatemalan labor market, with the aim of knowing how much more contribution in the return of education the obtaining of an academic degree at the secondary, university and postgraduate levels. Based on data from Income Employment Surveys for the years 2002 and 2018, an estimate of the Mincer model, in its discontinued spline form. The estimation was made by ordinary least squares and Heckman two-stage methods to control for selection bias. The results confirm the existence of the sheepskin effect in the three educational levels investigated. They also provide evidence of a devaluation of academic degrees in 2018 compared to 2002.

¹ Facultad de Ciencias Económicas y Empresariales, Universidad Rafael Landívar

Introducción

Los retornos de la educación evidencian una tendencia a la baja a nivel mundial, según un estudio del Banco Mundial (2014). La situación en algunos países de América Latina es tal que en Perú, Yamada (2007) publicó un estudio que en el título incluye la pregunta: ¿Vale la pena el esfuerzo?, para referirse al costo, tanto en tiempo como de oportunidad, que implica estudiar para obtener un título. Villaroel y Hernani (2011), en Bolivia, fueron más contundentes al respecto, al preguntar: ¿La educación todavía paga? A lo anterior se agrega que la decisión de empresas de escala mundial, como Apple, Google, Netflix o Siemens, de no requerir título universitario como requisito para contratar (Forbes, 2019).

En Guatemala una encuesta realizada a 209 empresas, la mayoría (86%) de tamaño mediano y grande, reveló que un poco menos del 20% de los trabajadores contratados tiene estudios universitarios. La mayoría, casi 50%, tiene estudios a nivel de secundaria. La encuesta también reveló que las empresas contratan trabajadores con certificaciones (Fundesa, 2020).

Dadas las tendencias descritas, surgen interrogantes como: ¿El fenómeno de reducción de los retornos de la educación y de los títulos (efecto “sheepskin” o diploma) es observable en Guatemala? ¿El fenómeno se observa

también en los estudios preuniversitarios? ¿Cuánto paga de prima el mercado laboral guatemalteco porque el trabajador tenga un título universitario?

El interés por investigar sobre el efecto diploma surge de la motivación por conocer el efecto de la masificación de graduados a nivel secundario y universitario, que se produjo durante las primeras dos décadas del siglo XXI en Guatemala, sobre los retornos de los diplomas académicos. En el primer caso, el número anual de graduados pasó de 84,111 en 2006 a 158,161 en 2018 (Ministerio de Educación, 2019). El número de personas que en el censo de población de 2018 reportaron haber obtenido un diploma del nivel medio fue de casi 1.8 millones (Instituto Nacional de Estadística, 2018). Por su parte, el número anual de graduados universitarios aumentó de 9,584 en 2007 a 32,075 en 2017. En el censo de 2018, el número de personas que reportaron poseer un título universitario fue alrededor de 619,000 (Instituto Nacional de Estadística, 2019). En este sentido, una primera aproximación a datos estadísticos disponibles de 2010 a 2015 revelan una devaluación de los títulos universitarios, conforme lo ilustra el siguiente cuadro 1. En dicho cuadro se puede observar que a medida que aumentó el número anual de graduados universitarios, el sueldo promedio mensual disminuyó.

Año	Sueldo promedio mensual	Número de graduados
2010	6,485	14,450
2011	6,016	19,990
2012	7,551	20,831
2013	6,342	24,442
2014	5,891	26,899
2015	5,750	33,680

Fuente: DIGI, 2014 e INE, 2017.

La investigación que se presenta contribuye con estimar el efecto diploma en Guatemala para los años 2002 y 2018. La pregunta de investigación es: ¿Cuál fue el valor del efecto diploma en Guatemala en los años 2002 y 2018? La misma pregunta también se realiza en

función del sexo de las personas. La investigación se realiza para dichos años en función de ser el primero y el más reciente en la publicación de la Encuesta Nacional de Empleo e Ingresos, cuyos datos se utilizaron para la estimación del efecto diploma.

Revisión de literatura

La teoría del capital humano es útil para entender la relación entre ingresos y educación. Dicha teoría postula que las personas pueden mejorar sus habilidades a través de la educación o entrenamiento en el trabajo. La inversión en educación o capacitación es considerada como inversión en capital humano en el sentido que mejora las habilidades físicas y mentales de las personas y, por consiguiente, aumenta sus ingresos futuros (Becker, 1962). En la literatura económica existen diversos enfoques para estimar la relación entre ingresos y educación. El más difundido es el modelo de Mincer (1974), que cuantifica el aumento de los ingresos por año de estudios. A partir de este modelo se derivan otros que calculan los ingresos según nivel educativo cursado, a través de la técnica “Spline”, o nivel educativo completado o inconcluso. Este último se conoce en la literatura económica como “sheepskin” o efecto diploma y comprende los aumentos en los ingresos de obtener un diploma o completar un grado académico (Harmon, Oosterbeek y Wlaker, 2003).

El modelo de Mincer tiene cuestionamientos teóricos, tales como la medición de los ingresos que provienen de las habilidades innatas de las personas. Este problema se corrige, en alguna medida, al estimar los retornos de la educación según el modelo del efecto diploma, ya que, de acuerdo a la teoría de la señalización, los más educados obtienen mayores rendimientos por sus habilidades innatas. También postula que dichos ingresos se obtienen siempre que los años de educación se certifiquen y sean señalizados como títulos en el mercado laboral (Spence, 2002). El empleador utiliza las credenciales o títulos académicos como señal de la productividad del trabajador y él como señal para ser seleccionado (Stiglitz, 2002). En contraposición a este planteamiento, Dore (1976) indica que cierto nivel educativo es un requisito para algunas profesiones, por lo que las empresas ofrecen mayores salarios a los trabajadores con diploma o grado académico requerido.

Uno de los primeros estudios para verificar la teoría de la señalización fue elaborado por Layard y Psacharopoulos (1974), quienes concluyeron la inexistencia del efecto diploma, al no encontrar diferencias de retornos entre personas con grados concluidos y no concluidos. El primer estudio que verificó empíricamente el efecto diploma fue realizado por Hungerford y Solon (1987), quienes encontraron diferencias de ingresos entre personas con educación universitaria completa e incompleta, con rendimientos de 13% contra 4%, respectivamente. A partir de entonces se elaboraron numerosos estudios sobre el efecto diploma o “sheepskin”, aunque no tanto como en el de los retornos por año de educación. Una rápida búsqueda en Google en diciembre de 2020 dio como resultado 360,000 documentos del segundo tema, contra casi 5,000 del primero. Entre los trabajos más recientes publicados y revisados para esta investigación, se pueden citar los de Rivera (2015) que aborda el tema en Ecuador, el de Klapp y Candia (2016), que estimó el efecto diploma para Chile, el de Parodi, Ramírez y Thomson (2017), elaborado para República Dominicana; y el de Hernández (2019), enfocado en Colombia.

