

NOWCASTING PARA PREDECIR ACTIVIDAD ECONÓMICA EN TIEMPO REAL: LOS CASOS DE BELICE Y EL SALVADOR

JUAN BARRIOS
Banco Interamericano
de Desarrollo

LUCÍA MARTÍN
Banco Interamericano
de Desarrollo

JULIA ESCOBAR
Banco Interamericano
de Desarrollo

WERNER PEÑA
Universidad de
Kent

JANELLE LESLIE
Banco Interamericano
de Desarrollo



*Belice y
El Salvador*

**Catalogación en la fuente proporcionada por la
Biblioteca Felipe Herrera del Banco Interamericano de Desarrollo**

Nowcasting para predecir actividad económica en tiempo real: los casos de Belice y El Salvador / Juan Barrios, Julia Escobar, Janelle Leslie, Lucía Martín, Werner Peña.
p. cm. — (Monografía del BID; 970)

Incluye referencias bibliográficas.

1. Economic forecasting-Belize. 2. Economic forecasting-El Salvador. 3. Machine learning-Belize. 4. Machine learning-El Salvador. I. Barrios, Juan José. II. Escobar, Julia. III. Leslie, Janelle. IV. Martín Rivero, Lucía. V. Peña, Werner. VI. Banco Interamericano de Desarrollo. Departamento de Países de Centroamérica, Haití, México, Panamá y la República Dominicana. VII. Serie.

IDB-MG-970

Códigos JEL:

E01 Measurement and Data on National Income and Product Accounts and Wealth • Environmental Accounts, E27 Forecasting and Simulation: Models and Applications, C53 Forecasting and Prediction Methods • Simulation Methods

Palabras claves:

Belice, El Salvador, Nowcasting, Pronósticos de Actividad Económica, Machine Learning, PIB trimestral, estadísticas nacionales

<http://www.iadb.org>



Copyright © [2021] Banco Interamericano de Desarrollo. Esta obra se encuentra sujeta a una licencia Creative Commons IGO 3.0 Reconocimiento-NoComercial-SinObrasDerivadas (CC-IGO 3.0 BY-NC-ND) (<http://creativecommons.org/licenses/by-nc-nd/3.0/igo/legalcode>) y puede ser reproducida para cualquier uso no-comercial otorgando el reconocimiento respectivo al BID. No se permiten obras derivadas.

Cualquier disputa relacionada con el uso de las obras del BID que no pueda resolverse amistosamente se someterá a arbitraje de conformidad con las reglas de la CNUDMI (UNCITRAL). El uso del nombre del BID para cualquier fin distinto al reconocimiento respectivo y el uso del logotipo del BID, no están autorizados por esta licencia CC-IGO y requieren de un acuerdo de licencia adicional.

Note que el enlace URL incluye términos y condiciones adicionales de esta licencia.

Las opiniones expresadas en esta publicación son de los autores y no necesariamente reflejan el punto de vista del Banco Interamericano de Desarrollo, de su Directorio Ejecutivo ni de los países que representa.

*Belice y
El Salvador*

NOWCASTING PARA PREDECIR ACTIVIDAD ECONÓMICA EN TIEMPO REAL: LOS CASOS DE BELICE Y EL SALVADOR

JUAN BARRIOS
Banco Interamericano
de Desarrollo

LUCÍA MARTÍN
Banco Interamericano
de Desarrollo

JULIA ESCOBAR
Banco Interamericano
de Desarrollo

WERNER PEÑA
Universidad de
Kent

JANELLE LESLIE
Banco Interamericano
de Desarrollo



*Belize y
El Salvador*



Contenido

07 Resumen
Ejecutivo

09 Introducción

13 Selección de
Belice y
El Salvador

17 *Nowcasting* para
obtener información
oportuna

19 Técnicas de *machine
learning* para ejercicios
de *nowcasting*

29 Datos

33 Resultados

45 Acompañamiento
Institucional

47 Reflexiones
finales

48 Bibliografía

50 Anexos

Agradecemos a Emory Ford y Rumile Arana del Banco Central de Belice (CBB por sus siglas en inglés) por darnos acceso a estadísticas de producción sectorial. Además, estamos agradecidos con el staff del Departamento de Investigación del CBB y del Instituto de Estadísticas de Belice (SIB por sus siglas en inglés), así como con María Deza (IADB) por los comentarios y sugerencias provistas durante presentaciones preliminares de este ejercicio. Todos los posibles errores son responsabilidad de los autores.



*Belice y
El Salvador*



Resumen Ejecutivo

La capacidad de predicción de corto plazo y la toma de decisiones en tiempo real bajo un alto grado de incertidumbre han cobrado una relevancia sin precedentes con la pandemia de la COVID-19. Durante el último año, el reto para los gobiernos de reaccionar rápida y efectivamente para atender los efectos de la pandemia en un entorno turbulento ha evidenciado la necesidad de contar con instrumentos que permitan anticipar el rumbo de la economía de manera ágil.

Una característica destacada de esta incertidumbre es que muchas estadísticas claves son publicadas con un retraso considerable, se revisan posteriormente y están disponibles en frecuencias diferentes. Por lo tanto, los hacedores de política, economistas y profesionales de negocios, cuyo trabajo es rastrear potenciales cambios económicos, tienen que examinar una gran cantidad de variables relevantes con el objetivo de construir pronósticos precisos.

Bajo este contexto, las técnicas de *nowcasting* se presentan como una herramienta efectiva para llenar el vacío en el rezago de la publicación de indicadores macroeconómicos, explotando la disponibilidad de otros indicadores cuya publicación reviste una mayor frecuencia. La base detrás de estas técnicas es la utilización de variables semi o altamente relacionadas con el PIB que sean publicadas de forma semanal, mensual o trimestral para obtener señales en tiempo real de la evolución del producto y obtener un pronóstico preciso de su valor en el trimestre de interés.

Este documento presenta modelos de *machine learning* ajustados para producir un *nowcasting* del PIB trimestral en Belice y El Salvador. Esta iniciativa forma parte del esfuerzo que el Banco Interamericano de Desarrollo (BID) ha realizado desde el inicio de la pandemia para desarrollar instrumentos de monitoreo econó-

mico oportunos. Los resultados muestran que las técnicas de *machine learning* son capaces de generar pronósticos del PIB trimestral precisos para dos economías estructuralmente diferentes en un contexto económico con alta volatilidad.

El modelo con mayor eficiencia predictiva para Belice anticipó una caída anual del PIB de 22.9% en el segundo trimestre de 2020 frente a la cifra observada de 23.9%; un descenso de 15.0% en el tercer trimestre comparado con la cifra observada de 12.8%; y una contracción de 14.2% en el último trimestre de 2020 contra la cifra real de 13.1%. En el caso de El Salvador, el mejor modelo pronosticó una contracción de 17.8% frente a un observado de -19.4% en el segundo trimestre de 2020; una caída predicha por el modelo de 8.0 % comparado con el observado de 9.9% en el tercer trimestre; y una caída anticipada de 2.3% en el último trimestre del año contra la cifra observada de -2.3%. Para el primer trimestre de 2021, los modelos predicen un descenso inter-anual de 6.8% para Belice (comparado con el observado de -8.4%) y un crecimiento inter-anual de 1.2% para El Salvador (comparado con el observado de 3.0%).

Debido a que la calibración de los ejercicios de *nowcasting* es un proceso dinámico que se perfecciona en el tiempo, en el BID confiamos en que este documento contribuirá al trabajo continuo de los Gobiernos y las agencias estadísticas de Belice y El Salvador para contar con mejores predicciones económicas que informen las decisiones de política en sus países.



*Belize y
El Salvador*



Introducción

En enero 2020 el Fondo Monetario Internacional (FMI, 2020) proyectaba un crecimiento para la economía mundial de 3.3% para ese mismo año, debido al comportamiento positivo de los mercados y la expectativa de una mejora en las relaciones comerciales entre China y Estados Unidos. Para Latinoamérica y el Caribe (LAC) se proyectaba una modesta recuperación, con un crecimiento esperado de 1.6% respecto al 0.1% de 2019. Luego de transcurridos apenas tres meses, la Organización Mundial de la Salud (OMS) declaró que el virus COVID-19 era una pandemia, y con esto el mundo experimentó uno de los cambios más radicales del último siglo que tomó desprevenido a los Gobiernos, y del cual se desconocían sus implicaciones y efectos sociales y económicos.

A más de un año del comienzo de la pandemia, la contracción económica ha sido profunda, así como los efectos en las de por sí debilitadas finanzas públicas. Los gobiernos de LAC han enfrentado una crisis sanitaria histórica, implementando confinamientos estrictos y prolongados frente a la fragilidad de sus sistemas de salud. Se estima que la caída del PIB regional en 2020 fue del 7%, prácticamente cuatro veces más que durante la crisis financiera de 2009. Al mismo tiempo, el colapso de los ingresos fiscales y un fuerte aumento en el gasto¹ para hacer frente a la pandemia han llevado a una ampliación de los déficits fiscales, generando un aumento y encarecimiento de la deuda pública.

La incertidumbre generada por la pandemia y el reto de reaccionar rápidamente para atender sus efectos mediante programas de asistencia en un entorno turbulento, han evidenciado la necesidad de contar con instrumentos de monitoreo eficaces. Pasado un año del inicio de la pandemia, la incertidumbre sobre los riesgos que amenazan el panorama macroeconómico en el mediano y largo plazo continúan. Por ejemplo, las medidas de confinamiento se han

relajado, pero el riesgo de nuevas restricciones dominará la formulación de políticas hasta que la vacunación se generalice. Esto determinará la velocidad de la recuperación de la actividad económica, y con ello, la restauración en la sostenibilidad de las finanzas públicas.

En este contexto, el BID y El Departamento de Países de Centroamérica (CID), Haití, México, Panamá y la República Dominicana, han trabajado desde el inicio de la pandemia en desarrollar herramientas que nos permitan tener una mayor claridad sobre las perspectivas económicas. Con este objetivo, el BID ha calibrado modelos de *machine learning* para producir ejercicios de *nowcasting* del PIB trimestral en dos países piloto. Una de las principales ventajas de los ejercicios de *nowcasting* es que permiten predecir el comportamiento de variables económicas como el PIB a partir de datos de alta frecuencia, llenando la brecha existente entre la terminación de un periodo (normalmente un trimestre) y la publicación de la variable en cuestión por parte de las autoridades estadísticas.

El objetivo de este documento es presentar los modelos de *machine learning* utilizados en los ejercicios de *nowcasting* y su aplicación y resultados en dos países de Centroamérica: Belice y El Salvador. Con ello, el BID busca proveer información valiosa y oportuna sobre el rumbo de la economía de ambos países tanto a sus respectivos gobiernos como a las principales partes interesadas que facilite la toma de decisiones. En el caso de Belice, el Instituto de Estadísticas de Belice (SIB, por sus siglas en inglés) publica el PIB trimestral aproximadamente dos meses después del vencimiento de cada trimestre, mientras que el Banco Central de Reserva de El Salvador (BCR) lo publica 90 días después. En ambos casos, el *nowcasting* del PIB trimestral puede suplir la falta de información en esa brecha de 60-90 días.

¹ Entre las principales medidas adoptadas se incluyeron asignaciones presupuestales adicionales, transferencias de efectivo a hogares y empresas, el relajamiento de las reglas fiscales, el recorte o diferimiento del pago de impuestos y el pago directo de parte de la nómina de las empresas, entre otros.

Además de producir pronósticos del PIB trimestral significativamente precisos para ambos países, los resultados que se muestran en este documento destacan la capacidad de los modelos de *machine learning* para producir proyecciones en un contexto económico con alta volatilidad e incertidumbre tanto a nivel nacional como internacional. Además, una ventaja importante de estos modelos es que son más adecuados para aprender a reconocer caídas en el PIB que no se han observado en el pasado y, al hacerlo, pueden producir resultados más precisos en comparación con las técnicas econométricas estándar.

Sin embargo, es importante tener en cuenta que estos ejercicios se basan en la calidad de los datos preliminares utilizados para el pronóstico; en otras palabras, el pronóstico inmediato se basa en el supuesto de que las cifras preliminares no cambian drásticamente después de las revisiones. Asimismo, los resultados confirman que los modelos de *machine learning* son una buena alternativa para producir ejercicios precisos de predicción inmediata en economías pequeñas donde aún quedan algunos desafíos en términos de recopilación y disponibilidad de datos.

Este documento está estructurado en ocho secciones. Siguiendo a esta introducción, la segunda sección describe las razones por la que Belice y El Salvador fueron seleccionados como los dos países piloto, así como la capacidad estadística disponible en cada caso. La tercera sección define las técnicas de *machine learning* utilizadas en los ejercicios de *nowcasting*. La cuarta sección profundiza en cada uno de los métodos de *machine learning* empleados en este documento. La quinta sección describe los datos utilizados en cada país y particularidades relacionadas a los mismos. La sexta sección presenta los resultados de los métodos de predicción y se presenta la comparación de estos en términos de su eficiencia predictiva. En la séptima sección se detalla el proceso de colaboración con autoridades y fortalecimiento institucional en los países pilotos. Finalmente, la octava sección presenta algunas conclusiones y lecciones aprendidas en el uso de las herramientas de *machine learning* para producir *nowcasting* del PIB trimestral.





Las técnicas de *nowcasting* se presentan como una herramienta efectiva para llenar el vacío en el rezago de la publicación de indicadores macroeconómicos



*Belize y
El Salvador*



Selección de Belice y El Salvador

La selección de los dos países piloto para este ejercicio de *nowcasting* entre los países de CID se basó en comprobar la efectividad de estos métodos en dos economías que, aunque guardan ciertas similitudes, presentan diferencias estructurales significativas, como es el caso de Belice y El Salvador. Si bien es cierto que las medidas implementadas en prácticamente todos los países para contrarrestar la crisis sanitaria y económica tienen implicaciones que requieren una medición frecuente y oportuna, la selección de Belice y El Salvador tiene como objetivo probar la eficacia de los modelos para generar resultados confiables en todos los países independientemente de su estructura productiva.

En las siguientes subsecciones se describe brevemente el contexto socioeconómico de Belice y El Salvador para que el lector pueda comparar las similitudes y diferencias entre ambos. Esencialmente, aunque los dos países poseen economías pequeñas y abiertas ubicadas en América Central, la diferencia en el tamaño de sus economías es considerable, además de que Belice posee lazos históricos y comerciales con el Caribe que El Salvador no comparte. Entre otros de los contrastes más relevantes destacan los sectores económicos que constituyen la base de sus aparatos productivos, socios comerciales, la situación fiscal, las fuentes de financiamiento disponibles, el efecto de la pandemia, y los retos que los países enfrentan. Más importante aún, existen diferencias sustanciales en las capacidades estadísticas de estos países. Pese a esto, y como se verá en la quinta sección de este documento, los resultados en términos de predicción del PIB trimestral confirman que la metodología utilizada es capaz de producir resultados confiables en economías que son estructuralmente distintas.

