



Escuela de Gobierno y
Transformación Pública
Tecnológico de Monterrey

Working papers are preliminary documents that have not been peer-reviewed. They should not be considered conclusive or disseminated as scientifically validated information.

Monitoreo económico de alta resolución en El Salvador: Estimación oportuna del crecimiento del PIB y su desagregación espacial

José Morales-Arilla

josemoralesarilla@tec.mx

Escuela de Gobierno y Transformación Pública, Tecnológico de Monterrey

Rodrigo Sánchez Gavito Portilla

rodrigo.sanchezg@tec.mx

Laboratorio de Desarrollo Regional, Escuela de Gobierno y Transformación Pública,
Tecnológico de Monterrey

Hermilo Cortés

hermilocg@tec.mx

Laboratorio de Desarrollo Regional, Escuela de Gobierno y Transformación Pública,
Tecnológico de Monterrey

Ana Gabriela Ibarra

anaibarra927@gmail.com

School of Government and Public Transformation

Working Paper No. 35

Publication update: July 2026

Contenido

Resumen Ejecutivo.....	4
1. Introducción	6
2. Descripción de datos.....	7
2.1. Datos geoespaciales	7
2.2. Datos macroeconómicos de los EE.UU.	10
2.3. Datos administrativos.....	12
3. Enfoque Metodológico.....	15
3.1. Especificaciones de la Variable Dependiente	15
3.2. Análisis de Estacionalidad y Ajuste de las Series.....	16
3.3. Fase 1: Modelos de Serie de Tiempo Univariados	17
3.4. Fase 2: Modelos con Covariables	20
3.5. Análisis de Robustez.....	20
4. Resultados: Modelos Seleccionados y Desempeño	21
4.1. Evaluación de modelos de serie de tiempo	21
4.2. Identificación de mejores modelos con covariables.....	23
4.3. Resultados en los conjuntos de entrenamiento y prueba	24
4.4. Análisis de Robustez.....	26
5. Modelos de Aprendizaje de Máquina	27
6. Simulación de la implementación del modelo predictivo	31
6.1. Evaluación de los modelos con enfoque estático.....	31
6.2. Evaluación de los modelos de aprendizaje de máquina con enfoque dinámico	33
7. Modelo para la estimación del PIB subnacional.....	36
Conclusiones.....	44
Referencias.....	45
Anexos.....	47

Lista de Tablas

Tabla 1. Resultados de las pruebas ADF y KPSS – IVE en niveles.....	21
Tabla 2. Resultados de las pruebas ADF y KPSS –Logaritmo del IVE.	21
Tabla 3. Resultados de las pruebas ADF y KPSS – Primera Diferencia del Logaritmo del IVE.....	22
Tabla 4. Precisión de pronósticos de modelos de series de tiempo en conjunto de prueba de la primera diferencia del logaritmo del IVE.....	22
Tabla 5. Identificación de mejores modelos con covariables.	23
Tabla 6. Precisión de Pronósticos de Modelos con Covariables en Conjunto de Prueba.	25
Tabla 7. Precisión de Pronósticos de Modelos de Aprendizaje de Máquina en Conjunto de Prueba	30
Tabla 8. Valores estimados vs. observados de crecimiento económico (modelos de aprendizaje de máquina).	33
Tabla 9. RMSE de los modelos de aprendizaje de máquina.....	35
Tabla 10. Estimación del PIB sub nacional, tercer trimestre, 2025 Dólares corrientes y contribución al total.....	43