En Guatemala son escasos los estudios sobre los rendimientos o retornos de la educación que se pueden consultar. Entre los pocos a los que se pudo acceder se citan los de Pérez (2003), Saidón (2004), Alejos (2006), Banco Mundial (2011) y Díaz (2019). Los primeros tres estudios se refieren al año 2000; y el del Banco Mundial a los años 2000 y 2006. El último es un análisis de estática comparativa entre los años 2002 y 2016. En la revisión de literatura sobre el tema, no se pudo encontrar una investigación sobre el efecto diploma en Guatemala.

Modelo y datos

Mincer (1974) propuso el modelo básico para estimar los rendimientos de la educación, en especial de cada año de estudio, como sigue:

$$\text{Ln } W_j = \text{constante} + \beta_s s_j + \beta_e \text{experiencia} + \beta_{e1} \text{experiencia}^2$$

El término j se refiere al individuo j . Siguiendo a Mincer (1974), los valores esperados para los parámetros β_0 y β_1 son mayores que cero y menor de cero para β_{e1} , que corresponde a la experiencia al cuadrado. El parámetro β_s estima el rendimiento de los años de educación y los parámetros β_e y β_{e1} los rendimientos de la experiencia y experiencia al cuadrado. En los primeros dos los rendimientos son crecientes; y en el tercero, decrecientes.

El modelo básico de Mincer se modifica mediante la técnica “spline”, término que fusiona las palabras en inglés “split” y “line”. Esto significa suponer que la relación entre los ingresos y los años de educación no

es lineal, como lo planteó Mincer en su modelo (Riviera, 2015). La forma funcional del modelo “spline” puede ser con o sin discontinuidad (Hernández, 2019). En este trabajo se utiliza la forma con discontinuidad para estimar el retorno de la obtención de diploma en los niveles preuniversitario o secundario (12 años de educación), universitario (18 años de educación) y de posgrado (más de 18 años de educación), por considerar que en Guatemala son los que extienden títulos que habilitan para el mercado laboral:

$$\begin{aligned} \text{Ln}W = & \beta_0 + \beta_1 \text{preuinc} + \beta_2 \text{preucomp} + \beta_3 \text{univinc} + \beta_4 \text{univcomp} + \beta_5 \text{postinc} \\ & + \beta_6 \text{postcomp} + \beta_7 \text{area} + \beta_8 \text{sexo} + \beta_9 \text{experiencia} \\ & + \beta_{10} \text{experiencia}^2 + \varepsilon \end{aligned}$$

Donde:

$\text{Ln}W = \text{Ln}$ ingreso por trabajo, representado por el salario mensual.

$\beta_1 \text{preuinc}$ = variable dummy con valor 0 si no tiene y 1 si tiene incompleta la educación secundaria.

$\beta_2 \text{preucomp}$ = variable dummy con valor 0 si no tiene y 1 si tiene completa la educación secundaria.

$\beta_3 \text{univinc}$ = variable dummy con valor 0 si no tiene y 1 si tiene incompleta la educación universitaria.

$\beta_4 \text{univcomp}$ = variable dummy con valor 0 si no tiene y 1 si tiene completa la educación universitaria.

$\beta_5 \text{postinc}$ = variable dummy con valor 0 si no tiene y 1 si tiene incompletos estudios de posgrado.

$\beta_6 \text{postcomp}$ = variable dummy con valor 0 si no tiene y 1 si tiene completos estudios de posgrado.

$\beta_7 \text{area}$ = área geográfica con valor igual a 0 para rural y 1 para urbano.

$\beta_8 \text{sex}$ = sexo, con valor 0 para mujer y 1 para hombre.

$\beta_9 \text{experiencia}$ = edad menos años de educación.

$\beta_{10} \text{experiencia}^2$ = edad menos años de educación al cuadrado.

Dos de los supuestos del modelo de Mincer es que no existe sesgo de habilidad o de variable omitida y no existe autoselección (Sapelli, 2003). Sin embargo, un problema en la estimación de modelos de rendimientos de la educación, como el anterior, que calcula el efecto diploma, es el de la autoselección, en el sentido de las personas que deciden no incorporarse al mercado laboral, por lo que los retornos pueden estar subestimados (Ordaz, 2007). Para corregir el posible sesgo de autoselección existente, se utiliza el modelo de Heckman (1979)

en dos etapas. La primera estima la variable omitida, la razón inversa de Mills (λ), mediante un modelo probit que calcula la probabilidad de las personas de estar en la población ocupada. La segunda etapa incluye la razón inversa de Mills como variable explicativa en el modelo de Mincer. El cálculo de la razón inversa de Mills se estimó según el modelo anterior más las siguientes variables que explican la selección de incorporarse o no al mercado laboral:

$$P = \lambda(\text{constante} + \beta_s s_j + \beta_e \text{estado civil} + \beta_t \text{tamaño del hogar} + \beta_i \text{otros ingresos})$$

Donde:

P = Probabilidad de pertenecer a la población ocupada.

Estado civil = Variable dicotómica con valor 0 para soltero y 1 para no soltero

Tamaño del hogar = Número de integrantes del hogar

Otros ingresos = Ingresos no salariales

Los datos para estimar el modelo se obtuvieron de la ENEI 2002 y ENEI 2018, ambas referidas a noviembre (Instituto Nacional de Estadística, 2003 y 2018). La muestra se integró con personas de 18 y más años, de ambos sexos, residentes en las áreas urbana y rural. En 2002 la muestra fue de 1,477 personas; y en 2018, de 3,518. Los datos para medir el efecto diploma, es decir, quién completó o no un nivel educativo, se obtuvieron de la variable que indica el nombre del título obtenido. En ese sentido, quienes

reportaron cursar un nivel educativo, pero no reportaron nombre del título, fueron considerados como incompleto en dicho nivel. El cuadro 2 resume las principales estadísticas descriptivas. En dicho cuadro se observa similitud entre los datos de 2002 y 2018, en lo que respecta a edad y años de experiencia. En años de educación y sueldo promedio se observa incremento en 2018 respecto a 2002.