Belice: Contexto Socioeconómico

Belice posee una economía pequeña y abierta localizada en Centroamérica que depende fuertemente de la producción y exportación de bienes primarios y turismo. En 2019, el PIB de Belice ascendió a US\$1.9 mil millones, el menor tamaño entre los países miembros del BID, mientras que la población era de poco más de 417 mil habitantes, la tercera menor población en este grupo de países.² El turismo es el principal sector económico, con una participación en el PIB de aproximadamente 37.2% en 2019.³ Esta industria representa 39.3% del empleo total y 48% del total de exportaciones de bienes y servicios. Previo a la pandemia, alrededor de 70% de los visitantes al país provenían de Estados Unidos. La segunda industria de mayor importancia es la agricultura, la cual representa alrededor de 10% del PIB, emplea a más de 15% de la fuerza laboral empleada y genera más de 80% de las exportaciones de bienes. El Reino Unido es el principal destino de las exportaciones de bienes, con 34% del total en 2020, seguido de Estados Unidos (22%) y países CARICOM (17%).

Debido a su dependencia económica en el turismo, Belice ha sido uno de los países más afectados por la pandemia a nivel mundial. En 2020, la economía sufrió una contracción de 14.1%, la mayor caída en la actividad económica en la historia del país ocasionada por un descenso interanual de 70% en la actividad turística y las restricciones impuestas a la movilidad interna. Este golpe sin precedentes añadió presión a una economía cuyo crecimiento ha sido bajo en las últimas décadas, llevando el tamaño de la economía, en términos constantes, a los niveles de 2011. El ingreso per cápita cayó de US\$4,699 en 2019 a

² Después de Barbados y Bahamas.

³ Estos porcentajes consideran los efectos directos e indirectos del turismo y corresponden a 2019.

US\$3,944 en 2020 y el desempleo se estima en 13.7% de la población empleada. En medio de la pandemia, los huracanes Eta e Iota azotaron el país, causando daños cercanos al 0.4% del PIB y profundizando los retos económicos y sociales.

Como resultado del impacto de la pandemia y los huracanes, en 2020 Belice registró brechas fiscales históricas y un aumento de la deuda. Se estiman déficits primarios y globales del 8.3% y 10.8% del PIB en 2020, respectivamente. Aunque Belice no cuenta con una regla fiscal, el pago de la deuda externa de bonos está asociado al cumplimiento de objetivos fiscales. Su incumplimiento desde 2019 desencadenó el pago trimestral, en lugar de semestral, de los cupones del “*Superbono*”. El nivel de deuda tuvo un incremento abrupto desde un 97.5% del PIB en 2019 hasta un 125.8% del PIB en 2020. La frágil situación fiscal llevó a una rebaja de la calificación de S&P (a CC) y de la calificación de Moody’s (a Caa3), así como a un salto del EMBI de 1,042 puntos básicos en abril a 1600 al inicio de julio de 2020 (actualmente se encuentra en 1,406 puntos básicos).

El Salvador: Contexto Socioeconómico

El tamaño de la economía de El Salvador es 14 veces mayor que la de Belice (US\$27 mil millones en 2019), aunque comparado con otros países de Centroamérica como Costa Rica, Panamá o República Dominicana continúa siendo considerada una economía pequeña.⁴ La economía salvadoreña es altamente dependiente del desempeño de los Estados Unidos y de las remesas, poco diversificada y dominada por el sector terciario (70% del PIB)⁵, y en la cual dos de cada tres ocupados son informales (DIGESTYC, 2020).

El país ha observado un crecimiento históricamente débil que lo ha mantenido en la categoría de ingreso medio-bajo durante treinta años⁶ y que ha limitado las oportunidades económicas para la población, y un aumento permanente de la vulnerabilidad social⁷ y fiscal, que ha ocasionado un elevado flujo migratorio de miles de ciudadanos salvadoreños al exterior, principalmente, hacia los Estados Unidos. En

materia fiscal, a pesar del proceso gradual de consolidación fiscal de la década pasada, el nivel de endeudamiento público es alto (MH, 2021)⁸ y el costo de financiamiento es creciente. Esta dinámica de deuda, combinada con el bajo crecimiento económico, limita el margen de maniobra fiscal frente a choques externos y a los desastres naturales.

Como resultado de las medidas de confinamiento frente a la pandemia y el choque externo del menor crecimiento de Estados Unidos, la economía salvadoreña se contrajo 7.9% en 2020, una de las caídas más abruptas en la región centroamericana. Las exportaciones de bienes experimentaron un descenso anual de 15%, similar a la reducción del monto exportable durante la crisis financiera de 2009. Un importante amortiguador fueron las remesas familiares que en los primeros meses de la pandemia sufrieron una caída estrepitosa cercana a 40%, pero a medida que Estados Unidos otorgó los paquetes fiscales de alivio económico a los hogares iniciaron un proceso de recuperación que permitió un crecimiento de 4.7% al cierre del año. A pesar de la recuperación de las remesas, la contracción del producto y el empleo formal contribuyeron a un incremento de la pobreza (DIGESTYC, 2021) y la desigualdad (BID, 2021).

El deterioro económico y las medidas presupuestarias para atender las demandas sanitarias y de alivio económico han impactado la situación fiscal. En 2020, el déficit fiscal se triplicó hasta 10% del PIB, mientras que la deuda observó un aumento de 18 puntos porcentuales, alcanzando un nivel de 87.9% del PIB al cierre del año (MH, 2021).

Capacidad Estadística de Belice y El Salvador

En los ejercicios de *nowcasting* un aspecto de crucial importancia es la cantidad y calidad de información disponible para calibrar los modelos. En el caso del PIB trimestral, este ejercicio requiere contar con información de variables de alta frecuencia (por ejemplo, información mensual o semanal) que tengan relación con los movimientos trimestrales de la producción.

⁴ El Salvador representa el 10.6% de la población y el 7.5% del PIB de la región de Centroamérica, Panamá y República Dominicana.

⁵ Banco Central de Reserva de El Salvador (BCR).

⁶ El Banco Mundial clasifica las economías del mundo en cuatro grupos de ingreso per cápita: alto, mediano alto, mediano bajo y bajo. En 1987 El Salvador se encontraba junto a 18 economías de ALC en el grupo de países de ingreso medio-bajo. En 2019 sólo 4 economías no habían pasado a un nivel de ingreso superior, entre ellas El Salvador.

⁷ Previo a la crisis de la Covid-19, 2 de cada 3 salvadoreños eran pobres o continuaban expuestos a caer en situación de pobreza frente a cambios negativos en el crecimiento y/o en las remesas.

⁸ En 2020 la deuda representó 85.8% del PIB y para el 2021 se estima que aumente a 88.6% del PIB.


En el caso de Belice, la disponibilidad de información es un reto importante. El Instituto de Estadísticas de Belice (SIB por sus siglas en inglés) publica información sobre el PIB trimestral aproximadamente dos meses después de vencido cada trimestre; asimismo, publica de forma regular información sobre comercio exterior y precios. Por su parte, el Banco Central de Belice (CBB por sus siglas en inglés) publica información regular sobre agregados monetarios y financieros, comercio exterior y producción sectorial. Asimismo, la Junta de Turismo de Belice (BTB por sus siglas en inglés) mantiene información mensual actualizada sobre entradas y salidas de personas al país. A pesar de estas capacidades estadísticas, en casos como la producción sectorial o estadísticas fiscales (por ejemplo, ingresos tributarios) la información mensual se publica con intervalos que limitan su disposición para realizar ejercicios de *nowcasting* en tiempo real. En la misma vía, no hay acceso público a datos mensuales del número de ocupados en el sector formal de la economía, así como información mensual sobre producción y consumo de energía, las cuales son variables que en ejercicios de *nowcasting* generalmente muestran una fuerte asociación con el

PIB trimestral⁹.

En el caso de El Salvador, el Banco Central de Reserva publica de forma mensual una variedad de índices de producción, estadísticas del comercio exterior y estadísticas fiscales. Asimismo, el Instituto Salvadoreño del Seguro Social (ISSS) publica información mensual sobre el número de cotizantes activos (proxy de empleo formal) con un retraso de uno o de un mes y medio, lo que permite incluir esta información en la predicción de la producción trimestral.

Las capacidades estadísticas descritas se reflejan en el indicador de desempeño estadístico del Banco Mundial para varios países de Centroamérica, en el cual El Salvador ocupa la tercera posición, mientras que Belice se encuentra en la octava posición. En este sentido, la producción de los ejercicios de *nowcasting* en ambos países debe tener presente las limitaciones y retos que las capacidades estadísticas presentan.

INDICADOR DE DESEMPEÑO ESTADÍSTICO



Fuente: Nivel General de Capacidad Estadística. Banco Mundial (2021).

⁹ Debe tenerse presente que, en el caso de Belice, el Instituto de Estadística se encuentra trabajando en la estimación de una nueva serie de Producto Interno Bruto, la cual se espera que sea publicada en los próximos meses. Los modelos aquí presentados pueden ser fácilmente recalibrados para producir ejercicios de *nowcasting* con la nueva serie.



*Belize y
El Salvador*



Nowcasting para obtener información oportuna

El término *nowcasting* resulta de la combinación de las palabras “now” y “forecasting”, cuyo significado en español es ahora y pronosticando, respectivamente. Estas palabras se utilizan para demostrar explícitamente que el objetivo de este tipo de ejercicio es pronosticar una variable económica en tiempo real cuando la misma aún no ha sido estimada y/o publicada (Tiffin, 2016). Esto es precisamente por lo que los ejercicios de *nowcasting* han atraído mucha atención recientemente, especialmente por parte de los hacedores de política, institutos de estadística y bancos centrales. Variables macroeconómicas como el PIB son publicadas con un rezago de dos o tres meses en la mayoría de los países de LAC, lo cual restringe, de alguna manera, la información disponible de los hacedores de política pública y todas las partes interesadas para tomar decisiones en el corto plazo. Por lo tanto, cuando se evalúa la situación de la economía en tiempo real, se recurre a datos que han sido publicados en el pasado y que no representan las condiciones actuales, lo que no es un ejercicio óptimo en un contexto de alta volatilidad.

Los ejercicios de *nowcasting* permiten llenar el vacío en el rezago de la publicación de indicadores macroeconómicos explotando la disponibilidad de otros indicadores cuya publicación reviste de una mayor frecuencia. La base detrás de estos modelos es utilizar variables que están semi o altamente correlacionadas con el PIB que sean publicadas de forma semanal, mensual o trimestralmente para obtener señales en tiempo real de la evolución del PIB y producir un pronóstico preciso del valor del producto en el trimestre de interés.

Con el desarrollo de herramientas de *machine learning*, el cual puede ser definido como una aplicación estadística que aprende como mejorar su propio desempeño con el fin de producir resultados precisos, los ejercicios de *nowcasting* basados en algoritmos supervisados han cobrado popularidad. Estos algoritmos de aprendizaje supervisado tienen como objetivo captar la fortaleza de la relación entre la variable objetivo y un conjunto de predictores, explotando las características de los predictores y su interacción con la variable objetivo. Entre las técnicas de aprendizaje supervisado, las más utilizadas incluyen las regresiones penalizadas y los árboles de decisión. En particular, ambas técnicas se han utilizado para predecir el PIB trimestral.

Por ejemplo, Tiffin (2016) implementa regresiones penalizadas y algoritmos basados en árboles de decisión (Random Forest) para producir un *nowcasting* del PIB trimestral para Líbano. Jung et al (2018), Bolhuis y Rayner (2020a) y Bolhuis y Rayner (2020b) discuten el uso de técnicas de aprendizaje automático, incluyendo regresiones penalizadas y técnicas con base en árboles de decisión, para predecir variables macroeconómicas. Estos autores resaltan las siguientes ventajas de aplicar técnicas de aprendizaje automático para predecir el PIB trimestral: (i) los modelos de *machine learning* priorizan el desempeño fuera de la muestra; (ii) estos modelos están mejor equipados para tratar no linealidades presentes en los datos; (iii) su flexibilidad les permite modelar relaciones complejas entre variables.¹⁰

En este documento se implementan técnicas de *machine learning* para producir un *nowcasting* del PIB trimestral de Belice y El Salvador.

¹⁰ Estas características permiten que los modelos de aprendizaje automático eviten los problemas clásicos presentes en los métodos tradicionales de predicción inmediata, entre ellos: presencia de colinealidad entre predictores, diferencias en la dimensión de los datos, relevancia de predictores y presencia de no linealidades (Bolhuis y Rayner, 2020b).



*Belize y
El Salvador*



Técnicas de *machine learning* para ejercicios de nowcasting

A continuación, se describen de forma breve los métodos utilizados para realizar el *nowcasting* del PIB trimestral de Belice y El Salvador. Los seis métodos utilizados en los ejercicios son: Random Forest (RF), Gradient Boosting Machine (GBM), Redes Neuronales, regresión Lasso, regresión Ridge y regresión Elastic Net. Debe tenerse presente que esta sección presenta los métodos de forma muy general, para una presentación exhaustiva de los mismos se debe consultar la literatura relevante.