Lista de Figuras

Figura 1. Luces nocturnas VIIRS Black Marble.	8
Figura 2. Índices de Vegetación (serie desestacionalizada).	9
Figura 3. Temperatura de Superficie Terrestre (serie original).	9
Figura 4. Pluviosidad (serie desestacionalizada).	10
Figura 5. PIB constante de Estados Unidos.	11
Figura 6. Índice de Precios al Consumidor de Estados Unidos.	11
Figura 7. Índice de Volumen Encadenado del PIB para El Salvador (desestacionalizado).	12
Figura 8. Producto Interno Bruto corriente para El Salvador.	13
Figura 9. Comercio exterior para El Salvador.	13
Figura 10. Remesas Familiares para El Salvador.	14
Figura 11. Consumo Eléctrico para El Salvador (por categoría).	14
Figura 12. Entrenamiento y prueba de Modelos con Covariables, por modelo.	24
Figura 13. Errores promedio de Modelos con Covariables.	26
Figura 14. Entrenamiento y prueba de modelos con covariables, por modelo.	29
Figura 15. Errores promedio de los modelos de aprendizaje de máquina (2012 Q1-2024Q3).	30
Figura 16. Valores estimados vs. observados de crecimiento económico (promedio de los cinco mejores modelos).	32
Figura 17. Pronóstico dinámico para el IVE en nivel (Modelos Aprendizaje de Máquina).	34
Figura 18. Errores de los modelos de aprendizaje de máquina con enfoque dinámico	34
Figura 19. Metodología empleada en el modelo de desagregación espacial, Kummu et. al. (2025)37	
Figura 20. Correlaciones entre el PIB subnacional en PPP y los indicadores proxy	38
Figura 21. Correlaciones entre el PIB subnacional en PPP y el PIB corriente	40
Figura 22. PIB subnacional en PPP y PIB corriente, en logaritmos	40
Figura 23. Matriz de correlaciones entre los indicadores proxy y el PIB subnacional estimado42	
Figura 24. Estimación de la participación del PIB departamental en el PIB total	42

Resumen Ejecutivo

En los últimos años, los avances en tecnología satelital y en el procesamiento masivo de datos geoespaciales han abierto nuevas posibilidades para el análisis económico. Satélites de observación terrestre generan millones de datos sobre la actividad humana. Hoy podemos conocer lecturas diarias sobre la iluminación nocturna de las ciudades o los patrones de uso del suelo. Esta información puede utilizarse para estudiar fenómenos sociales y económicos. Por ejemplo, algunos estudios han demostrado que la intensidad de las luces nocturnas captadas desde el espacio guarda una relación estrecha con indicadores tradicionales de actividad económica, como el producto interno bruto (PIB), lo que ha permitido desarrollar metodologías innovadoras para estimar crecimiento económico o medir pobreza en países con limitaciones estadísticas.

El presente estudio aprovecha estas fuentes de información para integrar un conjunto de datos variados y construir modelos econométricos y de aprendizaje de máquina diseñados para realizar estimaciones oportunas del crecimiento del PIB en El Salvador. Los modelos predictivos que se construyen en este estudio combinan registros administrativos tradicionales (como el consumo eléctrico, las remesas o el comercio exterior) con indicadores geoespaciales captados vía satélite, entre ellos la intensidad de las luces nocturnas, el vigor de la vegetación y otras condiciones climatológicas como variables de control. Esta arquitectura de datos permite capturar el pulso de la actividad productiva y ha mostrado una relación estadística estrecha con la variación del Índice de Volumen Encadenado (IVE) desestacionalizado, indicador oficial utilizado para medir el crecimiento del PIB real en El Salvador.

Para garantizar la solidez del modelo y la confiabilidad de sus resultados, la estrategia de selección no fue producto de una decisión discrecional, sino el resultado de un protocolo de optimización masiva. En el proceso de selección de los mejores modelos, se evaluaron sistemáticamente más de 32,000 combinaciones estadísticas distintas con el fin de identificar aquellas con la mayor capacidad predictiva. Si bien las variables explicativas fueron seleccionadas con base en evidencia documentada en la literatura económica sobre su relación con la actividad productiva, no se impuso una especificación econométrica predeterminada. En cambio, mediante técnicas de ciencia de datos, todas las combinaciones posibles fueron sometidas a un proceso automatizado de evaluación comparativa, permitiendo que los algoritmos identificaran las especificaciones con mejor desempeño estadístico. Además, este mismo procedimiento completo se replicó utilizando otras medidas del PIB (incluido el PIB en valores corrientes) como ejercicio de robustez para validar los resultados obtenidos.

Utilizando un periodo de entrenamiento y otro de prueba, los resultados indican que los modelos poseen una capacidad consistente para predecir el crecimiento del PIB con un margen de error reducido. Esta conclusión se sustenta principalmente en los bajos valores del error cuadrático medio (RMSE) observados en las evaluaciones fuera de muestra, lo que indica que, en términos generales, las predicciones se mantienen cercanas a los valores efectivamente observados cuando se enfrentan a datos no utilizados durante el periodo de prueba. Complementariamente, el análisis del error promedio muestra que, en horizontes de evaluación suficientemente amplios, este converge hacia cero, lo que sugiere la ausencia de sesgos sistemáticos en las estimaciones. En conjunto, los bajos niveles de RMSE y la estabilidad del error promedio proporcionan evidencia de que los modelos generan predicciones precisas y, al mismo tiempo, estadísticamente equilibradas.