Variable	2002		2018	
	Hombres	Mujeres	Hombres	Mujeres
Años de educación	7	6	11	9
Edad	34	32	35	34
Experiencia	17	14	18	17
Sueldo promedio	2,784	2,490	3,102	2,990

Fuente: Instituto Nacional de Estadística, 2003 y 2018.

Análisis de resultados

En principio se calculó la ecuación de Mincer, para estimar el retorno por cada año de educación, en los años 2002 y 2018, calculados con base en los métodos de mínimos cuadrados ordinarios y de dos etapas de Heckman (1979). Los resultados se presentan en el cuadro 3. El modelo de Heckman comprueba la existencia de auto-selección, dada la significancia estadística de la variable Lambda al nivel de 1%. En consecuencia, en ambos años la muestra es no aleatoria, por lo que el análisis de resultados debe realizarse con base en el modelo de Heckman, debido a que el modelo de mínimos cuadrados ordinarios subestima los retornos de la educación a causa del sesgo de autoselección. La subestimación, según el modelo de Heckman, es reducida, de casi un punto porcentual en 2002 y de una décima de punto porcentual en 2018, por cada año de estudio. En el cuadro se observa una reducción del retorno de cada año de educación: fue de dos puntos porcentuales entre 2002 y 2018 de 9.3% a 6.9%, respectivamente.

El retorno por año de experiencia aumentó un punto porcentual entre 2002 y 2018. La función cóncava de los retornos, respecto a la experiencia al cuadrado, permite calcular el momento en que se maximizan los ingresos en función de dicha variable. Esto se logra al dividir el coeficiente de la experiencia, antecedido por el signo menos, entre el coeficiente de la experiencia al cuadrado por 2. El resultado para el año 2002 fue de 45 años de experiencia y para 2018 de 66 años. En la práctica se observa que los trabajadores en Guatemala alcanzan el máximo salario al tener 41 años de experiencia (IGSS, 2016), cifra un poco menor a la estimada en esta investigación para el año 2002, pero con diferencia significativa en el año 2018, que fue de 66 años.

Ecuación de Mincer	2002		2018	
	MCO	Heckman	MCO	Heckman
Variable				
Años de educación	0.081*	0.093*	0.068*	0.069*
Experiencia	0.052*	0.027*	0.0373*	0.0398*
Experiencia al cuadrado	-0.0006*	-0.0003*	-0.0003*	-0.0003*
Área geográfica	0.429*	0.386*	0.131*	0.13*
Sexo	0.335*	0.096*	0.111*	0.121*
Lambda		-0.311*		0.016*
Constante	5.378*	6.125*	6.2*	6.14*
R ²	0.39		0.40	
Números de observaciones	1,477		3,518	

* Significativo al 1%; ** al 5%

Fuente: Elaboración propia con base en datos de Instituto Nacional de Estadística, 2002 y 2018.

La estimación del efecto diploma para los años 2002 y 2018, calculados con base en los métodos de mínimos cuadrados ordinarios y de dos etapas de Heckman se presentan en el cuadro 4. El modelo de Heckman comprueba la existencia de autoselección, dada la significancia estadística de la variable Lambda al nivel de 1%. Dicho modelo muestra que para el año 2002 las variables, otros ingresos y estado civil

fueron estadísticamente significativas para explicar la decisión de las personas de no incorporarse al mercado laboral. En 2018 solo la variable de tamaño del hogar, medida por el número de hijos, fue significativa. El signo de Lambda para este año indica que las personas con mayores habilidades se excluyeron del mercado laboral. En la práctica, en este trabajo se supone que es un sesgo de falta de información.

Los resultados del modelo de Heckman en todas las variables son estadísticamente significativos y con el signo esperado. En este sentido, se observa una diferencia en el efecto diploma a favor de las personas que residen en el área urbana y son hombres. El valor del coeficiente de la variable experiencia indica que cada año de la misma aporta a las personas 3.7% de ingreso adicional. El signo negativo de la experiencia al cuadrado muestra una función de ingresos cóncava con respecto a la experiencia.

Los cálculos evidencian la existencia del efecto diploma en los tres niveles educativos analizados. Así, por ejemplo, en 2002 una persona con título de secundaria obtuvo un 54% más de ingresos, contra 23% de una persona sin dicha credencial académica. En el caso de estudios universitarios y de posgrado el premio por la titulación es de más de 100%.

Cuadro 4
Guatemala: Estimación del efecto diploma

Ecuación de Mincer según nivel educativo	2002		2018	
	MCO	Heckman	MCO	Heckman
Área geográfica	0.09840**	0.188061*	0.148336*	0.117612*
Sexo	0.149700*	0.303008*	0.106364*	0.260400*
Experiencia	0.023071*	0.037093*	0.023204*	0.023421*
Experiencia al cuadrado	-0.000323*	-0.000633*	-0.000318*	-0.000167*
Secundaria incompleta	0.201871*	0.226540*	0.200554*	0.259009*
Secundaria completa	0.404316*	0.549901*	0.415127*	0.378776*
Universidad incompleta	0.626869*	0.720419*	0.620409*	0.562271*
Universidad completa	1.13032*	1.26989*	0.945375*	0.865067*
Posuniversidad incompleta	1.09787*	1.01864*	1.183240*	1.059690*
Posuniversidad completa	1.74555*	1.32828*	1.307120*	1.186380*
Lambda		0.60443*		-0.617205*
Constante	6.82897*	6.45035*	7.135650*	7.036210*
Ecuación de selección				
Otros ingresos		-3.39232e-05*		
Estado civil		-0.0982343**		
Tamaño del hogar				-0.172816*
R ²	0.45		0.40	
Números de observaciones	1,477		3,518	

* Significativo al 1%; ** al 5%

Fuente: Elaboración propia con base en datos de Instituto Nacional de Estadística, 2002 y 2018.

Los resultados obtenidos indican que en el mercado laboral guatemalteco los diplomas, como credenciales de grados académicos, son utilizados por los empleados a manera de indicadores de las habilidades de los trabajadores, conforme lo postula la teoría de la señalización (Spence, 2002; Stiglitz, 2002). Esta situación también fue comprobada en otros países latinoamericanos, como Colombia (Mora, 2003) y Ecuador (Rivera, 2015).