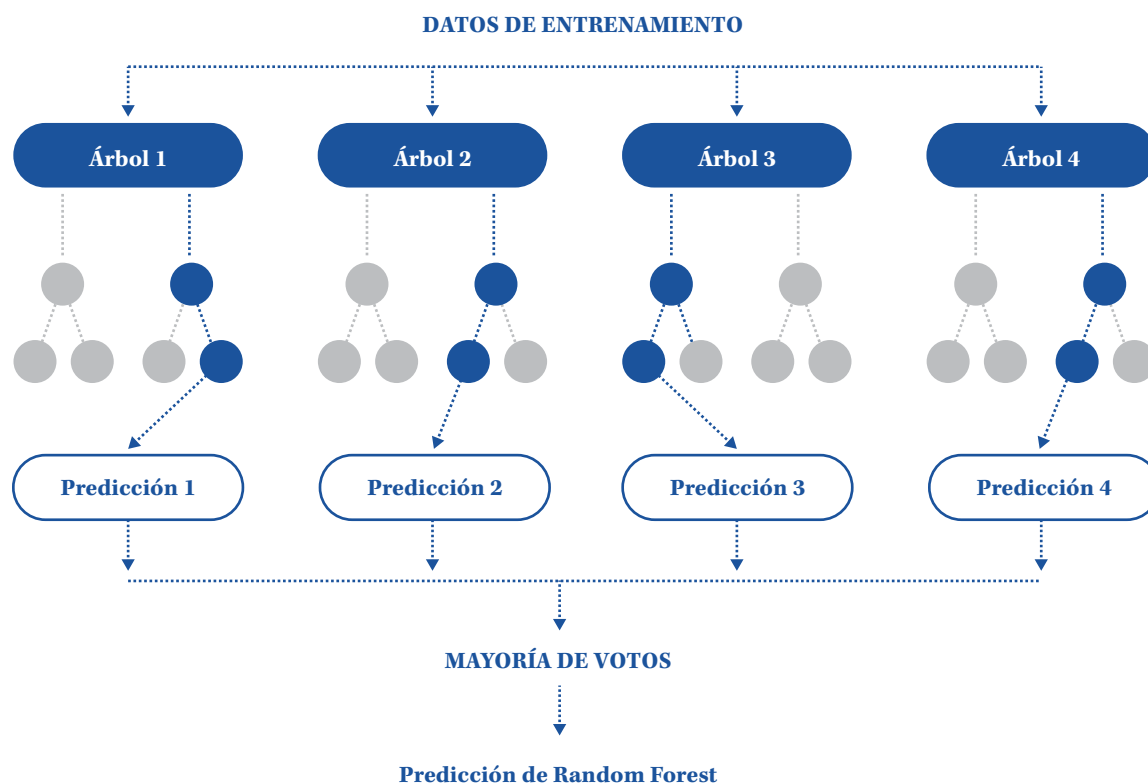
Random forest

Este método tiene como base la construcción de árboles de decisión a partir de las variables contenidas en una matriz X y una selección aleatoria de atributos. En términos sencillos, la técnica de random forest implica la selección aleatoria uniforme y con reemplazo de diferentes sub-muestras o N casos de los datos contenidos en una matriz X los cuales sirven para entrenar y hacer crecer cada árbol que hace parte del bosque. Random forest se diferencia de otras técnicas basadas en árboles de decisión en que en cada nodo se da una selección aleatoria de variables o *features*, las cuales a su vez se utilizan para dividir cada nodo (Breiman, 2001). En esta medida, cada árbol produce una predicción de la variable objeti-

vo, en nuestro caso el PIB trimestral, y en conjunto el modelo elige la mejor predicción que precisamente es la que obtiene “más votos” en el bosque de árboles de decisión (agregación bootstrap) (véase figura 1). En comparación a otros métodos, random forest posee la ventaja de acumular las predicciones de los árboles que conforman el bosque, lo que, en conjunto con la selección de los árboles con la menor tasa de error, permite obtener un buen grado de protección contra los errores que cada árbol puedan generar de forma individual (esto siempre que la correlación entre los árboles sea baja). Así, el método *random forest* divide a los datos contenidos en X en una serie de regiones de forma recursiva y con base en criterios contenidos en $X_1, X_2, X_3 \dots X_r$, las cuales en conjunto con una selección aleatoria de predictores producirán un pronóstico de la variable objetivo, luego con el objetivo de lograr predicciones óptimas cada región de X debe ser aquella que optimice la pureza del conjunto de datos de acuerdo a las clases k . Luego, la variable dependiente se obtiene como el promedio de las regiones usando las siguientes expresiones (Tiffin, 2016):

$$\hat{f}(x) = \sum_m \hat{c}_m I(x \in X_r); \hat{c}_m = \text{avg}(y_i | x_i \in X_r) \quad (1)$$

FIGURA 1. REPRESENTACIÓN SIMPLIFICADA DE LA TÉCNICA DE RANDOM FOREST



Fuente: Adaptación de Chakure (2019).


De acuerdo con Breiman y Cutler, la técnica de random forest posee, entre otras, las siguientes ventajas: (i) es eficiente a la hora de manejar grandes bases de datos con una gran cantidad de variables; (ii) provee una estimación de qué variables son importantes en la clasificación y (iii) genera una estimación interna no sesgada del error de generalización a medida que avanza la construcción del bosque. Entre las principales desventajas de esta técnica se

encuentran: interpretación de resultados más allá de los pronósticos se vuelve complicada; asimismo, su entrenamiento, en especial el tuning de los hiper-parámetros, es computacionalmente demandante. Para la calibración de este modelo se afinaron los hiper-parámetros y se utilizó la técnica de validación cruzada (*cross-validation*) con el objetivo de entrenar el modelo y obtener el mejor desempeño fuera de la muestra.

Recuadro 1: Árbol de regresión

Siguiendo a Tiffin (2016), es importante definir el funcionamiento de los árboles de regresión que se encuentran a la base de la técnica de Random Forest y de Gradient Boosting Machine (como se verá más adelante). Las figuras incluidas en este recuadro facilitan explicar el funcionamiento de los mismos. Supongamos que se tiene un predictor x y una variable de respuesta y en una base de datos con N observaciones. Inicialmente, los datos se encuentran en la misma

agrupación o base de datos. El árbol de regresión inicia con la primera partición de la base de datos con base en características propias de la información contenida en la base de datos y particularmente en la variable (o variables) regresora. Supongamos que en este primer paso 100 es un punto que permite separar de forma clara la información contenida en la base de datos en dos grupos (atendiendo la minimización de la desviación general de la media en cada una de las particiones). Esta primera partición de pie a particiones posteriores de la información con base en reglas que permiten separar los subgrupos en nuevas ramas hasta que se llega a un tamaño mínimo del nodo, el cual se determina a posteriori (en las figuras de abajo, la predicción del árbol de regresión (arriba) se presenta en el panel inferior). Así, los árboles de regresiones estiman el valor de la variable de respuesta obteniendo el valor medio de la misma de cada nodo. En lo que respecta al tamaño del árbol (número de participaciones de los nodos), se debe realizar un balance entre ajuste dentro de la muestra (*in-sample*) y fuera de la muestra (*out-of-sample*), ya que hacer crecer los árboles en su totalidad puede derivar en un sobre ajuste que da primacía al ajuste dentro de la muestra por sobre el ajuste fuera de la muestra, lo cual tiene como consecuencia la producción de pronósticos no precisos. Para evitar el sobre ajuste los árboles de regresión se “podan” de forma óptima con el objetivo de mejorar el pronóstico fuera de la muestra a costa del desempeño dentro de la muestra.



Fuente: Tiffin (2016).

Recuadro 2:

Validación cruzada (cross validation)

La validación cruzada es una técnica que permite evaluar y optimizar el probable desempeño fuera de la muestra del modelo calibrado. Básicamente, esta técnica consiste en dividir la base de datos con la que se trabaja en diferentes bloques (folds), y escoger una sub-muestra de ellos como grupo de testeo, mientras que los bloques restantes son utilizados para el entrenamiento del modelo. Luego, con el modelo calibrado con los bloques de entrenamiento se procede a obtener las predicciones del mismo y se compara con la data de testeo, ello con el fin de obtener el error de predicción. Este procedimiento se repite una y otra vez con todas las combinaciones posibles de los bloques de entrenamiento y testeo manteniendo record de los errores de predicción. De esta forma, se escoge el modelo, y sus parámetros, que reducen el error de predicción a su mínimo valor en todas las combinaciones posibles. Así, se obtiene un modelo predicción que optimiza el desempeño fuera de la muestra (Tiffin, 2016).

Gradient Boosting Machine

La técnica de Gradient Boosting Machine implica la conformación de un conjunto de árboles de decisión en el que la idea es acumular y entrenar “modelos de predicción débil”¹¹ para que, a través de un modelo conjunto (*ensemble*) con pesos heterogéneos, obtener una predicción precisa de la variable de interés. Los modelos de predicción son entrenados utilizando los errores del modelo que representa la acumulación (*ensemble*) de árboles de predicción débil hasta un momento dado (Natekin y Knoll, 2013). En este sentido, los modelos subsecuentes permiten clasificar observaciones que los modelos anteriores no clasificaban de forma correcta; por ello, los modelos de predicción débil mejoran sucesivamente el rendimiento de la regresión en comparación con la del modelo anterior (énfoque progresivo por etapas).¹² Así, la predicción realizada por cada árbol agregado se acumula en conjunto con la secuencia de predicciones de los árboles anteriores en un esfuerzo por corregir o mejorar la salida final del modelo. Siguiendo a Boehmke y Greenwell (2020) la metodología del Gradient Boosting Machine se puede resumir en los siguientes pasos:

1. Ajustar una regresión con un árbol de regresión $y = F_1(x)$
2. Se obtienen los residuos de este árbol y luego los mismos se utilizan para ajustar el siguiente árbol $F_2(x) = F_1(x) + e_1$
3. De la misma forma se obtienen los residuos del árbol $F_2(x)$ y se ajusta el siguiente árbol $F_3(x) = F_2(x) + e_2$
4. El proceso continúa hasta que una métrica de *cross-validation* lo detiene

Siguiendo este proceso Z número de veces (Z número de árboles) obtenemos un modelo aditivo por etapas expresado por la ecuación 2:

$$F(x) = \sum_{z=1}^Z F_z(x) \quad (2)$$

¹¹ Un modelo de predicción débil es un modelo cuyo rendimiento no es significativamente mejor que el rendimiento que se podría obtener por casualidad (Brownlee, 2016). El uso de modelos de predicción débiles tiene algunas ventajas en comparación con modelos de predicción precisos: no es exigente desde el punto de vista computacional, los modelos aprenden lentamente basándose en conjuntos anteriores y ayuda a evitar el problema común del sobreajuste.

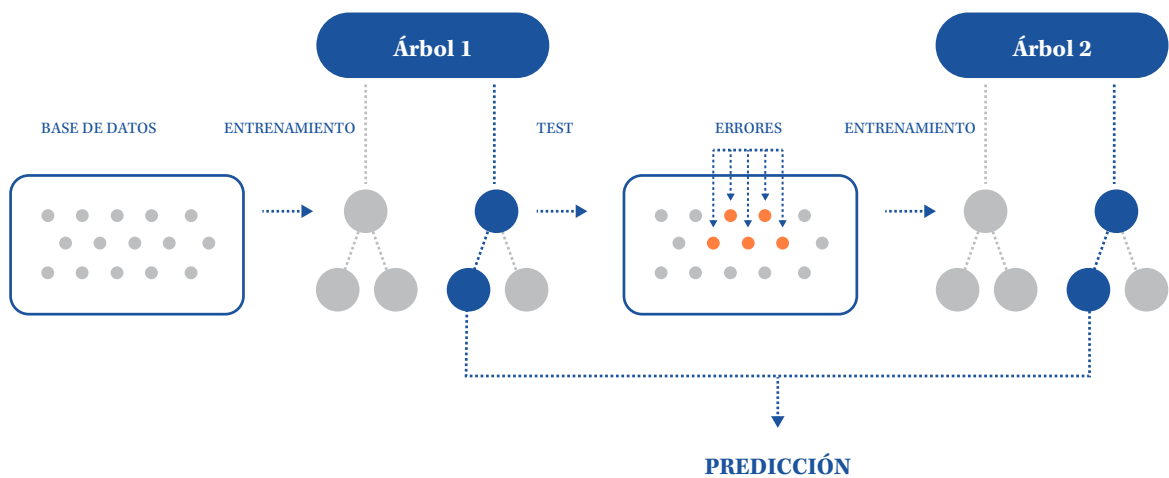
¹² En Gradient Boosting Machine, las “deficiencias” se identifican con un gradiente y es este gradiente el que nos dice cómo mejorar el modelo (Sick, 2018).

En la expresión anterior, $F(x)$ es un árbol de regresión que se actualiza sucesivamente agregando modelos de predicción débil. Luego nos gustaría minimizar la siguiente expresión ajustando $F(x)_i$ con nuevos árboles de regresión:

$$L = \sum_z L(y_z, F_z(x)) \tag{3}$$

Con la adición de estos árboles de regresión débiles, podemos llegar a un modelo poderoso que puede producir con precisión un pronóstico del PIB trimestral. La Figura 2 proporciona una representación simplificada del mecanismo detrás de Gradient Boosting Machines.

FIGURA 2. REPRESENTACIÓN SIMPLIFICADA DEL GRADIENT BOOSTING MACHINE



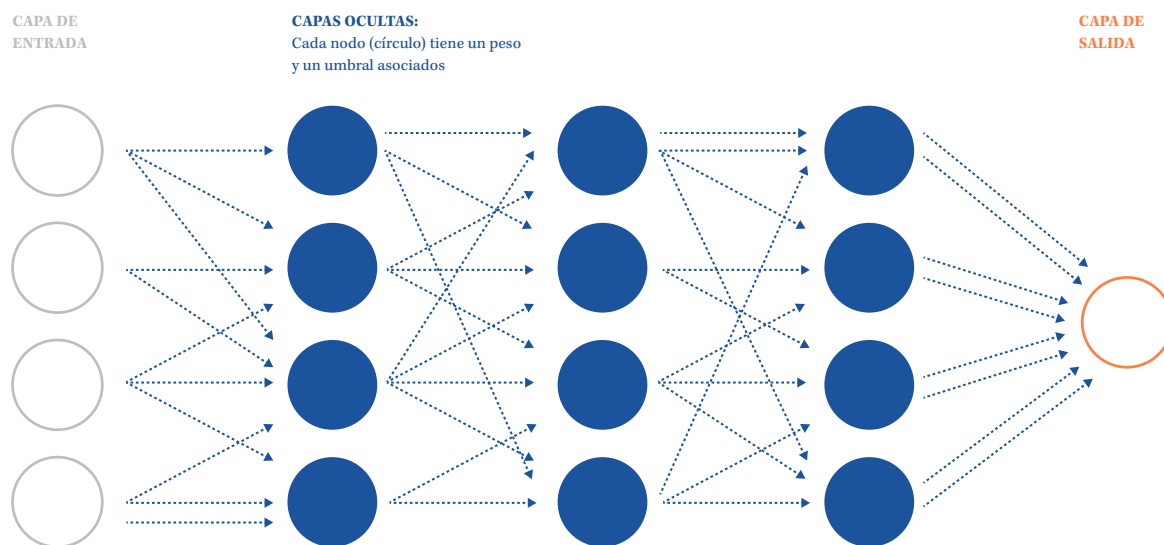
Fuente: Adaptación de Boehmke y Greenwell (2020).

Redes neuronales

Las redes neuronales se componen de un grupo de nodos (que pueden pensarse como regresiones lineales) que están conectados entre sí en diferentes capas (Mitchell, 2010). En términos simples, a cada entrada se le asigna un peso para medir la importancia de cada variable, las entradas luego se multiplican por el peso correspondiente para producir un resultado. El resultado, a su vez, se pasa a una función de activación que determina si la salida ha

superado el umbral correspondiente para activar los datos y pasar a la siguiente capa / nodo. Este proceso se repite en cada capa contenida en la red neuronal, lo que significa que la información contenida en los nodos anteriores sirve para alimentar las siguientes capas / nodos (ver Figura 3).

FIGURA 3. REPRESENTACIÓN SIMPLIFICADA DE REDES NEURONALES ARTIFICIALES



Fuente: Adaptación de IBM Cloud Education (2020).