Dado que las bases de datos se actualizan con alta frecuencia y en plazos cortos, el modelo es capaz de generar una estimación del crecimiento del PIB a 45 días después del cierre de cada trimestre – esto es un mes y medio antes que la publicación oficial. La estrategia de selección de variables priorizó precisamente fuentes de datos con procesos de actualización ágiles, con el objetivo de asegurar disponibilidad oportuna de información. Esta arquitectura permite anticipar las cifras oficiales en aproximadamente un mes y medio respecto a los calendarios tradicionales de publicación del Banco Central de Reserva (BCR).

Además, aprovechando las mismas fuentes de información, este documento incorpora una metodología para estimar el PIB a nivel departamental – una métrica que actualmente no se produce de manera oficial en el país. Utilizando una combinación de las mismas fuentes de información pero que cuentan con desagregación subnacional, se construyó otro modelo estadístico para aproximar la distribución territorial del PIB. Esto contribuye a cerrar una brecha en la disponibilidad de estadísticas económicas subnacionales, proporcionando una base empírica para el análisis regional. Contar con estimaciones periódicas del PIB departamental permite identificar con mayor claridad los polos de dinamismo económico, diferentes tendencias entre territorios y las áreas con mayor potencial de crecimiento. Esta estimación puede apoyar el diseño de políticas públicas más focalizadas, orientar estrategias de inversión territorial y fortalecer la planificación económica con una perspectiva regional más informada.

Estos modelos servirán como insumo para el diseño de una herramienta en línea que permita al Gobierno de El Salvador fortalecer su capacidad de monitoreo oportuno de la economía. A través de una plataforma en línea actualizada periódicamente, los tomadores de decisión podrán contar con estimaciones tempranas sobre la evolución de la actividad económica y la estimación de la desagregación territorial del PIB. La herramienta busca complementar y no sustituir las estadísticas oficiales tradicionales, ampliando el conjunto de instrumentos disponibles para el análisis económico y la formulación de estrategias para el crecimiento económico.

El estudio incorpora algoritmos de aprendizaje de máquina diseñados para adaptarse de forma dinámica a cambios en el entorno económico. Los algoritmos de aprendizaje de máquina pueden incorporar nuevas tendencias conforme se amplía la base de datos, ajustando sus patrones de aprendizaje y capturando cambios estructurales en la actividad económica. Esto permite que el sistema identifique nuevas relaciones entre variables, tendencias emergentes o choques económicos sin necesidad de rediseñar continuamente el modelo base. En la práctica, esto fue diseñado para proveer de capacidad de adaptación a la herramienta en línea, para mantener su relevancia ante posibilidades de transformación económica. De esta forma, la plataforma que se diseñó para los tomadores de decisiones no solo ofrece una herramienta de monitoreo coyuntural, sino también un sistema analítico que evoluciona con la economía.

En conjunto, este estudio contribuye a incorporar en la práctica de la política económica las nuevas tendencias en el uso de datos y herramientas analíticas avanzadas para la toma de decisiones. La metodología desarrollada muestra el potencial de estas nuevas fuentes de datos para complementar los sistemas estadísticos tradicionales, además de generar estimaciones subnacionales que actualmente no tienen una publicación oficial. De esta manera, el proyecto no solo genera estimaciones útiles para el seguimiento de la actividad económica, sino que también sienta las bases para una infraestructura analítica más moderna, capaz de transformar grandes volúmenes de información en insumos estratégicos para la planificación económica, el diseño de políticas públicas y la promoción del desarrollo.

1. Introducción

En los últimos años, los avances en disponibilidad de datos y en capacidades analíticas han transformado la forma en que se analiza y monitorea la actividad económica. El uso de nuevas fuentes de información, como registros administrativos de alta frecuencia e indicadores geoespaciales captados por satélite, ha ampliado las herramientas disponibles para aproximar el comportamiento de la economía. Estas innovaciones han sido adoptadas crecientemente en la investigación económica y en instituciones públicas para complementar las estadísticas tradicionales, particularmente en contextos donde la información oficial se publica con rezagos o con niveles limitados de desagregación. En este contexto, el presente estudio desarrolla un modelo econométrico que integra diversas fuentes de datos y metodologías analíticas modernas para estimar y anticipar la evolución de la actividad económica en El Salvador. Además, partiendo de las mismas fuentes de datos, pero usando aquéllas que cuentan con desagregación subnacional, se construye una estimación de la desagregación territorial, que permita tener una lectura aproximada del PIB departamental en El Salvador. Estos modelos permiten generar insumos de forma oportuna, que fortalecen el monitoreo económico y el diseño de políticas públicas.