La estimación del efecto diploma según la variable sexo solo tuvo significancia estadística con el modelo de mínimos cuadrados ordinarios. En el modelo de Heckman no se pudo comprobar la existencia de sesgo de selección en la separación por ambos sexos. Los resultados para los hombres se presentan en el cuadro 5 y muestran la existencia del efecto diploma en los tres niveles educativos analizados.

Cuadro 5		
Guatemala: Estimación del efecto diploma en hombres		
Variable	2002	2018
Área geográfica	0.08159**	0.152360*
Experiencia	0.035748*	0.033528*
Experiencia al cuadrado	-0.000341*	-0.000304*
Secundaria incompleta	0.189189*	0.187474*
Secundaria completa	0.416612*	0.390989*
Universidad incompleta	0.641842*	0.665101*
Universidad completa	1.18861*	0.953471*
Posuniversidad incompleta	1.0025*	1.14122*
Posuniversidad completa	1.67189*	1.25509*
Constante	6.45410*	6.74454*
R ²	0.46	0.42
Números de observaciones	969	2351

* Significativo al 1%

Fuente: Elaboración propia con base en datos de Instituto Nacional de Estadística, 2002 y 2018.

El análisis comparativo no muestra mayor variación en el efecto diploma en el nivel educativo secundario. En los siguientes dos niveles educativos se observa reducción en el monto del efecto diploma y un aumento en el nivel incompleto, en especial en el de posuniversidad, que aumentó de 100% en 2002 a 114% en 2018. Asimismo, el rendimiento entre quienes obtuvieron su título en este nivel se redujo de 167% a 125%, respectivamente.

Los resultados para el sexo femenino se presentan en el cuadro 6, en el que se observa una pequeña reducción

en la variable área, que por ser el resultado positivo corresponde a la urbana, y un aumento de casi medio punto porcentual en la variable experiencia. El efecto diploma presenta resultados diversos según nivel educativo. En el secundario aumentó en los dos años estudiados, tanto para estudios incompletos como completos. En los niveles universitario y posuniversitario completos se produjo una devaluación del título. En el primer caso, el efecto diploma disminuyó de 101% a 95%; y en el segundo, de 193% a 138%, para los años 2002 y 2018.

Cuadro 6		
Guatemala: Estimación del efecto diploma en mujeres		
Variable	2002	2018
Área geográfica	0.14588**	0.139506*
Experiencia	0.031325*	0.037993*
Experiencia al cuadrado	-0.000266*	-0.000364**
Secundaria incompleta	0.229163*	0.242294*
Secundaria completa	0.377755*	0.465152*
Universidad incompleta	0.598934*	0.594597**
Universidad completa	1.01891*	0.945646*
Posuniversidad incompleta	1.17861*	1.22797*
Posuniversidad completa	1.93374*	1.38462*
Constante	6.32862*	6.547950*
R ²	0.43	0.37
Números de observaciones	508	1167

* Significativo al 1%; ** al 5%

Fuente: Elaboración propia con base en datos de Instituto Nacional de Estadística, 2002 y 2018.

Al comparar entre sexos, se observa que el efecto diploma en los dos años investigados es mayor en las mujeres para el nivel de posuniversidad, tanto incompleto como completo. Resultados similares se obtuvieron en investigaciones de Ecuador, en especial en el nivel secundario (Rivera, 2015) y de Colombia para todos los niveles (García, 2019).

En el análisis intertemporal se observa una reducción de los retornos en todas las variables, excepto las de secundaria y posuniversidad incompleta, con respecto a 2002. Las mayores reducciones en el efecto diploma se observan en los niveles educativos secundaria y universidad completa. La reducción de los retornos de la educación ya había sido documentada por un estudio anterior del autor (Díaz 2019), en el que se indicó que dicho fenómeno coincide con la tendencia mundial evidenciada en un estudio del Banco Mundial (2014) que describe una reducción en los retornos a la educación desde la década de 1980, como resultado de un aumento en los años de escolaridad en el mundo. No obstante, dicha reducción no es generalizada como lo demuestran los estudios de Merlo (2009), que encontró aumento en los retornos de la educación en Argentina entre 1995 y 2002, y García (2019) cuya investigación también documentó aumento en los retornos de la educación en Colombia entre 2002 y 2010. Lo mismo aconteció en el estudio realizado por Parodi, Ramírez y Thompson (2017) para República Dominicana en el período 2000-2015.

A pesar de la reducción en el valor del efecto diploma, en Guatemala aún es rentable obtener un título académico, en especial universitario. De hecho, lo es más que

en República Dominicana (Parodi, Ramírez y Thompson, 2017), Colombia (Hernández, 2017) Argentina (Merlo, 2009) y Ecuador (Rivera, 2015), países en el que el efecto diploma para estudios universitarios no supera el 50%, mientras que en Guatemala es mayor del 100%.

La baja en los retornos de la educación se explica a partir de condiciones estructurales del mercado laboral, dado que Guatemala es un país con alta tasa de subempleo visible, de 12% en 2016, y de empleo informal, de casi 70% (INE, 2018), como consecuencia de la baja creación de empleo formal. En el período 2015 a 2018 se generaron alrededor de 30,000 empleos formales cada año (Instituto Guatemalteco de Seguro Social, 2017), en tanto que el número de personas que se incorporaron al mercado laboral, según el número de graduados de nivel diversificado, fue de casi 159,000 (Ministerio de Educación, 2016). Los datos anteriores muestran que, en general, la oferta de empleo excede a la demanda.

Desde otra perspectiva, la baja en el efecto diploma en el período analizado puede obedecer a una pérdida de valor del título por efecto antigüedad, como lo documentó Antelius (2000) para el caso de Suecia. De acuerdo con su investigación, el efecto diploma desapareció después de 4 años para un título universitario. También puede ser resultado de un efecto de sobreeducación o mayor a la requerida por el mercado laboral, como lo evidenció McGuinness (2002) en el caso de Irlanda del Norte. Ambos temas constituyen futuras líneas de investigación para un mercado laboral como el de Guatemala.

Conclusiones

Los datos estadísticos analizados para los años 2002 y 2018 muestran diferencias en favor de los hombres respecto a las mujeres en lo que respecta a años de estudio, experiencia laboral y sueldo.