El entrenamiento de redes neuronales implica el uso de una función de pérdida a minimizar. Para llevar a cabo esta minimización, se puede utilizar el algoritmo de descenso del gradiente estocástico, que es el procedimiento estándar. Este algoritmo ayuda a encontrar las derivadas parciales necesarias con respecto a los pesos y sesgos mediante una función de actualización. Es posible actualizar los pesos y sesgos hasta minimizar la función de pérdida y produzcamos una predicción precisa de la variable de resultado. La Figura 3 presenta una descripción de diagrama simplificado del mecanismo detrás de este algoritmo.

$$y = F\left(\sum_{i=1}^m w_i x_i + \text{sesgo}\right) \quad (4)$$

Regresión Ridge

Las regresiones Ridge son parte de los algoritmos supervisados de *machine learning* que se ajustan a través de regresiones lineales penalizadas. La idea de este método es reducir la complejidad de una regresión con una cantidad considerable de variables explicativas. Así, este método implica realizar un

trade-off entre el sesgo de los coeficientes y la varianza (Boehmke and Greenwell, 2020). Este proceso de *trade-off* entre sesgo y varianza se representa en la figura 4. Mientras que los Mínimos Cuadrados Ordinarios (MCO) buscan reducir el sesgo al máximo, las regresiones penalizadas aceptan incrementar el sesgo en orden de reducir la varianza de los coeficientes y de esta forma encontrar un óptimo en la complejidad del modelo. Básicamente, las regresiones Ridge penalizan los predictores según su tamaño encogiéndolos a valores que tienden a cero, el tamaño final de cada coeficiente dependerá de su importancia para explicar la variable objetivo. La regresión Ridge busca minimizar una *función de pérdida* (similar a la que se minimiza en MCO, pero adicionando el término que contiene el coeficiente de regularización (λ)) como la expresión 5, mientras que la expresión 6 muestra la obtención de los coeficientes según este método.


$$L(\hat{\beta}) = \sum_{i=1}^n (y_i - x_i' \hat{\beta})^2 + \lambda \sum_{j=1}^m \hat{\beta}_j^2 \quad (5)$$

$$\hat{\beta}_{\text{ridge}} = (X'X + \lambda I)^{-1} (X'Y) \quad (6)$$

En la expresión 5 y 6, λ se define como el coeficiente de regularización (o penalización). Cuando el parámetro λ toma el valor de cero, los coeficientes estimados provienen de MCO. Es también importante notar que cuando el coeficiente de regularización incrementa, la varianza tiende a reducirse, sin embargo, al costo de incrementar el sesgo. En este sentido, la

selección del parámetro de regularización no es trivial. Para ello, se pueden utilizar un IC (*information criterion*) o se puede realizar una cross-validation y seleccionar el valor del parámetro que minimice una métrica como el *Mean Square Error* (MSE) o el *Root Mean Square Error* (RMSE). Este último proceder es el que se aplica en este documento.

FIGURA 4. ILUSTRACIÓN DEL TRADE-OFF ENTRE VARIANZA Y SESGO MCO VS RIDGE



Fuente: Elaboración propia.

Regresión Lasso

Las regresiones Lasso (*Least Absolute Shrinkage and Selection Operator*, por sus siglas en inglés) comparten el mismo principio que las regresiones Ridge y forman parte de las regresiones regularizadas. Sin embargo, la diferencia entre ambas es el coeficiente de penalización para los coeficientes de las variables predictivas. Precisamente, la penalización en las regresiones Lasso viene dada por el segundo término de la expresión 7 (*loss function*):

$$L(\hat{\beta}) = \sum_{i=1}^n (y_i - x_i' \hat{\beta})^2 + \lambda \sum_{j=1}^m |\hat{\beta}_j| \quad (7)$$

De la misma forma que en la regresión Ridge, el valor óptimo de λ puede ser obtenido a partir de la aplicación de un IC o de un cross-validation seleccionado el λ que produzca el menor MSE o el RMSE. Una de las principales diferencias entre las regresiones Lasso y Ridge es que la regresión Lasso, por el tipo de penalización que aplica, permite realizar una selección de variables (para las variables con menos aporte explicativo el coeficiente es cero), lo que no sucede con la penalización de la regresión Ridge. En este sentido, la regresión Lasso permite realizar un *feature selection* el cual permite tener conocimiento de aquellas variables que, de acuerdo a la regresión, tienen una relación estadísticamente significativa con el PIB trimestral.¹³


¹³ Como se verá más adelante, en el caso de Belice, se utilizó una pre-selección de variables con base en la regresión Lasso para incrementar la capacidad predictiva de los modelos en un contexto de importantes retos de disponibilidad estadística.

Regresión Elastic Net

Como se puede intuir, unas de las principales limitaciones de la regresión Lasso es que la selección de variables que tienen mayor poder de predicción de la variable objetivo depende de forma importante de la dimensionalidad de las variables contenidas en la base de datos de interés, así como de la disponibilidad de información. Por ello, una selección eficiente de variables está condicionada por la dimensionalidad y disponibilidad de información. En el caso de las regresiones Ridge, una de las principales limitaciones es que las mismas dependen en gran medida de que las variables incluidas tengan una relación significativa con la variable objetivo, de lo contrario se corre el riesgo de afectar la eficiencia de la predicción. Una de las soluciones a estas limitaciones es la combinación de los métodos descritos anteriormente (Boehmke y Greenwell, 2020); es decir, la penalización de los coeficientes viene dada por la combinación de las penalizaciones en las regresiones Lasso y Ridge. Así, se tiene la expresión 8. En la regresión Elastic Net además de buscar un valor óptimo para el parámetro λ también se debe encontrar un valor para α . Este último parámetro es un peso con rango entre 0 (regresión Ridge) y 1 (regresión Lasso).

$$L(\hat{\beta}) = \frac{\sum_{i=1}^n (y_i - x_i' \hat{\beta})^2}{2n} + \lambda \left(\frac{1-\alpha}{2} \sum_{j=1}^m \hat{\beta}_j^2 + \alpha \sum_{j=1}^m |\hat{\beta}_j| \right) \quad (8)$$



The background image shows a hand touching a screen that displays a complex network of white lines and nodes. A bright light source creates a lens flare effect across the center. On the left, a robotic arm is partially visible. The overall theme is technology and data.

Las técnicas de *nowcasting* se presentan como una herramienta efectiva para llenar el vacío en el rezago de la publicación de indicadores macroeconómicos



*Belize y
El Salvador*



Datos

El proceso de recolección de datos para llevar a cabo un ejercicio de *nowcasting* presenta retos importantes que se encuentran directamente vinculados con la capacidad y disponibilidad estadística de los países. En general, estos ejercicios requieren un amplio abanico de variables que estén asociadas en cierto grado con la evolución del PIB trimestral. Asimismo, un aspecto importante es que el ejercicio mejora a medida que se completan las series de tiempo de las variables predictoras, por lo que se debe hacer un balance entre oportunidad y eficiencia de los modelos de predicción. Esto cobra sentido cuando se tiene en cuenta que las variables predictoras utilizadas tienen diferentes períodos de publicación, entre los que se encuentran mensuales, bimensuales y trimestrales. A continuación, se describen los datos utilizados en ambos países.

Belice

El objetivo del ejercicio para el caso de Belice es producir un ejercicio de *nowcasting* del PIB trimestral desestacionalizado (precios constantes de 2000 - millones de dólares de Belice). Para este ejercicio, se recopiló información sobre más de 108 variables.¹⁴ La base de datos fue construida recolectando información de varias fuentes, entre ellas: Banco Central de Belice (CBB), Instituto de Estadística de Belice (SIB), la Junta de Turismo de Belice (BTB) y

Federal Reserve Economic Data de los Estados Unidos de América (FED-FRED). Las variables se agrupan en variables del sector real, variables fiscales, variables del sector externo, variables monetarias y variables de otros países que guardan relación con la evolución del producto trimestral de Belice.¹⁵ ¹⁶ Las variables tienen frecuencia mixta, mientras que la frecuencia del PIB es trimestral, la mayoría de las variables se tienen de forma mensual. La base de datos construida cubre el periodo de 1994 a 2021. Una parte de estas variables mensuales se encuentran disponibles al final del trimestre correspondiente, lo que permite realizar un pronóstico preliminar aproximadamente 12 semanas antes de la publicación del dato oficial del PIB trimestral por parte de la SIB y un pronóstico final 4 semanas antes de su publicación.

Todas las variables monetarias expresadas en dólares se deflactaron con el IPC general. Todas las variables se estandarizaron a valores trimestrales. Para implementar esto, las variables con frecuencia mensual se dividieron entre variables de flujo, variables índices / tasa y variables de stock. Para las variables de flujo se toma la suma de los meses que componen cada trimestre (por ejemplo, este es el caso de exportaciones e importaciones).¹⁷ Para el segundo y tercer grupo de variables se tomó el valor promedio de los meses correspondientes a cada trimestre.¹⁸ En el Anexo 1 se presenta

¹⁴ La selección de las variables tuvo como base el documento de Aasaavari et al. (2018) y discusiones entre el consultor y el equipo supervisor del BID. Sin embargo, después de aplicar la regresión Lasso y el feature selection el número de variables se redujo a 24.

¹⁵ Para el caso específico, se ha recolectado información mensual sobre indicadores del sector real del Reino Unido y Estados Unidos, dos de los principales socios comerciales de Belice.

¹⁶ Como se ha mencionado anteriormente, algunas variables que previsiblemente guardan una fuerte relación con la evolución del PIB trimestral no fue posible conseguir las o su periodicidad de publicación no facilita su inclusión en ejercicios de *nowcasting*. En casos como la producción sectorial o estadísticas fiscales (por ejemplo, ingresos tributarios) la información mensual se publica con intervalos que limitan seriamente la disposición de esta información para realizar ejercicios de *nowcasting*. En la misma vía, no hay acceso público a datos mensuales del número de ocupados en el sector formal de la economía, así como información mensual sobre producción y consumo de energía, las cuales son variables que en ejercicios de *nowcasting* generalmente muestran una fuerte asociación con el PIB trimestral.

¹⁷ En los casos en que únicamente se dispone información de un mes en el trimestre, se asume que la variable presentará el mismo valor en los dos meses restantes que componen el trimestre. En los casos en que dos meses estén disponibles, se asume que el valor de la variable en el tercer mes será igual al del segundo. Se considera que este es un procedimiento sencillo que no agrega más ruido estadístico a la información y que no presenta un riesgo importante en la capacidad estadística de los modelos calibrados. Sin embargo, es posible utilizar modelos autoregresivos o de otra índole para complementar la información de cada trimestre.

¹⁸ En los casos en que únicamente se dispone información de un mes en el trimestre se toma ese valor como el promedio del trimestre. En los casos en que haya información de dos meses se toma como el promedio del trimestre el número que se obtiene como promedio de los dos meses.

el listado de las variables incluidas en este ejercicio y su correspondiente clasificación. Para alimentar los modelos, utilizamos la tasa de crecimiento trimestral interanual de las variables para hacer frente a la no estacionariedad que normalmente afecta a las series de tiempo macroeconómicas y porque el interés del BID se centra en medir la evolución de la tasa de crecimiento del PIB trimestral.¹⁹

El Salvador

El objetivo del ejercicio para el caso de El Salvador es producir un ejercicio de *nowcasting* del índice de volumen encadenado (referencia 2014) del PIB trimestral para la serie desestacionalizada publicada por el Banco Central de Reserva (BCR). Para este ejercicio se construyó una base de datos primaria con 98 variables macroeconómicas, las cuales se recopilaban de forma mensual o trimestral desde enero del 2005 hasta, dependiendo de la variable, marzo de 2021.²⁰ En su mayoría, estas variables fueron obtenidas del BCR, aunque también se ha recurrido al Instituto Salvadoreño del Seguro Social (ISSS), Federal Reserve Economic Data de los Estados Unidos de América (FED-FRED) y a datos sobre volumen de

ventas y de inversiones recolectados por la Fundación Salvadoreña para el Desarrollo Económico y Social (FUSADES).

Las variables expresadas en dólares nominales fueron deflactadas con el IPC o el Índice de Precios al Por Mayor (IPM)/Índice de Precios al Productor (IPP) para las variables relacionadas al comercio exterior. Las variables tienen frecuencia mixta, mientras que el índice de volumen encadenado del PIB es trimestral, la mayoría de las variables se tienen de forma mensual. Por ello, se procedió a estandarizar todas las variables a variables trimestrales. Las variables con frecuencia mensual se dividieron entre variables de flujos, variables índices/tasas y variables de stock. Para las primeras se toma la suma de los meses que componen cada trimestre. Para las segundas y las terceras se toma el valor promedio de los meses correspondientes a cada trimestre (véase anexo 2).²¹ Finalmente, los modelos fueron alimentados con la tasa de crecimiento trimestral interanual de las variables contenidas en la base de datos, ya que permite lidiar con el problema de no estacionariedad, al tiempo que el crecimiento del PIB es la variable de interés.²²

¹⁹ Como parte del ejercicio, los modelos también fueron alimentados con las variables en nivel, resultando en pronósticos y eficiencia aceptables. Esto pone en perspectiva el hecho de que las herramientas de *machine learning* proveen un marco más flexible en relación al uso de modelos estándares de series de tiempo.

²⁰ La selección de las variables tuvo como base el documento de Aasaavari et al. (2018) y discusiones entre el consultor y el equipo supervisor del BID.

²¹ Esta es una diferencia en comparación a Aasaavari et al. (2018) en donde las variables stock son representadas por el valor del último mes del trimestre. En este documento se considera que tomar el promedio de las variables stock puede representar de mejor forma el comportamiento de las variables de stock en el trimestre.

²² Como parte del ejercicio, también se corrieron los modelos con las variables en nivel, produciendo un ajuste adentro y fuera de la muestra muy similar al obtenido con las tasas de crecimiento inter-trimestrales.





*Belice y
El Salvador*



Resultados

Esta sección presenta los resultados obtenidos al calibrar los seis métodos de aprendizaje automático y sus correspondientes *ensembles* para pronosticar el PIB trimestral de Belice y El Salvador.²³ Los resultados se presentan para regresiones penalizadas y luego para el resto de los modelos.²⁴

En el caso de Belice, los resultados muestran que las regresiones penalizadas son los modelos que producen un mejor ajuste en comparación con los otros métodos, esto medido por el RMSE. Específicamente, un *ensemble* de estas regresiones produce un pronóstico muy cercano al resultado observado entre el segundo y cuarto trimestre de 2020. El modelo predijo una caída del PIB de 22.9% en el segundo trimestre (la cifra real fue del 23.9%), una caída del 15.0% en el tercer trimestre (la cifra real fue del 12.8%), para el cuarto trimestre, este modelo predijo una caída del PIB del 14.2% (la cifra real fue del 13.1%), y para el primer trimestre del 2021 el modelo pronostica una caída del PIB del 6.8%, mientras que la caída real fue de 8.4%.