El estudio¹ detalla la forma en que se construyó el modelo de estimación del crecimiento del Producto Interno Bruto (PIB) de El Salvador, y mostrar los resultados de dicho ejercicio de estimación. Para ello, se utilizó el Índice de Volumen Encadenado (IVE) desestacionalizado como referencia principal, pero se integraron también distintas pruebas de robustez utilizando los datos del PIB corriente y otras especificaciones de la producción. El análisis se distingue por fundamentar su valor en la integración de diversas fuentes de información administrativa, macroeconómica y fuentes alternativas (como la intensidad de luces nocturnas, índices de vegetación, factores climáticos y otras) que permiten capturar la dinámica económica con mayor oportunidad que los métodos de medición tradicionales.

El documento se ha estructurado comenzando en la **Sección 2** con una descripción de las fuentes de información utilizadas. A continuación, la **Sección 3** expone el enfoque metodológico seguido, el cual se desarrolló en dos fases: una primera centrada en modelos de series de tiempo univariados y una segunda que integra las covariables externas. La **Sección 4 presenta los resultados** y la evaluación del desempeño de los modelos seleccionados, analizando su precisión mediante métricas utilizadas comúnmente en los modelos predictivos. Como complemento para fortalecer la capacidad predictiva y detectar patrones complejos, la **Sección 5** describe la implementación de modelos de aprendizaje de máquina. En la **Sección 6** se realizan ejercicios de proyección de crecimiento realizados para los trimestres más recientes, de manera que se pueda poner a prueba el modelo que se pretende utilizar para una herramienta en línea. En la **Sección 7**, por último, se hace un reporte sobre la construcción de una metodología para el cálculo del PIB a nivel departamental. Finalmente, se incluyen **anexos** con distintos detalles técnicos, variaciones en las especificaciones de la variable explicativa y otros aspectos.

¹ Se utilizaron herramientas de inteligencia artificial exclusivamente como apoyo en la redacción y edición del texto, a partir de las ideas, argumentos y contenidos definidos por los autores, así como para la revisión final del manuscrito, incluyendo aspectos de contenido, claridad, gramática y consistencia. Estas herramientas no se emplearon para generar preguntas de investigación, hallazgos, análisis, resultados empíricos, interpretaciones o conclusiones, ni contribuyeron a la construcción de la narrativa, la estructura o el diseño general del documento. La responsabilidad plena por el contenido, el análisis y la presentación de este documento de trabajo recae en sus autores.

2. Descripción de datos

Las fuentes utilizadas incluyen registros administrativos nacionales, como consumo eléctrico, comercio exterior y remesas, junto con indicadores alternativos de naturaleza geoespacial y ambiental. Entre estos se encuentran la intensidad de las luces nocturnas provenientes de distintos satélites, índices de vegetación, temperatura de la superficie, y la ocurrencia de desastres naturales. Asimismo, se consideran variables macroeconómicas de Estados Unidos, dada su relevancia para la dinámica económica salvadoreña. Adicionalmente, se emplearán los datos oficiales del Banco Central de Reserva de El Salvador, utilizando el Índice de Volumen Encadenado como la variable central para modelar el crecimiento real. La serie del Producto Interno Bruto a precios corrientes se incorporará como un insumo secundario para análisis de robustez y contraste de resultados. A continuación, se describen las principales características y alcances de cada uno de los conjuntos de datos utilizados en esta etapa del análisis.