Los cálculos de los retornos de la educación muestran una reducción de casi dos puntos porcentuales por año de estudio y un aumento de un punto porcentual por año de experiencia laboral, entre los años 2002 y 2018.

Las estimaciones realizadas muestran la existencia del efecto diploma en los niveles educativos secundario, universitario y posuniversitario. El mayor monto del efecto diploma, en los años estudiados, se observa en el nivel de universidad completa respecto al de universidad incompleta.

Los resultados evidencian una devaluación de los títulos académicos, en especial a nivel universitario. A pesar de esto, en Guatemala la obtención de un título universitario provee un alto retorno.

Referencias

- Alejos, L. (2006). "La elección laboral y los retornos a la educación en Guatemala". *Revista de Estudios Sociales*, (73), 1-112.
- Antelius, J. (2000). Sheepskin effects in the returns to education: Evidence on Swedish data. Recuperado el 30 de noviembre de 2020, de <https://swopec.hhs.se/fiefwp/papers/WP158.pdf>
- Banco Mundial. (2011). *Mejores empleos en Guatemala. El rol del capital humano*. Washington: Autor.
- Becker, G. (1962). "Investment in human capital: A theoretical analysis". *The Journal of Political Economy*. 70 (5), 9-49.
- Díaz, G. (2019). "Disminución de los retornos de la educación en Guatemala". *Atlantic Review of Economics* 2 (1), 1-27.
- DIGI. (2014). *Seguimiento a graduados de la Universidad de San Carlos*. Guatemala: USAC.
- Forbes, (2019). Para trabajar en Apple, Google o Netflix ya no es forzoso haber estudiado en la Universidad. Recuperado el 30 de noviembre de 2020, de <https://www.forbes.com.mx/apple-google-y-netflix-no-requieren-empleados-con-titulos-de-4-anos/>
- Fundesa, (2020). *Brechas de talento 2020*. Guatemala: Autor.
- García, M. (2019). *Evolución de los retornos de la educación en Colombia. Período 2002-2010*. [Tesis de maestría, Universidad Externado de Colombia].
- Harmon, C., Oosterbeek, H., & Walker, I. (2003). "The Returns to Education: Microeconomics". *Journal of Economic Surveys*, 17(2), 115–156. <https://doi.org/10.1111/1467-6419.00191>.
- Hernández, L. (2017). Identificación de potenciales efectos diploma a través de regresiones spline: Evidencia para hombres y mujeres año 2017. Recuperado el 30 de noviembre de 2020, de <https://expeditiorepositorio.utadeo.edu.co/handle/20.500.12010/7697>
- Hungerford, T., & Solon, G. (1987). "Sheepskin Effects in the Return to Education". *The Review of Economics and Statistics*, 69(1), 175–177.
- Instituto Guatemalteco de Seguridad Social. (2016). *Boletín de afiliación 2016*. Guatemala: Autor.
- Instituto Nacional de Estadística. (2003). *Encuesta Nacional de Empleo e Ingresos. 2002*. Recuperado el 30 de noviembre de 2020, de <https://www.ine.gob.gt/ine/estadisticas/bases-de-datos/encuesta-nacional-de-empleo-e-ingresos/>
- Instituto Nacional de Estadística (2016). *República de Guatemala. Compendio de educación 2015*. Recuperado el 30 de noviembre de 2020, de <https://www.ine.gob.gt/ine/estadisticas/bases-de-datos/educacion/>
- Instituto Nacional de Estadística (2018). *Encuesta Nacional de Empleo e Ingresos. 2016*. Recuperado el 30 de noviembre de 2020, de <https://www.ine.gob.gt/index.php/encuestas/empleo-e-ingresos>
- Instituto Nacional de Estadística (2019). *XII Censo nacional de población y VII de vivienda 2018*. Recuperado el 2 de diciembre de <https://www.censopoblacion.gt/descarga>
- Klapp, F. y Candia, A. (2016). *Estimación del premio o retorno a la educación en Chile*. Santiago de Chile: Libertad y Desarrollo.
- Layard, R. y Psacharopoulos, G. (1974). "The screening hypothesis and the returns to education", *Journal of Political Economy*, (82), 985-998.
- McGuinness, S. (2002). *Graduate over-education as a Sheepskin effect: Evidence from Northern Ireland*. Working. (Papers Series No. 70). Northern Ireland Economic Research Centre.
- Merlo, J. (2009). *Retornos a la educación durante una depresión económica. Evidencia empírica para la Argentina*. Recuperado el 2 de diciembre de 2020, de http://economia.uc.cl/docs/tesis_jjmerlo.pdf

Mincer, J. (1974). Schooling, experience, and earnings. National Bureau of Economic Research. Recuperado el 2 de diciembre de 2020, de <http://papers.nber.org/books/minc74-1>

Ministerio de Educación (2019). Informe nacional de graduados 2018. Guatemala: Autor.

Mora, J. (2003). "Sheepskin effects and screening in Colombia". Colombian Economic Journal, (1), 97-108.

Ordaz, J. (2007). "México: capital humano e ingresos. Retornos a la educación, 1994-2005". Estudios y perspectivas, (90), 1-70.

Parodi, S., Ramírez, I. y Thompson, J. (2017). Tasa de retorno de la inversión en educación en República Dominicana (2000-2015). Nota técnica del BID; 1325.

Pérez, A. (2003). Educación e ingresos: retornos de la educación en Guatemala. Guatemala: Universidad Rafael Landívar.

Rivera, J. (2015). Retorno a la educación en Ecuador: Entre brechas salariales y mercados especializados. Recuperado el 2 de diciembre de 2020, de <http://repositorio.uasb.edu.ec/handle/10644/4295>

Saidón, M. (2004). Retornos a la educación en Guatemala: descuentos de costos mediante una simulación. Guatemala: Universidad Rafael Landívar.

Spence, M. (2002). "La señalización y la estructura informativa de los mercados". Revista Asturiana de Economía. (25), 49-94.

Stiglitz, J. (2002). "La información y el cambio en el paradigma de la ciencia económica" Revista Asturiana de Economía. (25), 95-164.