Para el caso de El Salvador, el modelo que tiene una mayor eficiencia predictiva es el *ensemble* de las regresiones penalizadas. Por ejemplo, para el segundo trimestre de 2020 el modelo pronostica una caída de 17.8% (la cifra real fue de -19.4%), para el tercer trimestre la contracción predicha por el modelo fue 8.0%, siendo la cifra publicada por el BCR de -9.9%. Para el cuarto trimestre el modelo predice una caída de -2.3%, mientras que la cifra observada fue de -2.3%. Finalmente, para el primer trimestre del 2021 se pronostica un crecimiento de 1.2% en relación con el primer trimestre de 2020 (la cifra real se ubicó en 3.0%). Como se ha mencionado, El Salvador posee una capacidad estadís-

tica mayor a la de Belice, lo cual se refleja en el ajuste de los modelos, pues en general los RMSE obtenidos para El Salvador son menores que los obtenidos para Belice. Las siguientes subsecciones presentan los resultados y selección del mejor modelo para Belice y El Salvador.

Regresiones Penalizadas

La Tabla 1 y la Figura 5 presentan los resultados de los siguientes métodos: regresión Lasso, regresión Ridge y regresión Elastic-Net. Las regresiones se han obtenido para las variables en tasas de crecimiento. Como se observa, en la Figura 5 el pronóstico realizado por las regresiones penalizadas es bastante bueno en relación con la evolución del PIB trimestral en ambos países. En general, el ajuste tanto dentro como fuera de la muestra es mejor para El Salvador en relación con Belice. Como se ha mencionado, esto se debe que en el caso de Belice no se pudo acceder a variables con una probable alta correlación con la evolución del PIB trimestral, como la producción y el consumo de energía eléctrica o series mensuales de empleo (las cuales sí están disponibles en El Salvador). Un aspecto importante de estos modelos es que son capaces de capturar la gran reducción en la producción en el segundo trimestre de 2020, el tercer trimestre de 2020 y el cuarto trimestre de 2020 en ambos países. Esto enfatiza la capacidad de modelos de *machine learning* a la hora de identificar cambios importantes en las series de tiempo, así como su capacidad de lidiar con no-linealidades existentes en la información recolectada.²⁵ Una de las ventajas de las técnicas de *machine learning* es que enfatizan el desempeño fuera de la muestra a la hora de definir la

²³ El software R fue utilizado para obtener estos resultados.

²⁴ Como se ha mencionado, los modelos de Belice han sido calibrados a partir de una pre-selección de variables utilizando la regresión Lasso. Así, en el caso de este país, los modelos han sido alimentados con 24 variables seleccionadas por esta regresión penalizada. Este proceder ha incrementado el ajuste dentro y fuera de la muestra. La lista de variables seleccionadas por la regresión Lasso para Belice se muestra en el anexo 3. En el caso de El Salvador no fue necesario realizar esta pre-selección de variables para calibrar los modelos. Sin embargo, la lista de variables seleccionadas por la regresión Lasso para este país se muestran en el anexo 4.


²⁵ Este ejercicio también incluyó la estimación de un modelo de factores dinámicos para El Salvador y se verificó que el modelo registró mayores dificultades para predecir las caídas de la producción en el segundo, tercer y cuarto trimestre. Asimismo, los modelos de *machine learning* ajustados producían un menor error de predicción.

precisión de los mismos. En nuestro caso particular los modelos fueron entrenados dividiendo la data en un 70-80% como parte del entrenamiento y haciendo uso del proceso de *cross-validation*. El entrenamiento de los modelos incluyó el periodo 2006-Q1 a 2020-Q2. Los pronósticos de estas calibraciones se comparan con el set de datos de prueba y se estima el RMSE. Los resultados de los MSE y RMSE para las regresiones penalizadas se muestran en la tabla 1. El RMSE se mide en las unidades de medida de la variable de resultado (crecimiento del PIB trimestral en ambos países). Los tres modelos producen un RMSE similar en el caso de ambos países; sin embargo, la regresión Lasso (para el caso de El Salvador) y la regresión Ridge (en el caso de Belice) son los modelos que reducen el RMSE al mínimo, indicando el mejor ajuste fuera de la muestra. Asimismo,


en términos comparativos, los datos de la tabla 1 muestran que los modelos predicen un mejor ajuste en el caso de El Salvador, ya que el RMSE es menor en todos los casos, confirmando lo mencionado anteriormente en cuanto a la disponibilidad de información. Los modelos para ambos países fueron entrenados usando información para el periodo Q1-2006/ Q2 2020, por ello, los pronósticos producidos después del Q2-2020 (a la derecha de la línea vertical de color azul) actúan como una prueba true-out-of-sample para medir la capacidad predictiva de los modelos. Como se observa de la figura, en todos los casos los modelos producen resultados muy cercanos a las tasas de crecimiento del tercer y cuarto trimestre del 2020 y primer trimestre de 2021, confirmando así la capacidad predictiva de los modelos.


FIGURA 5. RESULTADOS DE LAS REGRESIONES PENALIZADAS PARA EL SALVADOR Y BELICE

(A) EL SALVADOR: REGRESIÓN LASSO




(B) BELICE: REGRESIÓN LASSO






(C) EL SALVADOR: REGRESIÓN RIDGE

• Crecimiento PIB-Observado
— Crecimiento PIB-Pronóstico




(D) BELICE: REGRESIÓN RIDGE

• Crecimiento PIB-Observado
— Crecimiento PIB-Pronóstico



(E) EL SALVADOR: REGRESIÓN ELASTIC NET

• Crecimiento PIB-Observado
— Crecimiento PIB-Pronóstico



Fuente: Estimación propia con base en BCR, ISSS, FUSADES, FED-FRED, CBB, SIB, BTB.

TABLA 1. REGRESIONES PENALIZADAS MSE Y RMSE

Modelo	El Salvador		Belice	
	MSE	RMSE	MSE	RMSE
Lasso regression	0.60	0.77	4.89	2.21
Ridge regression	0.66	0.81	3.16	1.78
Enet regression	0.60	0.78	3.75	1.94

Fuente: Estimación propia con base en BCR, ISSS, FUSADES, FED-FRED, CBB, SIB, BTB.


Random Forest, Gradient Boosting Machine y Neural Network

Además de las regresiones penalizadas presentadas en el apartado anterior, también se estimaron los siguientes modelos: Random Forest, Gradient Boosting Machine y Neural Networks (Ver Tabla 2 y Figura 6). Los modelos se han calibrado para las variables en tasas de crecimiento. Al igual que las regresiones penalizadas, estos modelos son capaces de capturar la fuerte caída del PIB en los tres últimos trimestres de 2020. La Figura 6 muestra que el ajuste de los modelos dentro de la muestra es preciso. Se observa también que nuevamente el ajuste de los datos para El Salvador es relativamente mejor que para el caso de Belice. En especial, se tiene que los modelos de random forest y GBM poseen un buen ajuste dentro de la muestra y también fuera de la misma, lo cual se representa

por los puntos a la derecha de la línea azul (*true-out-of-sample*). En general, los modelos predicen bien las caídas del PIB en los últimos tres trimestres del 2020 y primer trimestre de 2021, a excepción de GBM que en ambos países no logra capturar la abrupta caída de la producción en el segundo trimestre de dicho año. Como se ha dicho, las técnicas de *machine learning* enfatizan el desempeño fuera de la muestra y para ello los modelos se han entrenado con información que cubre Q1 2006 a Q2 2020. Con esta información se obtienen las predicciones y se comparan con los datos de prueba (excluidos del entrenamiento) para luego obtener el RMSE de cada uno de los modelos, estos resultados se muestran en la Tabla 2. De los modelos calibrados para El Salvador el que produce el RMSE más bajo es el GBM, seguido por la red neuronal y random forest. Para Belice los modelos que producen el RMSE más bajo son GBM y Random Forest.


FIGURA 6. RESULTADOS DE GBM, RANDOM FOREST Y NEURAL NETWORK PARA EL SALVADOR Y BELICE






(D) BELICE: RANDOM FOREST

• Crecimiento PIB-Observado
— Crecimiento PIB-Pronóstico



(E) EL SALVADOR: NEURAL NETWORK

• Crecimiento PIB-Observado
— Crecimiento PIB-Pronóstico



(F) BELICE: NEURAL NETWORK

• Crecimiento PIB-Observado
— Crecimiento PIB-Pronóstico

Fuente: Estimación propia con base en BCR, ISSS, FUSADES, FED- FRED, CBB, SIB, BTB.

TABLA 2. GBM, NNET Y RANDOM FOREST MSE Y RMSE

Modelo	El Salvador		Belice	
	MSE	RMSE	MSE	RMSE
Gradient Boosting Machine	0.67	0.82	3.33	1.83
Neural Network	0.95	0.98	3.56	1.89
Random Forest	1.00	1.00	3.35	1.83


Fuente: Estimación propia con base en BCR, ISSS, FUSADES, FED-FRED, CBB, SIB, BTB.


Combinación de todos los modelos (*ensemble approach*)

Una de las ventajas ofrecida por los ejercicios de *nowcasting* es que se pueden combinar los pronósticos de diferentes modelos con el objetivo de sacar ventaja de las particularidades de cada uno de ellos. Esto es lo que se conoce como *ensemble approach*. Precisamente, en esta subsección se presentan los resultados de este ejercicio con los seis modelos calibrados para ambos países. Existen diferentes métodos para realizar esta combinación, en este documento se utilizan dos de ellos: promedio simple (pesos equivalentes) y pesos construidos con el inverso del RMSE. En el primer método se utilizan todos los pronósticos producidos por todos los modelos y se obtiene un promedio de todos los pronósticos. En el segundo método se construye un peso a

partir del inverso del RMSE producido por cada uno de los modelos. Los resultados de este ejercicio para los dos países se muestran en la Figura 7. Para verificar el impacto en la reducción del error de predicción, la tabla 3 presenta la estimación del RMSE para ambos *ensembles*. La tabla 3 muestra claramente que el error de predicción se ha reducido de forma importante para ambos países, lo que indicaría que la combinación de los pronósticos de los modelos de *machine learning* utilizados en este documento permite incrementar la eficiencia predictiva en relación a los modelos tomados de forma individual, según lo demuestra la métrica del RMSE.

FIGURA 7. ENSEMBLE APPROACH PARA EL SALVADOR Y BELICE





Fuente: Estimación propia con base en BCR, ISSS, FUSADES, FED-FRED, CBB, SIB, BTB.

TABLA 3. RMSE Y MSE DE ENSEMBLES PARA EL SALVADOR Y BELICE

Modelo	El Salvador		Belice	
	MSE	RMSE	MSE	RMSE
Ensemble-pesos iguales	0.29	0.54	1.45	1.21
Ensemble- pesos - RMSE inverso	0.29	0.54	1.44	1.20

Fuente: Estimación propia con base en BCR, ISSS, FUSADES, FED-FRED, CBB, SIB, BTB.

Seleccionando el mejor modelo

En esta sección se combinan los resultados obtenidos en las secciones previas con el objetivo de comparar los modelos y escoger los que minimizan el RMSE y producen el mejor ajuste *true-out-of-sample*. La comparación de las métricas de los 6 modelos y sus correspondientes *ensembles* para ambos países se muestra en la tabla 4. En términos individuales, los resultados muestran que las regresiones penalizadas son los modelos que producen un mejor ajuste en comparación con los otros métodos, ya que producen RMSE comparativamente más bajos y tienen la capacidad de predecir la caída del

PIB en el segundo trimestre con mayor precisión. Estos resultados están en línea con los hallazgos anteriores de Tiffin (2016), quien calibró diferentes métodos de aprendizaje automático para predecir el PIB trimestral del Líbano. El autor encuentra que la regresión penalizada Elastic-Net produjo el RMSE más bajo y un mejor ajuste. Así, para El Salvador el modelo que produce el RMSE más bajo es la regresión Lasso, mientras que para Belice es la regresión Ridge. No obstante, los resultados también muestran que la eficiencia predictiva incrementa cuando se utilizan los *ensembles* de los seis modelos, ya que los mismos presentan el menor valor para la métrica del RMSE. Con el objetivo de comprobar el

poder de predicción de estos modelos, se procedió a entrenar los modelos con información hasta el último trimestre de 2019 para que los pronósticos de todos los trimestres de 2020 y el primer trimestre de 2021 sean *true-out-of-sample*. Los resultados

de estos modelos se presentan en las figuras 8 y 9²⁶ y en la tabla 5 (se presenta una menor cantidad de años para observar más claramente el ajuste de los modelos).

TABLA 4. REGRESIONES PENALIZADAS, GBM, NNET, RANDOM FOREST Y ENSEMBLES MSE Y RMSE

Modelo	El Salvador		Belice	
	MSE	RMSE	MSE	RMSE
Lasso regression	0.60	0.77	4.89	2.21
Ridge regression	0.66	0.81	3.16	1.78
Enet regression	0.60	0.78	3.75	1.94
Gradient Boosting Machine	0.67	0.82	3.33	1.83
Neural Network	0.95	0.98	3.56	1.89
Random Forest	1.00	1.00	3.35	1.83
Ensemble-pesos iguales	0.29	0.54	1.45	1.21
Ensemble- pesos - RMSE inverso	0.29	0.54	1.44	1.20