2.1. Datos geoespaciales

El uso de indicadores geoespaciales como covariables en modelos de actividad económica está respaldado por una literatura creciente que ha validado su correlación con el PIB a distintas escalas. En el caso de las luces nocturnas, Henderson et al. (2012) establecieron la relación fundamental entre la intensidad lumínica satelital y el crecimiento económico, y estudios posteriores han extendido este análisis al producto VIIRS utilizado en este trabajo. Chen y Nordhaus (2019) documentaron que los datos VIIRS presentan ventajas sobre sus predecesores en la predicción de la actividad económica a nivel subnacional, mientras que Beyer et al. (2022) demostraron la viabilidad de utilizarlos a frecuencia trimestral como proxy del PIB en economías emergentes. Gibson et al. (2021) confirmaron además que los datos VIIRS superan en precisión a los productos DMSP anteriores, especialmente para unidades espaciales desagregadas como las que caracterizan a economías pequeñas.

- **VIIRS NASA Black Marble Product:** Datos mensuales de radiancia espectral del producto VIIRS Black Marble, los cuales fueron agregados de forma trimestral para el periodo comprendido entre enero de 2012 y septiembre de 2025. Esta métrica se expresa en nanovatios por centímetro cuadrado por estereorradián ($nW \cdot cm^{-2} \cdot sr^{-1}$) y mide la intensidad de la energía lumínica emitida por la superficie terrestre, funcionando como un proxy de alta precisión de la actividad socioeconómica². Para asegurar la estabilidad de la señal, se seleccionó la capa *AllAngle_Composite_Snow_Free* y se aplicó un control de calidad mediante el filtrado de *Quality Flags* (excluyendo QF=2 y QF=255). Este procesamiento, basado en los algoritmos de detección térmica del sensor VIIRS, garantiza que los datos estén libres de ruido atmosférico, reflejos lunares e interferencias por fuentes efímeras como los incendios forestales, permitiendo el análisis exclusivo de luces artificiales estables.

² Henderson, J. V., Storeygard, A., & Weil, D. N. (2012). *Measuring economic growth from outer space*. American Economic Review, 102(2), 994-1028.

Figura 1. Luces nocturnas VIIRS Black Marble.




Nota: Serie de tiempo de la radiancia espectral ($nW \cdot cm^{-2} \cdot sr^{-1}$) acumulada trimestralmente para el periodo 2012-2025. Los valores representan la suma de las radiancias mensuales del producto VIIRS Black Marble (VNP46A3), procesadas para eliminar interferencias por nubosidad, nieve e incendios forestales.

En cuanto a los índices de vegetación, su inclusión como indicador de actividad económica descansa principalmente en su capacidad para capturar la dinámica del sector agrícola. Johnson (2016) documentó que el EVI es uno de los mejores predictores del rendimiento de cultivos entre los índices espectrales disponibles, lo que lo convierte en un proxy válido del PIB agrícola en economías con un sector primario relevante. La incorporación de variables climáticas como temperatura superficial y pluviosidad CHIRPS responde a la evidencia de que las variaciones en estas variables afectan la actividad económica a través de múltiples canales, particularmente en países en desarrollo. Kotz et al. (2022), en un análisis global publicado en Nature, documentan que los cambios en los patrones de precipitación reducen las tasas de crecimiento económico a nivel subnacional, con efectos más pronunciados en economías de menor ingreso. De manera complementaria, la OECD (2025) señala que el impacto de las anomalías de precipitación sobre el PIB es significativamente mayor en países donde la agricultura representa una fracción relevante del producto, condición que caracteriza a la economía salvadoreña.

- **MODIS Normalized Difference Vegetation Index (NDVI):** datos presentados como un índice normalizado (escala de -1 a 1) producidos por la NASA, disponibles con una frecuencia de actualización bimensual desde febrero de 2000 hasta septiembre de 2025. Esta métrica cuantifica el vigor fotosintético mediante el contraste de reflectancia entre las bandas roja e infrarroja cercana, permitiendo monitorear la salud de la biomasa a lo largo del tiempo.
- **MODIS Enhanced Vegetation Index (EVI):** datos presentados como un índice normalizado optimizado por la NASA, disponibles con una frecuencia bimensual desde febrero de 2000 hasta septiembre de 2025. El EVI es superior en áreas de vegetación densa ya que no se satura, manteniendo una respuesta lineal con la biomasa real. Además, es más preciso porque utiliza la banda azul para limpiar la señal de aerosoles y humo, y aplica un factor de ajuste que elimina el ruido del brillo del suelo, proporcionando una medida más pura del dosel vegetal.
- **WFP Normalized Difference Vegetation Index (NDVI-WFP):** datos con frecuencia decadal distribuidos por el Programa Mundial de Alimentos (WFP), disponibles desde julio de 2002 hasta septiembre de 2025. Este indicador está optimizado para la detección temprana de

anomalías agrícolas a nivel subnacional (ADM2), facilitando el análisis de desviaciones en el vigor vegetal.