Anexo 1

Modelos estimados para el año 2002

Modelo 1: MCO, usando las observaciones 1-1477

Variable dependiente: Insueldo

	Coefficiente	Desv. Típica	Estadístico t	Valor p	
Const	6.82897	0.0520668	131.1579	<0.0001	***
Área	0.0983963	0.0397174	2.4774	0.0133	**
Sexo	0.14917	0.025423	5.8675	<0.0001	***
Experiencia	0.0230712	0.00322511	7.1536	<0.0001	***
experiencia2	-0.000323595	7.41333e-05	-4.3650	<0.0001	***
Secinc	0.201871	0.0360083	5.6062	<0.0001	***
Seccomp	0.404316	0.0308216	13.1180	<0.0001	***
Univinc	0.626869	0.0447432	14.0104	<0.0001	***
Univcomp	1.13032	0.0437554	25.8327	<0.0001	***
Postinc	1.09787	0.184552	5.9488	<0.0001	***
Postcomp	1.74555	0.100497	17.3692	<0.0001	***

Media de la vble. dep.	7.611750	D.T. de la vble. dep.	0.601757
Suma de cuad. residuos	294.0641	D.T. de la regresión	0.447872
R-cuadrado	0.449808	R-cuadrado corregido	0.446055
F(10, 1466)	119.8526	Valor p (de F)	3.1e-182
Log-verosimilitud	-903.8551	Criterio de Akaike	1829.710
Criterio de Schwarz	1887.986	Crit. de Hannan-Quinn	1851.437

Modelo 1: Estimación en dos etapas de Heckit, usando las observaciones 1-3129

Variable dependiente: Insueldo

Variable de selección: trabaja

	Coficiente	Desv. Típica	z	Valor p	
Const	6.45035	0.212002	30.4258	<0.0001	***
Área	0.188061	0.0500611	3.7566	0.0002	***
Sexo	0.303008	0.0910768	3.3270	0.0009	***
Experiencia	0.0370927	0.00655931	5.6550	<0.0001	***
experiencia2	-0.000633159	0.000161149	-3.9290	<0.0001	***
Secinc	0.14658	0.0453954	3.2290	0.0012	***
Seccomp	0.387402	0.0500363	7.7424	<0.0001	***
Univinc	0.595698	0.0602686	9.8841	<0.0001	***
Univcomp	1.13222	0.0703407	16.0962	<0.0001	***
Postinc	1.01864	0.140788	7.2353	<0.0001	***
Postcomp	1.32828	0.122694	10.8260	<0.0001	***
Lambda	0.604429	0.0215042	28.1075	<0.0001	***
Ecuación de selección					
Const	-1.38419	0.123534	-11.2050	<0.0001	***
Área	0.336958	0.0783602	4.3001	<0.0001	***
Sexo	1.33315	0.0538024	24.7786	<0.0001	***
Experiencia	0.0813707	0.00723556	11.2459	<0.0001	***
experiencia2	-0.00197342	0.000149916	-13.1635	<0.0001	***
Secinc	0.289072	0.0785436	3.6804	0.0002	***
Seccomp	0.586214	0.0681609	8.6004	<0.0001	***
Univinc	0.491686	0.102355	4.8037	<0.0001	***
Univcomp	0.854787	0.121681	7.0248	<0.0001	***
Tamhog	-0.0330722	0.0117734	-2.8091	0.0050	***
Otrosing	-0.00011387	2.5346e-05	-4.4926	<0.0001	***
Civil	-0.146637	0.0677096	-2.1657	0.0303	**

Anexo 2

Modelos estimados para el año 2018

Modelo 1: MCO, usando las observaciones 1-3518

Variable dependiente: Insueldo

	Coefficiente	Desv. Típica	Estadístico t	Valor p	
Const	7.13565	0.0262682	271.6458	<0.0001	***
Area	0.148336	0.0179016	8.2862	<0.0001	***
Sexo	0.106364	0.0154725	6.8744	<0.0001	***
experiencia	0.0232042	0.00189059	12.2735	<0.0001	***
experiencia2	-0.00031882	4.10081e-05	-7.7746	<0.0001	***
Secinc	0.200554	0.058252	3.4429	0.0006	***
Secomp	0.415127	0.0171044	24.2702	<0.0001	***
Uninc	0.620409	0.025599	24.2357	<0.0001	***
Unicomp	0.945375	0.0285084	33.1613	<0.0001	***
Postinc	1.18324	0.139615	8.4751	<0.0001	***
Postcom	1.30712	0.0845272	15.4639	<0.0001	***

Media de la vble. dep.	7.902411		D.T. de la vble. dep.	0.538859
Suma de cuad. Residuos	608.8620		D.T. de la regresión	0.416669
R-cuadrado	0.403793		R-cuadrado corregido	0.402093
F(10, 3507)	237.5187		Valor p (de F)	0.000000
Log-verosimilitud	-1906.441		Criterio de Akaike	3834.881
Criterio de Schwarz	3902.703		Crit. de Hannan-Quinn	3859.080

Modelo 1: Estimación en dos etapas de Heckit, usando las observaciones 1-8611**Se han quitado las observaciones ausentes o incompletas: 4800**

Variable dependiente: Insueldo

Variable de selección: Trabaja

	Coefficiente	Desv. Típica	z	Valor p	
Const	7.03621	0.115223	61.0660	<0.0001	***
Area	0.117612	0.0262059	4.4880	<0.0001	***
Sexo	-0.0507534	0.0328005	-1.5473	0.1218	
Experiencia	0.0234212	0.00514631	4.5511	<0.0001	***
Experiencia2	-0.00016752	6.42383e-05	-2.6078	0.0091	***
Secinc	0.259009	0.0834043	3.1055	0.0019	***
Secomp	0.378776	0.025474	14.8691	<0.0001	***
Uninc	0.562271	0.0385899	14.5704	<0.0001	***
Unicomp	0.865067	0.0437611	19.7680	<0.0001	***
Postinc	1.05969	0.207598	5.1045	<0.0001	***
Postcom	1.18638	0.126487	9.3794	<0.0001	***
lambda	-0.617205	0.0900667	-6.8527	<0.0001	***
Ecuación de selección					
Const	-1.22614	0.290244	-4.2245	<0.0001	***
DOMINIO	0.256493	0.0824251	3.1118	0.0019	***
Sexo	0.994122	0.0947065	10.4969	<0.0001	***
Edad	0.117188	0.0158276	7.4040	<0.0001	***
Edad2	-0.00141213	0.000181075	-7.7986	<0.0001	***
Secinc	-0.346858	0.225676	-1.5370	0.1243	
Secomp	0.217823	0.0824068	2.6433	0.0082	***
Uninc	0.337546	0.132695	2.5438	0.0110	**
Unicomp	0.594149	0.197579	3.0071	0.0026	***
Postinc	5.576128308	6721.25	0.0008	0.9993	
Postcom	5.622	2468.83	0.0023	0.9982	
Tamemp	0.00152814	0.00026527	5.7607	<0.0001	***
Otros	-2.81058e-05	1.90335e-05	-1.4766	0.1398	
Tamhog	-0.172816	0.0293056	-5.8970	<0.0001	***
Civil	-0.0942845	0.0963585	-0.9785	0.3278	