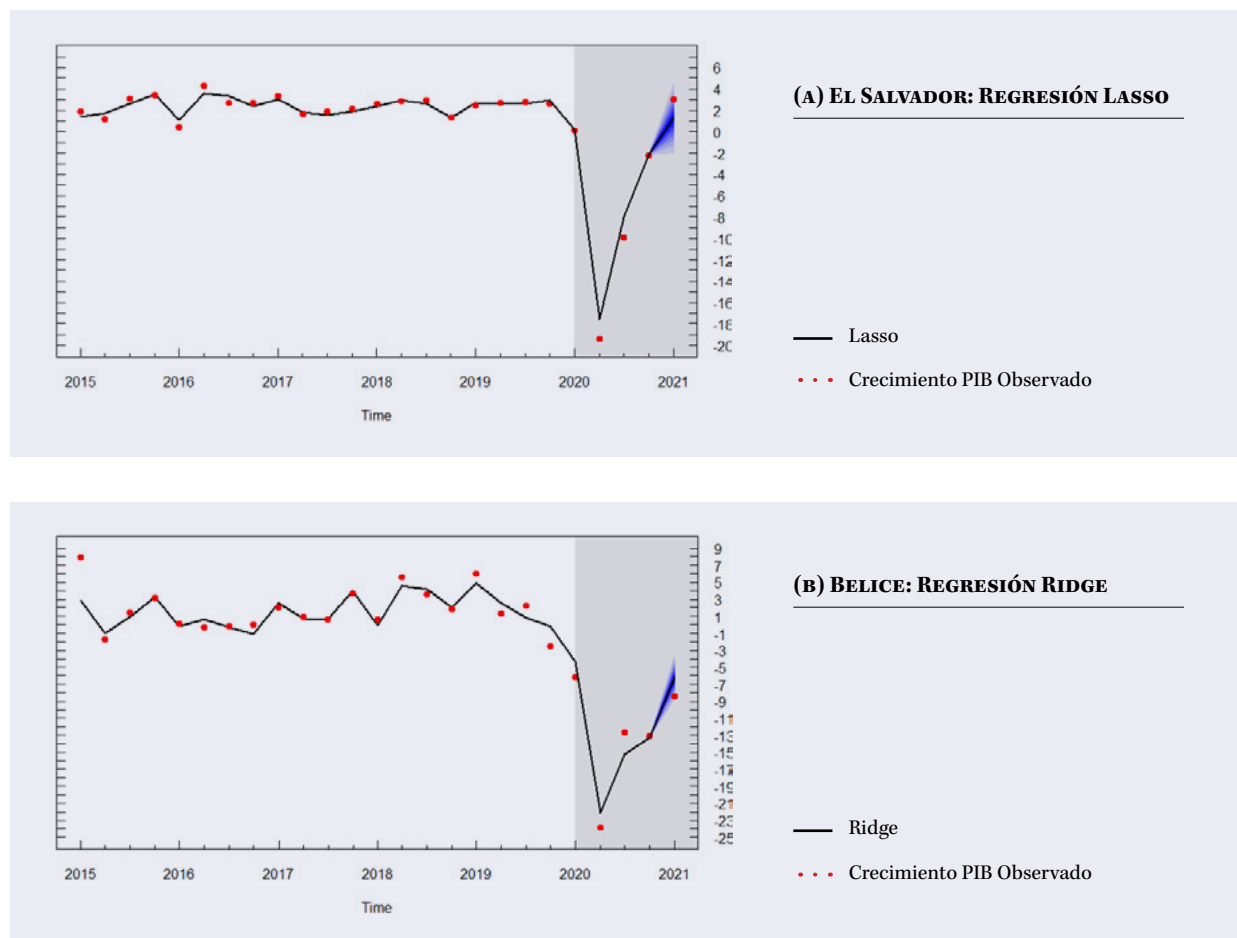
Fuente: Estimación propia con base en BCR, ISSS, FUSADES, FED-FRED, CBB, SIB, BTB.

En primera instancia, las figuras 8 y 9 revelan que los modelos producen un buen ajuste dentro de la muestra, pero también fuera de la muestra. Precisamente, los pronósticos ubicados en el área gris muestran un alto nivel de precisión en todos los trimestres del 2020 en el caso de El Salvador. En lo que respecta a Belice, se tiene que el modelo presentó dificultades para predecir la caída de experimentada en el segundo trimestre del 2020. En esencia, esto es reflejo de algo que se ha señalado a lo largo del documento: la capacidad estadística del país es de vital importancia para asegurar ejercicios de *nowcasting* precisos. A pesar de los retos que la capacidad estadística de Belice presenta, los modelos realizan un buen trabajo en aproximar con precisión las caídas de la producción en el resto de los trimestres. Esta es otra ventaja de los modelos de

machine learning, en la medida que el proceso de *cross-validation* asegura el mejor ajuste incluso en ejercicios con retos importantes en términos de capacidad estadística. Por su parte, la tabla 5 muestra los pronósticos *true-out-of-sample* producidos por las regresiones penalizadas y sus correspondientes *ensembles* (que para ambos países producen los menores RMSE). Los modelos para ambos países producen estimaciones bastante certeras del PIB trimestral. Los modelos muestran que son capaces de reconocer caídas de la producción sin precedentes de forma relativamente certera, lo que nuevamente muestra la capacidad de los modelos de *machine learning* para producir *nowcasting* precisos de la producción en un contexto de alta incertidumbre.

²⁶ Los *ensembles* presentados en la figura 9 y en la tabla 5 se han obtenido únicamente con las regresiones penalizadas, ya que son estas las que producen los menores RMSE.


FIGURA 8. REGRESIONES PENALIZADAS CON MEJOR AJUSTE PARA EL SALVADOR Y BELICE




Nota: Área azul en pronóstico del Q1 2021 fue construida a través de una adaptación de la metodología de *fancharts* desarrollada e implementada por el Banco de Inglaterra.

Fuente: Estimación propia con base en BCR, ISSS, FUSADES, FED-FRED, CBB, SIB, BTB.

FIGURA 9. ENSEMBLES CON MEJOR AJUSTE PARA EL SALVADOR Y BELICE





Nota: Área azul en pronóstico del Q1 2021 fue construida a través de una adaptación de la metodología de fancharts desarrollada e implementada por el Banco de Inglaterra. Fuente: Estimación propia con base en BCR, ISSS, FUSADES, FED-FRED, CBB, SIB, BTB.

TABLA 5. PRONÓSTICOS TRUE-OUT-OF-SAMPLE

Período	El Salvador (%)					Belice (%)				
	Observado	1. Elastic Net	2. Lasso	3. Ridge	4. Ensemble- pesos - RMSE inverso	Observado	1. Ridge	2. Elastic Net	3. Lasso	4. Ensemble- pesos - RMSE inverso
2020 Q1	0.1	0.5	0.2	1.7	0.8	-6.2	-4.3	-5.8	-5.7	-5.2
2020 Q2	-19.4	-18.1	-17.5	-17.9	-17.8	-23.9	-22.1	-23.5	-23.2	-22.9
2020 Q3	-9.9	-8.3	-8.0	-7.6	-8.0	-12.7	-15.3	-15.0	-14.7	-15.0
2020 Q4	-2.3	-2.6	-2.2	-2.0	-2.3	-13.1	-13.3	-15.0	-14.6	-14.2
2021 Q1	3.0	1.0	1.3	1.2	1.2	-8.4	-6.1	-7.3	-7.0	-6.8

Fuente: Estimación propia con base en BCR, ISSS, FUSADES, FED-FRED, CBB, SIB, BTB.



*Belice y
El Salvador*



Acompañamiento Institucional

El ejercicio de *nowcasting* en Belice fue, en buena medida, realizado gracias al apoyo del Banco Central de Belice (CBB), el cual proporcionó acceso a estadísticas de producción sectoriales que mejoraron la capacidad predictiva de los modelos. Al mismo tiempo, el BID se ha beneficiado de la retroalimentación recibida del CBB y el SIB en presentaciones preliminares de este esfuerzo.

En el caso de Belice, uno de los aspectos fundamentales del proyecto de *nowcasting* ha sido la complementariedad del trabajo del BID con el trabajo realizado por el CBB. Debe tenerse presente que el CBB cuenta con modelos propios de *nowcasting*, véase por ejemplo Arana (2015). Se espera que los modelos *nowcasting* apoyen los esfuerzos realizados por el CBB para monitorear y predecir el desempeño de la economía. Además del continuo diálogo con CBB y SIB, el proyecto del BID brindará capacitaciones a las autoridades para mejorar la capacidad institucional para diseñar y utilizar modelos *nowcasting* y apoyar su implementación a nivel institucional por parte del CBB.

En El Salvador se han realizado esfuerzos por contar con herramientas de *nowcasting*. El BCR, con apoyo de la Comisión Económica para América Latina y el Caribe (CEPAL), desarrolló en 2009 un modelo de predicción inmediata basado en técnicas del Filtro de Kalman, el cual consideró un modelo de factores dinámicos. El modelo del BCR tomó en cuenta 17

variables con frecuencia mensual, y permitió obtener un indicador consistente con pronóstico de corto plazo para el PIB agregado, pero no para sus componentes, por lo cual la interpretación se limitaba a determinar la dirección del efecto.

Posterior a ello, el Fondo Monetario Internacional (FMI) elaboró un modelo de *nowcasting* para la economía salvadoreña con un enfoque desagregado, para complementar la utilizada por el BCR (Aasaavari, 2018) que permitiera facilitar la interpretación y dar una explicación de la dinámica económica estimada. Para la metodología se consideró un modelo puente analizado desde el lado de la producción. Así pues, la motivación principal fue la de complementar los trabajos que se venían realizando respecto a este tipo de modelos con herramientas innovadoras de *machine learning*, que servirán no solo para las instituciones de estadísticas del país sino también para el trabajo que el BID realiza de monitoreo y valoración constante de la situación macroeconómica de los países miembros.



*Belize y
El Salvador*



Reflexiones finales

Como se ha evidenciado a lo largo del documento, el desarrollo de la rama de *machine learning* se constituye como una buena alternativa para los ejercicios de *nowcasting* del PIB trimestral. Estas herramientas poseen ventajas importantes como enfatizar el desempeño fuera de la muestra, detectar no linealidades presentes en los datos y, enlazado a esto, modelar relaciones complejas entre las variables de interés y predictores.

Con el objetivo de obtener el mayor provecho de los modelos *nowcasting*, un requisito fundamental es contar con información estadística oportuna de elevada frecuencia que tenga una alta relación con la evolución del PIB trimestral. Es por ello que la calibración de los modelos en El Salvador y Belice reveló áreas de oportunidad para futuros ejercicios de pronóstico de la actividad económica. Específicamente, el ejercicio dejó ver que Belice presenta algunos retos en cuanto a la disponibilidad de información. Por ejemplo, no se tuvo acceso a información de ciertas variables claves como la producción y consumo de energía, así como información sobre el mercado laboral. En relación con la publicación oportuna de información, variables como la producción sectorial y los ingresos y gastos del sector público se publican con retrasos que pueden afectar de forma significativa este tipo de ejercicios. Asimismo, en ambos países es importante que la publicación de cifras preliminares del PIB y de otras variables sean lo más precisas posibles, pues revisiones sustanciales de las mismas pueden socavar la fiabilidad del ejercicio. Por último, vale la pena señalar la relevancia de la colaboración y retroalimentación con las autoridades estadísticas para futuros ejercicios. Precisamente, la retroalimentación recibida en presentaciones preliminares de este ejercicio al Banco Central y al Servicio Estadístico de Belice permitió fortalecer el ejercicio.

Finalmente, la calibración de modelos de *nowcasting* es un proceso dinámico que se perfec-

ciona en el tiempo. De ahí la importancia de continuar su implementación una vez que el proceso inicial se ha completado, debido a que la serie de pasos que conllevan estos ejercicios es un proceso intensivo. Como se ha mencionado anteriormente, se debe de hacer primero una selección de los modelos de *nowcasting* que mejor se ajusten a las variables que se persigue predecir, que en nuestro caso fueron seis modelos entre los cuales se seleccionaron modelos de la gama de *machine learning*. Estos modelos se alimentaron de los datos nacionales que los países generan, y datos de contexto nacional e internacional elaborados por otras instituciones como la Reserva Federal de los Estados Unidos, y tanques de pensamiento de cada país. En este paso es importante la minuciosidad con que se selecciona los datos y su manejo, así como las transformaciones que se les realiza a cada una de ellas, según se requiera. Este trabajo es el más importante y ello depende de la calidad de las estadísticas que se toman en consideración y de la astucia a la hora de seleccionar las variables que mejor expliquen el comportamiento de cada economía. Para cada economía varían tanto el modelo que mejor se ajuste como las variables que mejor explican su comportamiento económico, y es ahí donde se evidencia uno de los principales valores agregados de este ejercicio de estimación.

En suma, los beneficios de contar con este tipo de herramientas son elevados, las predicciones han sido tomadas en consideración en los análisis y evaluaciones macroeconómicas que el BID realiza para ambas economías, y en caso de Belice de rotundo beneficio para su Banco Central. Dada la naturaleza del ejercicio y los beneficios que arrojan este tipo de herramientas, es de amplia recomendación para el resto de los países de la región de los países de CID, por su capacidad de modelar el crecimiento económico para diferentes tipos de economía de manera casi inmediata y con alto grado de precisión.

Bibliografía

Aasaavari, N., Di Vittorio, F., Giri, R., Lariau, A., Lissovolik, B., Teodoru, I. (2018). El Salvador, Selected issues. IMF Country Report No. 18/152. International Monetary Fund Washington, D.C.

Arana, Rumile (2015). Evaluating Short Term Bridge Model Forecasts of Real GDP in Belize: A Quarterly Approach. Research Department, Central Bank of Belize.

Banco Central de Reserva de El Salvador (2021). Base de Datos Económica. Accesada en enero de 2021. Disponible en: <https://www.bcr.gob.sv/bcrsite/?cat=1000&lang=es>

Banco Mundial (2021). Nivel general de la capacidad estadística. Accesada en enero de 2021. Disponible en: <https://datos.bancomundial.org/indicador>

Belize Tourism Board (BTB) (2021). Belize tourism statistics. Accesada en enero de 2021. Disponible en: <https://belizetourismboard.org/belize-tourism/statistics/>

BID 2021. Desigualdad y descontento social: Cómo abordarlos desde la política pública: Informe económico sobre Centroamérica, Haití, México, Panamá y República Dominicana. Banco Interamericano de Desarrollo.

Board of Governors of the Federal Reserve System (US), 6-Month Treasury Bill: Secondary Market Rate [TB6MS], retrieved from FRED, Federal Reserve Bank of St. Louis; <https://fred.stlouisfed.org/series/TB6MS>, June 21, 2021.

Board of Governors of the Federal Reserve System (US), Effective Federal Funds Rate [FEDFUNDS], retrieved from FRED, Federal Reserve Bank of St. Louis; <https://fred.stlouisfed.org/series/FEDFUNDS>, June 21, 2021.

Board of Governors of the Federal Reserve System (US), Industrial Production: Manufacturing (NAICS) [IPMAN], retrieved from FRED, Federal Reserve Bank of St. Louis; <https://fred.stlouisfed.org/series/IPMAN>, June 21, 2021.

Board of Governors of the Federal Reserve System (US), Industrial Production: Total Index [INDPRO], retrieved from FRED, Federal Reserve Bank of St. Louis; <https://fred.stlouisfed.org/series/INDPRO>, June 21, 2021.

Boehmke, B. and Greenwell, B. (2020). Hands-On Machine Learning with R, Taylor & Francis.

Bolhuis, M. and Rayner, B. (2020a). Deus ex Machina? A Framework for Macro Forecasting with Machine Learning. IMF Working Paper.

Bolhuis, M. and Rayner, B. (2020b). The More the Merrier? A Machine Learning Algorithm for Optimal Pooling of Panel Data. IMF Working Paper.

Breiman, L. (2001). Random Forest, Machine Learning, Vol. 45, pp.5-32.

Breiman, L. y Cutler, A. (s.f.). Random Forests. Disponible en: <https://www.stat.berkeley.edu/~breiman/RandomForests/>

Brownlee, J. (2020). A Gentle Introduction to the Gradient Boosting Algorithm for Machine Learning, XGBoost. Disponible en: <https://machinelearningmastery.com/gentle-introduction-gradient-boosting-algorithm-machine-learning/>

Central Bank of Belize (CBB) (2021). Rates and statistics. Accesada en enero de 2021. Disponible en: <https://www.centralbank.org.bz/rates-statistics>

Chakure, A. (2019). Random Forest Regression Along with its implementation in Python. Disponible en: <https://medium.com/swlh/random-forest-and-its-implementation-71824ced454f>

De Valk, S., Mattos, D. y Ferreira, P. (2019). Nowcasting: An R Package for Predicting Economic Variables Using Dynamic Factor Models, The R Journal Vol. 11/01, June 2019.

DIGESTYC. (2020). Encuesta de Hogares y Propósitos Múltiples 2019.

DIGESTYC. (2021). Encuesta de Hogares y Propósitos Múltiples 2020.

FMI (2020). Perspectivas de la Economía Mundial. Enero 2020.

FUSADES (2020). Encuestas de Confianza Empresarial.

IBM Cloud Education (2020). Neural Networks. Disponible en: <https://www.ibm.com/cloud/learn/neural-networks>

Instituto Salvadoreño del Seguro Social (2021). Patronos y trabajadores reportados y cotizados al ISSS. Disponible en: <https://www.transparencia.gob.sv/institutions/iss/ documents/ estadísticas>

James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013) – An Introduction to Statistical Learning. En Springer Texts in Statistics. Springer, New York.

Jung, J., Patnam, M and Ter-Martirosyan, A. (2018). An Algorithmic Crystal Ball: Forecasts-based on Machine Learning. IMF Working Paper.

Kuzin, V., Marcellino, M. and Schumacher, C. (2012). MIDAS vs. mixed-frequency VAR: Nowcasting GDP in the euro area, International Journal of Forecasting Volume 27, Issue 2, April–June 2011, Pages 529–542.

Ministerio de Hacienda de El Salvador. (2021). Resultados Fiscales 2020 y Proyecciones de Mediano y Largo Plazo 2021-2030.

Mitchell, T. (2010). Artificial Neural Networks [PowerPoint presentation], Machine Learning 10-701, Machine Learning Department Carnegie Mellon University. Disponible en: <http://www.cs.cmu.edu/~epxing/Class/10701-10s/Lecture/lecture7.pdf>

Natekin, A. and Knoll, A. (2013). Gradient boosting machines, a tutorial, Neurorobot 7: 21. Published online 2013 Dec 4. doi: 10.3389/fnbot.2013.00021

Organization for Economic Co-operation and Development, Production of Total Industry in the United Kingdom [GBRPROINDMISMEI],

retrieved from FRED, Federal Reserve Bank of St. Louis; <https://fred.stlouisfed.org/series/GBRPROINDMISMEI>, June 20, 2021.

Schumacher, C. (2014). MIDAS and bridge equations, Bundesbank Discussion Paper No 26/2014.

Sick, B. (2018). Advanced Studies in Applied Statistics (WBL) [PowerPoint presentation], ETHZ Applied Multivariate Statistics. Disponible en: https://ethz.ch/content/dam/ethz/special-interest/math/statistics/sfs/Education/Advanced%20Studies%20in%20Applied%20Statistics/course-material-1719/Multivariate/slides12_boosting_presented.pdf

Statistical Institute of Belize (SIB) (2021). Statistics. Accesada en enero de 2021. Disponible en: <http://sib.org.bz/statistics/>

Tiffin, A. (2016). Seeing in the Dark: A Machine-Learning Approach to Nowcasting in Lebanon. IMF Working Paper.

U.S. Bureau of Labor Statistics, Unemployment Rate - Hispanic or Latino [LNS14000009], retrieved from FRED, Federal Reserve Bank of St. Louis; <https://fred.stlouisfed.org/series/LNS14000009>, June 21, 2021.

U.S. Bureau of Labor Statistics, Unemployment Rate [UNRATE], retrieved from FRED, Federal Reserve Bank of St. Louis; <https://fred.stlouisfed.org/series/UNRATE>, June 21, 2021.

UC Business Analytics (2018). Gradient Boosting Machines. Disponible en: http://uc-r.github.io/gbm_regression

Anexos

ANEXO 1. VARIABLES UTILIZADAS PARA EJERCICIO DE NOWCASTING DE BELICE

Variable	Descripción	Clasificación
GDP_TOT_A	GDP, seasonally adjusted (Constant 2000 prices – BZ\$ million)	Flujo
GDP_AG	GDP: Agriculture, hunting and forestry (Constant 2000 prices – BZ\$ million)	Flujo
GDP_FI	GDP: Fishing (Constant 2000 prices – BZ\$ million)	Flujo
GDP_MA	GDP: Manufacturing (incl. mining and quarrying) (Constant 2000 prices – BZ\$ million)	Flujo
GDP_EL	GDP: Electricity and water (Constant 2000 prices – BZ\$ million)	Flujo
GDP_CO	GDP: Construction (Constant 2000 prices – BZ\$ million)	Flujo
GDP_WH	GDP: Wholesale and retail trade; repair (Constant 2000 prices – BZ\$ million)	Flujo
GDP_HR	GDP: Hotels and restaurants (Constant 2000 prices – BZ\$ million)	Flujo
GDP_TR	GDP: Transport and communication (Constant 2000 prices – BZ\$ million)	Flujo
GDP_OT	GDP: Other private services exc. FISIM 1) (Constant 2000 prices – BZ\$ million)	Flujo
GDP_PO	GDP: Producers of government services (Constant 2000 prices – BZ\$ million)	Flujo
GDP_AL	GDP: All industries at basic prices (Constant 2000 prices – BZ\$ million)	Flujo
GDP_TA	GDP: Taxes on products (Constant 2000 prices – BZ\$ million)	Flujo
CPI_AL	CPI: All items (index)	Índice
CPI_FO	CPI: Food & non-alcoholic beverages (index)	Índice
CPI_AL	CPI: Alcoholic beverages & tobacco (index)	Índice
CPI_CL	CPI: Clothing & footwear (index)	Índice
CPI_HO	CPI: Housing, water, electricity, gas, & other fuels (index)	Índice
CPI_FU	CPI: Furnishing, household equipment & routine household maintenance (index)	Índice
CPI_HE	CPI: Health (index)	Índice
CPI_TR	CPI: Transport (index)	Índice
CPI_CO	CPI: Communication (index)	Índice
CPI_RE	CPI: Recreation & culture (index)	Índice

Variable	Descripción	Clasificación
CPI_ED	CPI: Education (index)	Índice
CPI_RE	CPI: Restaurants & hotels (index)	Índice
CPI_MI	CPI: Misc. goods & services (index)	Índice
EXP_FO	EXPORTS: Food and Live Animals (BZE \$ Million)	Flujo
EXP_BE	EXPORTS: Beverages and Tobacco (BZE \$ Million)	Flujo
EXP_CR	EXPORTS: Crude Materials (BZE \$ Million)	Flujo
EXP_MI	EXPORTS: Mineral Fuels & Lub. (BZE \$ Million)	Flujo
EXP_OI	EXPORTS: Oils and Fats (BZE \$ Million)	Flujo
EXP_CH	EXPORTS: Chemical Products (BZE \$ Million)	Flujo
EXP_MA	EXPORTS: Manufactured goods (BZE \$ Million)	Flujo
EXP_MAC	EXPORTS: Mach. & Transp. Eqt (BZE \$ Million)	Flujo
EXP_OM	EXPORTS: Oth. Manufactures (BZE \$ Million)	Flujo
EXP_CO	EXPORTS: Commodities n.e.s (BZE \$ Million)	Flujo
EXP_COM	EXPORTS: Commercial Processing Zone (BZE \$ Million)	Flujo
EXP_EP	EXPORTS: Export Processing Zone (BZE \$ Million)	Flujo
EXP_PE	EXPORTS: Personal Goods (BZE \$ Million)	Flujo
EXP_TR	EXPORTS: Transshipment (BZE \$ Million)	Flujo
IMP_FO	IMPORTS: Food and Live Animals (BZE \$ Million)	Flujo
IMP_BE	IMPORTS: Beverages and Tobacco (BZE \$ Million)	Flujo
IMP_CR	IMPORTS: Crude Materials (BZE \$ Million)	Flujo
IMP_MI	IMPORTS: Mineral Fuels & Lub. (BZE \$ Million)	Flujo
IMP_OI	IMPORTS: Oils and Fats (BZE \$ Million)	Flujo
IMP_CH	IMPORTS: Chemical Products (BZE \$ Million)	Flujo
IMP_MA	IMPORTS: Manufactured goods (BZE \$ Million)	Flujo
IMP_MAC	IMPORTS: Mach. & Transp. Eqt (BZE \$ Million)	Flujo
IMP_OM	IMPORTS: Oth. Manufactures (BZE \$ Million)	Flujo
IMP_CO	IMPORTS: Commodities n.e.s (BZE \$ Million)	Flujo
IMP_COM	IMPORTS: Commercial Processing Zone (BZE \$ Million)	Flujo
IMP_EP	IMPORTS: Export Processing Zone (BZE \$ Million)	Flujo
IMP_PE	IMPORTS: Personal Goods (BZE \$ Million)	Flujo
IMP_TR	IMPORTS: Transshipment (BZE \$ Million)	Flujo
MON_CG	Monetary: Central Government Net (\$'ooo)	stock
MON_NDC	Monetary: Net domestic credit (\$'ooo)	stock
MON_M1	Monetary: Money Supply (M1) (\$'ooo)	stock

Variable	Descripción	Clasificación
MON_QU	Monetary: Quasi-money (\$'000)	stock
MON_M2	Monetary: Money Supply (M2) (\$'000)	stock
MON_DEP_D	Monetary: Deposit Rates-Demand	tasa
MON_DEP_SC	Monetary: Deposit Rates-Savings/Chequing	tasa
MON_DEP_S	Monetary: Deposit Rates-Savings	tasa
MON_DEP_T	Monetary: Deposit Rates-time	tasa
MON_DEP_WA	Monetary: Deposit Rates-Weighted Average	tasa
MON_LEN_P	Monetary: Lending Rates-personal	tasa
MON_LEN_C	Monetary: Lending Rates-commercial	tasa
MON_LEN_RC	Monetary: Lending Rates-residential construction	tasa
MON_LEN_O	Monetary: Lending Rates-other	tasa
MON_LEN_WA	Monetary: Lending Rates-Weighted Average	tasa
G_EXP_CU	Expenditure: current (BZE \$ Million)	Flujo
G_EXP_CA	Expenditure: capital (BZE \$ Million)	Flujo
G_OVE	Balances: overall (BZE \$ Million)	Flujo
UNEM_US	Unemployment Rate US, Percent, Monthly, Seasonally Adjusted	tasa
UNEM_US_LA	Unemployment Rate - Hispanic or Latino, Percent, Monthly, Seasonally Adjusted	tasa
EFFR_US	Effective Federal Funds Rate, Percent, Monthly, Not Seasonally Adjusted	tasa
IPI_US	Industrial Production Index, Index 2012=100, Monthly, Seasonally Adjusted	Índice
IPM_US	Industrial Production: Manufacturing (NAICS), Index 2012=100, Monthly, Seasonally Adjusted	Índice
MTB_6	6-Month Treasury Bill: Secondary Market Rate, Percent, Monthly, Not Seasonally Adjusted	tasa
G_REV_TAX	Revenue: Tax Revenue (\$'000)	Flujo
G_REV_INP	Revenue: Income and Profits (\$'000)	Flujo
G_REV_CGR	Revenue: Central Government Revenue	Flujo
G_REV_TGS	Revenue: Taxes on Goods and Services (\$'000)	Flujo
G_REV_ITT	Revenue: International Trade and Transactions (\$'000)	Flujo
SUP_SD	Sugar production: Sugarcane Deliveries (Long tons)	Flujo
SUP_SP	Sugar production: Sugar Production (Long tons)	Flujo
SUP_MP	Sugar production: Molasses Production (Long tons)	Flujo
CIP_CD	Citrus production: Citrus Deliveries (boxes)	Flujo

Variable	Descripción	Clasificación
CIP_CJ	Citrus production: Citrus Juices ('ooops)	Flujo
ODP_BA	Other Domestic Products: Banana (Metric tons)	Flujo
ODP_MP	Other Domestic Products: Marine Products ('ooo lbs)	Flujo
ODP_GA	Other Domestic Products: Garments ('ooo lbs)	Flujo
ODP_PB	Other Domestic Products: Petroleum (Barrels)	Flujo
TOU_A	Tourist Arrivals: Air	Flujo
TOU_LAN	Tourist Arrivals: Land	Flujo
TOU_SEA	Tourist Arrivals: Sea	Flujo
TOU_SOV	Tourist Arrivals: Stay-over Visitors	Flujo
TOU_CSD	Tourist Arrivals: Cruise Ship Disembarkations	Flujo
UK_IP	Production of Total Industry in the United Kingdom, Index 2015=100, Monthly, Seasonally Adjusted	Índice
MON_AG	Monetary: Loans and advances to the agricultural sector: Sugar (\$'ooo)	stock
MON_CI	Monetary: Loans and advances to the agricultural sector: Citrus (\$'ooo)	stock
MON_GR	Monetary: Loans and advances to the agricultural sector: Grains (\$'ooo)	stock
MON_BAN	Monetary: Loans and advances to the agricultural sector: Bananas (\$'ooo)	stock
MON_CDI	Monetary: Loans and advances to the agricultural sector: Cattle and dairy (\$'ooo)	stock
MON_POE	Monetary: Loans and advances to the agricultural sector: Poultry and eggs (\$'ooo)	stock
MON_PA	Monetary: Loans and advances to the agricultural sector: Papayas (\$'ooo)	stock
MON_OTH	Monetary: Loans and advances to the agricultural sector: Other (\$'ooo)	stock
BOP_REM	BOP-Secondary Income: Credit (mostly remittances)	Flujo
GDP_TOT_A_1	lag of GDP, seasonally adjusted (Constant 2000 prices – BZ\$ million)	Flujo
GDP_AG_1	lag of GDP: Agriculture, hunting and forestry (Constant 2000 prices – BZ\$ million)	Flujo
GDP_FI_1	lag of GDP: Fishing (Constant 2000 prices – BZ\$ million)	Flujo
GDP_MA_1	lag of GDP: Manufacturing (incl. mining and quarrying) (Constant 2000 prices – BZ\$ million)	Flujo
GDP_EL_1	lag of GDP: Electricity and water (Constant 2000 prices – BZ\$ million)	Flujo
GDP_CO_1	lag of GDP: Construction (Constant 2000 prices – BZ\$ million)	Flujo