JUNTA MONETARIA*

Sergio Francisco Recinos Rivera
Presidente

José Alfredo Blanco Valdés
Vicepresidente

Miembros titulares

Alvaro González Ricci
Ministro de Finanzas Públicas

Roberto Antonio Malouf Morales
Ministro de Economía

José Angel López Camposeco
Ministro de Agricultura, Ganadería y
Alimentación

Hugo Fernando García Gudiel
Electo por el Congreso de la República

Mariano Rubén Ventura Zamora
Electo por las asociaciones empresariales de
comercio, industria y agricultura

Luis Rolando Lara Grojec
Electo por los presidentes de los consejos de
administración o juntas directivas de los
bancos privados nacionales

Luis Antonio Suárez Roldán
Electo por el Consejo Superior de la
Universidad de San Carlos de Guatemala

Miembros suplentes

Sergio de la Torre Gimeno
Electo por las asociaciones empresariales
de comercio, industria y agricultura

Efrén Arturo Rosales Alvarez
Electo por el Consejo Superior de la
Universidad de San Carlos de Guatemala

Luis Fernando Samayoa Delgado
Electo por los presidentes de los consejos de
administración o juntas directivas de los
bancos privados nacionales

Rudy Roberto Castañeda Reyes
Electo por el Congreso de la República

* Al 30 de junio de 2021

AUTORIDADES*

Sergio Francisco Recinos Rivera
Presidente

José Alfredo Blanco Valdés
Vicepresidente

Oscar Roberto Monterroso Sazo
Gerente General

Johny Rubelcy Gramajo Marroquín
Gerente Económico

Jorge Vinicio Cáceres Dávila
Gerente Financiero

Leonel Hipólito Moreno Mérida
Gerente Jurídico

Ivar Ernesto Romero Chinchilla
Gerente Administrativo

FUNCIONARIOS SUPERIORES*

Departamento de Análisis Macroeconómico y Pronósticos
Eddy Roberto Carpio Sam
Director

David René Samayoa Gordillo
Subdirector

Jorge Salvador Samayoa Mencos
Subdirector

Departamento de Investigaciones Económicas
Juan Carlos Castañeda Fuentes
Director

Carlos Eduardo Castillo Maldonado
Subdirector

Departamento de Estadísticas Macroeconómicas
Víctor Estuardo Flores Súchite
Director

Ismael Herlindo Matías Vargas
Subdirector

Departamento de Análisis de Estabilidad Financiera
Héctor Augusto Valle Samayoa
Director

Juan Carlos Catalán Herrera
Subdirector

Departamento de Ejecución de Política Monetaria, Cambiaria y Crediticia
Marco Tulio López Quiñonez
Director

Edvin Ariel Morales y Morales
Subdirector

Departamento Internacional
Víctor Manuel Vásquez García
Director

Neri Alfredo Juracán Par
Subdirector

Departamento de Contabilidad y Sistema de Pagos
Luis Fernando Quintanilla Pereda
Director

Edgar Iván León Ovalle
Subdirector

William Ariel Cano Hernández
Subdirector

Departamento de Emisión Monetaria
Jorge Arturo Rivera Méndez
Director

Carlos Guillermo Pineda Meza
Subdirector

Departamento de Análisis de Riesgo de Reservas Monetarias Internacionales
Leslie Nalinle Sánchez Barrios de García
Subdirectora

Departamento de Tecnologías de Información
Mario Geovanni Cordova Gomar
Director

Luis Arturo González Pineda
Subdirector

Departamento de Servicios Administrativos
Mario Roberto León Ardon
Director

Manuel Lizandro Ramírez Barrios
Subdirector

Departamento de Seguridad
Walter Emilio Barrios Guevara
Director

Kilian René Rayo Saravia
Subdirector

Departamento de Comunicación y Relaciones Institucionales
Herberth Solórzano Somoza
Director

Oscar Jorge Augusto Hernández Ramírez
Subdirector

Departamento de Recursos Humanos
Juan Carlos Estrada Calvillo
Director

Gloria Edelmira Mayen Veliz de Velez
Subdirectora

Asesoría Jurídica
César Augusto Martínez Alarcón
Asesor III

Beatriz Eugenia Ordóñez Porta de Leal
Asesora III

Giovanni Paolo Vitola Mejía
Asesor II

Oficialía de Cumplimiento
Maynor Augusto Ambrosio Higueros
Oficial de Cumplimiento

Walter Israú Cordova Citalan
Oficial de Cumplimiento Suplente

Auditoría Interna
Juan Manuel Melendez Godínez
Auditor Interno

Nelton Adolfo Navarro Aguilar
Subauditor Interno

Planificación y Desarrollo Organizacional
Marco Tulio Juárez Chavarria
Asesor II

Secretaría de la Junta Monetaria
Romeo Augusto Archila Navarro
Secretario

José Fernando Monteros Portillo
Subsecretario

* Autoridades y funcionarios superiores en ejercicio de funciones al 30 de junio de 2021.

Nota: Los nombres y apellidos se incluyen textualmente de acuerdo con la lista proporcionada por la Sección de Planificación y Relaciones Laborales del Departamento de Recursos Humanos del Banco de Guatemala.



Guatemala

- 1) **Ciudad Guatemala**
Biblioteca Central
7ª. avenida, 22-01, zona 1
- 2) Parque Colón
8ª. calle, entre 11 y 12 avenidas, zona 1
- 3) Instituto "Dr. Carlos Federico Mora"
Calzada San Juan, 32-50, zona 7,
colonia Centroamérica
- 4) Parque Navidad
32 avenida y 23 calle, zona 5 (diagonal 34)
- 5) **Amatitlán**
5ª. calle y 4ª. avenida, esquina, barrio La Cruz
- 6) **San José Pinula**
Escuela "Dulce Corazón de María",
sector Puerta Negra, aldea San Luis
- 7) **Santa Catarina Pinula**
Edificio municipal, 1a. calle, 5-50, zona 1

Alta Verapaz

- 8) **Cobán**
Calzada "Rabín Ajau", zona 11, salida a Chisec
Instituto de la Juventud y el Deporte
- 9) **Cobán**
1ª. calle, 5-24, zona 2

Baja Verapaz

- 10) **Rabinal**
4a. avenida, 2-37, zona 3
- 11) **Salamá**
5ª. avenida, 6-21, nivel 2, zona 1

Chimaltenango

- 12) **San Martín Jilotepeque**
Plaza Central, frente a municipalidad
- 13) **Patzún**
3a. calle, 5-48, zona 1, edificio municipal
- 14) **Chimaltenango**
2ª. avenida, 2-20, zona 3, nivel 2
- 15) **Zaragoza**
7a. avenida Norte, No. 3,

Chiquimula

- 16) **Quezaltepeque**
3a. calle y 2ª. avenida, zona 2

- 17) **Ipala**
2a. calle, 3-18, zona 1, nivel 2, edificio municipal

- 18) **Olopa**
Edificio municipal, nivel 2, barrio El Centro

- 19) **Chiquimula**
6ª. avenida, 3-00, zona 1, edificio municipal

El Progreso

- 20) **Guastatoya**
Avenida Principal, contiguo al Banco G&T

- 21) **Morazán**
Barrio Concepción

- 22) **El Jícara**
Edificio municipal, nivel 2

Escuintla

- 23) **Tiquisate**
4a. calle, zona 1, edificio municipal

- 24) **Escuintla**
3ª. avenida, 3-63, zona 1

- 25) **Puerto San José**
Avenida El Comercio

- 26) **Santa Lucía Cotzumalguapa**
5a. calle, 3-39, zona 1, edificio municipal

Huehuetenango

- 27) **San Antonio Huista**
Cantón Central

- 28) **Huehuetenango**
4ª. calle, 5-07, zona 1

- 29) **San Mateo Ixtatán**
Cantón Yolwitz

- 30) **Malacatancito**
1a. calle A, 4-17, zona 1, barrio El Centro

Izabal

- 31) **Puerto Barrios**
7ª. calle y 8ª. avenida, esquina, zona 1,
parque "José María Reyna Barrios"

- 32) **Los Amates**
Edificio municipal

Jalapa

- 33) **Jalapa**
Calle "Tránsito Rojas", 5-46, zona 6, nivel 2

- 34) **San Luis Jilotepeque**
Edificio municipal, barrio El Centro

Jutiapa

- 35) **Asunción Mita**
Instituto Nacional de Educación de Diversificado
- 36) **El Progreso**
Calle Principal y avenida Achuapa, Casa de la Cultura
- 37) **Jutiapa**
4ª. avenida y 7ª. calle, zona 1

Petén

- 38) **Melchor de Mencos**
Escuela Municipal Bilingüe Intercultural barrio El Arroyito
- 39) **San Francisco**
A la par del Puesto de Salud
- 40) **San Luis**
Edificio municipal
- 41) **San Benito**
5a. avenida, entre 8ª. y 9ª. calles, zona 1
- 42) **Flores**
Instituto Nacional de Educación Diversificada Aldea Ixlú

Quetzaltenango

- 43) **El Palmar**
Edificio de la Cruz Roja
- 44) **Coatepeque**
Avenida Ferrocarril, barrio San Francisco, zona 3
- 45) **Quetzaltenango**
12 avenida, 5-12, zona 1

Quiché

- 46) **Pachalum**
Edificio mercado Central, nivel 4
- 47) **Santa Cruz del Quiché**
3ª. calle, 4-00, zona 5, barrio La Sirena
- 48) **Canillá**
Edificio municipal
- 49) **Santa María Nebaj**
3ª. avenida y 7ª. calle, zona 1, cantón Tutz'al

Retalhuleu

- 50) **Champerico**
Avenida del Ferrocarril, a un costado del parque Central, nivel 2

- 51) **San Felipe**
3ª. avenida, 2-44, zona 1, edificio municipal

Sacatepéquez

- 52) **Antigua Guatemala** (cerrada temporalmente)
Portal Las Panaderas
5ª. avenida Norte, No. 2, nivel 2
Edificio del Banco de Guatemala
- 53) **Sumpango**
0 avenida, 1-18, zona 3

San Marcos

- 54) **San Marcos**
9ª. calle, 7-54, zona 1
- 55) **Malacatán**
3ª. avenida, entre 1ª. y 2ª. calles, zona 1, colonia El Maestro
- 56) **San Pablo**
Mercado La Terminal, nivel 2
- 57) **Tecún Umán**
1ª. avenida, entre 3ª. y 4ª. calles, zona 1

Santa Rosa

- 58) **Chiquimulilla**
1ª. calle B y 2ª. avenida, zona 1, edificio municipal
- 59) **Barberena**
Parque Central, 4a. calle y 4a. avenida, zona 1

Guazacapán

- 60) **Guazacapán**
Edificio municipal, nivel 2

Sololá

- 61) **Sololá**
7a. avenida, 8-72, zona 2, nivel 2

Suchitepéquez

- 62) **Mazatenango**
7ª. calle, 3-18, zona 1

Totonicapán

- 63) **Totonicapán**
7a. avenida y 5a. calle, zona 1, nivel 2

Zacapa

- 64) **Zacapa**
4a. calle, 14-32, zona 1, nivel 2
- 65) **Gualán**
Barrio El Centro, edificio municipal, nivel 2
- 66) **Estanzuela**
1a. calle, 2-00, zona 1
- 67) **Río Hondo**
6a. calle, 2-49, zona 1, edificio municipal

* Al 30 de junio de 2021

6 8 3 5 0 3 1 5 4
4 0 1 8 3 6 9 7 1
2 4 6 6 3 6 1 6 7
5 1 2 6 8 5 7 3 3
5 2 7 0 3 0 2 5 1
0 4 4 6 3 2 4 2 2
7 1 3 7 8 0 0 0 7
9 6 3 5 9 3 0 5 2
6 0 8 9 2 1 6 3 3
4 0 5 8 6 0 1 3 2
8 3 4 7 5 1 3 3 0
8 1 0 0 8 9 7 7 4
4 0 2 3 5 6 1 8 8
0 3 5 0 1 9 1 8 5

1.28



¡Trabajando para los guatemaltecos!