Variable	Descripción	Clasificación
GDP_WH_1	lag of GDP: Wholesale and retail trade; repair (Constant 2000 prices – BZ\$ million)	Flujo
GDP_HR_1	lag of GDP: Hotels and restaurants (Constant 2000 prices – BZ\$ million)	Flujo
GDP_TR_1	lag of GDP: Transport and communication (Constant 2000 prices – BZ\$ million)	Flujo
GDP_OT_1	lag of GDP: Other private services exc. FISIM 1) (Constant 2000 prices – BZ\$ million)	Flujo
GDP_PO_1	lag of GDP: Producers of government services (Constant 2000 prices – BZ\$ million)	Flujo
GDP_AL_1	lag of GDP: All industries at basic prices (Constant 2000 prices – BZ\$ million)	Flujo
GDP_TA_1	lag of GDP: Taxes on products (Constant 2000 prices – BZ\$ million)	Flujo

Fuente: Elaboración propia con base en CBB, SIB, BTB y FED-FRED

ANEXO 2. VARIABLES UTILIZADAS PARA EJERCICIO DE NOWCASTING DE EL SALVADOR

Variable	Descripción	Clasificación
PIB_D	PIB-Total	Índice
CE_TOT_VV	FUSADES - Confianza Empresarial - Todos los sectores - Volumen de Ventas	Índice
CE_TOT_VI	FUSADES - Confianza Empresarial - Todos los sectores - Volumen de Inversiones	Índice
CE_IND_VV	FUSADES - Confianza Empresarial - Industria - Volumen de Ventas	Índice
CE_IND_VI	FUSADES - Confianza Empresarial - Industria - Volumen de Inversiones	Índice
CE_CON_AG	FUSADES - Confianza Empresarial - Construcción - Actividad global	Índice
CE_CON_VI	FUSADES - Confianza Empresarial - Construcción - Volumen de Inversiones	Índice
CE_COM_VV	FUSADES - Confianza Empresarial - Comercio - Volumen de Ventas	Índice
CE_COM_VI	FUSADES - Confianza Empresarial - Comercio - Volumen de Inversiones	Índice
CE_SER_VV	FUSADES - Confianza Empresarial - Servicios - Volumen de Ventas	Índice
CE_SER_VI	FUSADES - Confianza Empresarial - Servicios - Volumen de Inversiones	Índice
PI_D	BCR: Índice de Producción Industrial. Serie Desestacionalizada	Índice
IVAE_TOT_D	IVAE_Total	Índice
IVAE_AG_D	IVAE: Agricultura, Ganadería, Silvicultura y Pesca	Índice
IVAE_IN_D	IVAE: Industrias Manufactureras, Explotación de Minas y Canteras y Otras Actividades Industriales	Índice

Variable	Descripción	Clasificación
IVAE_CO_D	IVAE: Construcción	Índice
IVAE_CT_D	IVAE: Comercio, Transporte y Almacenamiento, Actividades de Alojamiento y de Servicio de Comidas	Índice
IVAE_IC_D	IVAE: Información y Comunicaciones	Índice
IVAE_AF_D	IVAE: Actividades Financieras y de Seguros	Índice
IVAE_AI_D	IVAE: Actividades Inmobiliarias	Índice
IVAE_AP_D	IVAE: Actividades Profesionales, Científicas, Técnicas, Administrativas, de Apoyo y Otros Servicios	Índice
IVAE_AA_D	IVAE: Actividades de Administración Pública y Defensa, Enseñanza, Salud y Asistencia Social	Índice
PRO_ENER	Producción de Energía Eléctrica (En Miles de kWh)	Flujo
CON_ENER	Consumo de Energía Eléctrica (En Miles de kWh)	Flujo
CON_APA_CEM	Consumo Aparente de Cemento (Miles de Bolsas de 42.5 kg)	Flujo
TRAN_CAR_AE	Transporte de Carga Aérea (Miles de kg)	Flujo
TRAN_CAR_MR	Transporte de Carga Marítima (Miles de Toneladas Métricas)	Flujo
ENT_PAS	Entrada de Pasajeros (Número de Personas)	Flujo
SAL_PAS	Salida de Pasajeros (Número de Personas)	Flujo
EXP_CO	Exportaciones: Café Oro y otros cafés no procesados	Flujo
EXP_AG	Exportaciones: Agricultura, ganadería, silvicultura y pesca- Resto de productos	Flujo
EXP_MC	Exportaciones: Explotación de minas y cantera	Flujo
EXP_AC	Exportaciones: Azúcar de caña y demás azúcares	Flujo
EXP_CP	Exportaciones: Café procesado	Flujo
EXP_IM	Exportaciones: Industrias manufactureras- Resto de productos	Flujo
EXP_SE	Exportaciones: Suministro de electricidad, gas, vapor y aire acondicionado	Flujo
EXP_CM	Exportaciones: Comercio al por mayor y al por menor reparación de vehículos automotores y motocicletas	Flujo
EXP_MO	Exportaciones: Maquila de Otros Productos	Flujo
EXP_MP	Exportaciones: Maquila de Prendas de Vestir de Punto	Flujo
EXP_MT	Exportaciones: Maquila de Productos Textiles	Flujo
IMP_D_BN	Importaciones detalladas: Bienes de consumo no duraderos	Flujo
IMP_D_BD	Importaciones detalladas: Bienes de consumo duraderos	Flujo
IMP_D_IM	Importaciones detalladas: Bienes intermedios Industria Manufacturera	Flujo
IMP_D_BA	Importaciones detalladas: Bienes intermedios Agropecuario	Flujo

Variable	Descripción	Clasificación
IMP_D_BC	Importaciones detalladas: Bienes intermedios Construcción	Flujo
IMP_D_BO	Importaciones detalladas: Bienes intermedios Otros	Flujo
IMP_D_BM	Importaciones detalladas: Bienes de capital Industria Manufacturera	Flujo
IMP_D_BT	Importaciones detalladas: Bienes de capital Transporte y Comunicación	Flujo
IMP_D_BCA	Importaciones detalladas: Bienes de capital Agropecuario	Flujo
IMP_D_BCC	Importaciones detalladas: Bienes de capital Construcción	Flujo
IMP_D_BIC	Importaciones detalladas: Bienes de capital Comercio	Flujo
IMP_D_BCS	Importaciones detalladas: Bienes de capital Servicios	Flujo
IMP_D_BE	Importaciones detalladas: Bienes de capital Electricidad, Agua y Servicios	Flujo
IMP_D_BCB	Importaciones detalladas: Bienes de capital Banca	Flujo
IMP_D_BCO	Importaciones detalladas: Bienes de capital Otros	Flujo
IMP_D_MA	Importaciones detalladas: Maquila	Flujo
REM	Remesas	Flujo
INGT_ISR	Ingresos tributarios SPNF: Impuesto Sobre la Renta (Neto)	Flujo
INGT_PAT	Ingresos tributarios SPNF: Patrimonio	Flujo
INGT_TRP	Ingresos tributarios SPNF: Transferencia de Propiedades	Flujo
INGT_IMP	Ingresos tributarios SPNF: Importaciones	Flujo
INGT_COP	Ingresos tributarios SPNF: Consumo de Productos	Flujo
INGT_USE	Ingresos tributarios SPNF: Uso de Servicios	Flujo
INGT_TFS	Ingresos tributarios SPNF: Timbres Fiscales	Flujo
INGT_IVA	Ingresos tributarios SPNF: Impuesto al Valor Agregado (IVA) (neto)	Flujo
INGT_OTR	Ingresos tributarios SPNF: Otros	Flujo
INGT_FOV	Ingresos tributarios SPNF: Contribuciones Especiales (FOVIAL)	Flujo
INGC_CSS	Ingresos corrientes SPNF: Contribuciones a la Seguridad Social	Flujo
INGC_NOT	Ingresos corrientes SPNF: No Tributarios	Flujo
INGC_SEM	Ingresos corrientes SPNF: Superávit de Operación de Empresas Públicas	Flujo
INGC_TRP	Ingresos corrientes SPNF: Transferencias de Financieras Públicas	Flujo
GPC	Gasto público de consumo SPF	Flujo
GIP	Inversion pública SPNF	Flujo
BFG	Balance fiscal global (excluyendo donaciones) SPNF	Flujo
M3	M3	Stock

Variable	Descripción	Clasificación
CTC	Crédito de consumo: tarjetas de crédito	Stock
CCO	Crédito de consumo: otros	Stock
CCV	Crédito para vivienda	Stock
CAG	Crédito para Agricultura, ganadería silvicultura, caza y pesca	Stock
CCON	Crédito para construcción	Stock
CPI	Crédito para industria	Stock
CCR	Crédito para Comercio, restaurantes y hoteles	Stock
CTA	Crédito para Transporte, almacenamiento y comunicaciones	Stock
COS	Crédito para Otros servicios	Stock
COPN	Crédito: Otros préstamos no clasificados	Stock
TIP_30	Tasa de interés pasiva 30 días	Tasa
TIP_180	Tasa de interés pasiva 180 días	Tasa
TPR1	Tasa de préstamos a un año	Tasa
TPR1_MAS	Tasa de préstamo a más de un año	Tasa
ISSS_PRIM	Cotizantes ISSS sector primario	Stock
ISSS_SEC	Cotizantes ISSS sector secundario	Stock
ISSS_TER	Cotizantes ISSS sector terciario	Stock
UNEM_US	Unemployment Rate US, Percent, Monthly, Seasonally Adjusted	Tasa
UNEM_US_LA	Unemployment Rate - Hispanic or Latino, Percent, Monthly, Seasonally Adjusted	Tasa
EFFR_US	Effective Federal Funds Rate, Percent, Monthly, Not Seasonally Adjusted	Tasa
IPI_US	Industrial Production Index, Index 2012=100, Monthly, Seasonally Adjusted	Índice
IPM_US	Industrial Production: Manufacturing (NAICS), Index 2012=100, Monthly, Seasonally Adjusted	Índice
MTB_6	6-Month Treasury Bill: Secondary Market Rate, Percent, Monthly, Not Seasonally Adjusted	Tasa

Fuente: elaboración propia con base en BCR, ISSS, FUSADES y FED-FRED.

ANEXO 3. VARIABLES SELECCIONADAS POR LA REGRESIÓN LASSO PARA BELICE

Nombre de variable	Descripción
CPI_HO	Consumer price index: Housing, water, electricity, gas, & other fuels
CPI_MI	Consumer price index: Misc. goods & services
EXP_FO	Exports: Food and Live Animals (BZE \$ Million)
IMP_FO	Imports: Food and Live Animals (BZE \$ Million)
IMP_CR	Imports: Crude Materials (BZE \$ Million)
IMP_MI	Imports: Mineral Fuels & Lub. (BZE \$ Million)
IMP_OI	Imports: Oils and Fats (BZE \$ Million)
IMP_MA	Imports: Manufactured goods (BZE \$ Million)
IMP_COM	Imports: Commercial Processing Zone (BZE \$ Million)
IMP_PE	Imports: Personal Goods (BZE \$ Million)
MON_LEN_RC	Monetary: Lending Rates-residential construction
G_OVE	Government balances: overall (BZE \$ Million)
UNEM_US_LA	Unemployment Rate - Hispanic or Latino, Percent, Monthly, Seasonally Adjusted
G_REV_TAX	Revenue: Tax Revenue (\$'ooo)
G_REV_ITT	Revenue: International Trade and Transactions (\$'ooo)
ODP_BA	Production: Other Domestic Products: Banana (Metric tons)
ODP_MP	Production: Other Domestic Products: Marine Products ('ooo lbs)
TOU_LAN	Tourist Arrivals: Land
TOU_SEA	Tourist Arrivals: Sea
TOU_SOV	Tourist Arrivals: Stay-over Visitors
UK_IP	Production of Total Industry in the United Kingdom, Index 2015=100, Monthly, Seasonally Adjusted
MON_AG	Monetary: Loans and advances to the agricultural sector: Sugar (\$'ooo)
MON_BAN	Monetary: Loans and advances to the agricultural sector: Bananas (\$'ooo)
MON_OTH	Monetary: Loans and advances to the agricultural sector: Other (\$'ooo)

Fuente: elaboración propia con base en BCR, ISSS, FUSADES y FED-FRED.

ANEXO 4. VARIABLES SELECCIONADAS POR LA REGRESIÓN LASSO PARA EL SALVADOR

Nombre de variable	Descripción
CE_IND_VI	FUSADES - Confianza Empresarial - Industria - Volumen de Inversiones
CE_CON_AG	FUSADES - Confianza Empresarial - Construcción - Actividad global
IPI	BCR: Índice de Producción Industrial. Serie Desestacionalizada
IVAE_TOT	IVAE: IVAE TOTAL
IVAE_CO	IVAE: Construcción
IVAE_CT	IVAE: Comercio, Transporte y Almacenamiento, Actividades de Alojamiento y de Servicio de Comidas
IVAE_IC	IVAE: Información y Comunicaciones
IVAE_AF	IVAE: Actividades Financieras y de Seguros
IVAE_AI	IVAE: Actividades Inmobiliarias
CON_ENER	Consumo de Energía Eléctrica (En Miles de kWh)
TRAN_CAR_MR	Transporte de Carga Marítima (Miles de Toneladas Métricas)
EXP_AG	Exportaciones: Agricultura, ganadería, silvicultura y pesca- Resto de productos
EXP_CM	Exportaciones: Comercio al por mayor y al por menor reparación de vehículos automotores y motocicletas
EXP_MT	Exportaciones: Maquila de Productos Textiles
IMP_D_BA	Importaciones detalladas: Bienes intermedios Agropecuario
IMP_D_BCA	Importaciones detalladas: Bienes de capital Agropecuario
IMP_D_BCC	Importaciones detalladas: Bienes de capital Construcción
IMP_D_BCB	Importaciones detalladas: Bienes de capital Banca
INGT_ISR	Ingresos tributarios SPNF: Impuesto Sobre la Renta (Neto)
INGT_TRP	Ingresos tributarios SPNF: Transferencia de Propiedades
INGT_COP	Ingresos tributarios SPNF: Consumo de Productos
INGT_IVA	Ingresos tributarios SPNF: Impuesto al Valor Agregado (IVA) (neto)
INGT_OTR	Ingresos tributarios SPNF: Otros
INGC_CSS	Ingresos corrientes SPNF: Contribuciones a la Seguridad Social
INGC_SEM	Ingresos corrientes SPNF: Superávit de Operación de Empresas Públicas
GIP	Inversion pública SPNF
CCO	Crédito de consumo: otros
COS	Crédito para otros servicios
TPR1_MAS	Tasa de préstamo a más de un año
ISSS_PRIM	Cotizantes ISSS sector primario

Fuente: elaboración propia con base en BCR, ISSS, FUSADES y FED-FRED.



**NOWCASTING PARA
PREDECIR ACTIVIDAD
ECONÓMICA EN TIEMPO REAL:
LOS CASOS DE BELICE Y
EL SALVADOR**

*Belize y
El Salvador*