Figura 2. Índices de Vegetación (serie desestacionalizada).



Nota: Serie de tiempo de los índices de vegetación (EVI, NDVI y NDVI-WFP) expresados como un índice normalizado para el periodo comprendido entre enero de 2012 y septiembre de 2025. Los valores reflejan la intensidad del vigor fotosintético regional y la salud de la biomasa.

- **MODIS Land Surface Temperature en Grados Celsius:** datos medidos en Grados Celsius (°C) producidos por la NASA, disponibles con una frecuencia de actualización diaria desde febrero de 2000 hasta septiembre de 2025. Esta variable mide la emisión térmica de la capa superior de la superficie terrestre (suelo, vegetación o cuerpos de agua) captada por el sensor MODIS. El procesamiento de estos datos permite monitorear el balance energético regional y las variaciones térmicas superficiales, funcionando como un indicador clave para el análisis de cambios en el uso del suelo y el impacto de fenómenos climáticos locales.

Figura 3. Temperatura de Superficie Terrestre (serie original).




Nota: Serie de tiempo de la temperatura de la superficie terrestre expresada en Grados Celsius (°C) para el periodo comprendido entre enero de 2012 y septiembre de 2025. Los valores representan el promedio térmico captado por el sensor MODIS de la NASA.

- **CHIRPS Pluviosidad en milímetros:** Datos medidos en Milímetros (mm) pertenecientes al grupo *Climate Hazards Group InfraRed Precipitation with Station data* (CHIRPS), disponibles

con una frecuencia mensual desde enero de 1981 hasta septiembre de 2025. Esta variable combina datos satelitales infrarrojos con registros de estaciones climáticas in situ para crear series de tiempo de precipitación de alta resolución. Su procesamiento permite identificar patrones de variabilidad hídrica y regímenes de lluvia, siendo insumo para analizar la productividad agrícola y la disponibilidad de recursos hídricos en la región.

Figura 4. Pluviosidad (serie desestacionalizada).



Nota: Serie de tiempo de la pluviosidad acumulada expresada en Milímetros (mm) para el periodo comprendido entre enero de 2012 y septiembre de 2025. Los valores representan la estimación de precipitación del producto CHIRPS, el cual integra sensores satelitales y validación terrestre.

- **EM-DAT Desastres naturales en El Salvador:** Datos estructurados como un marcador binario de ocurrencia (donde 1 indica la presencia de un desastre y 0 su ausencia) provenientes de la *International Disaster Database* para El Salvador, el cual identifica la ocurrencia de eventos climáticos o geofísicos.

2.2. Datos macroeconómicos de los EE.UU.

La inclusión de datos económicos de Estados Unidos como covariables en el modelo responde a la estrecha integración de la economía salvadoreña con la de su principal socio comercial y fuente de remesas. El Banco Mundial (2024) caracteriza a El Salvador como una economía pequeña y dolarizada cuyo desempeño está directamente ligado al ciclo económico estadounidense a través del comercio exterior y de remesas que representan cerca del 26% del PIB. Esta dependencia tiene sustento empírico en la literatura de derramas (*spillovers*) de crecimiento: Cravino y Levchenko (2021) documentan que los países con mayor apertura comercial exhiben respuestas de producto significativamente más pronunciadas ante choques en la economía de Estados Unidos, con efectos de red que amplifican los impactos directos a través de encadenamientos bilaterales de comercio. En el caso específico de Centroamérica, López y Serrano (2025) modelan explícitamente los efectos de derrame productivo entre los países de la región y Estados Unidos, confirmando que la transmisión de choques a través del canal comercial es cuantitativamente relevante para economías pequeñas como la salvadoreña.



- **FRED PIB trimestral de EEUU:** Datos del PIB real expresados en dólares constantes producidos por la Reserva Federal de St. Louis (FRED), disponibles con una frecuencia trimestral. Esta métrica representa el valor de mercado de todos los bienes y servicios finales producidos en los Estados Unidos, ajustados por inflación para permitir comparaciones temporales precisas.


Figura 5. PIB constante de Estados Unidos.



Nota: Serie de tiempo del Producto Interno Bruto (PIB) de Estados Unidos expresado en Miles de Millones de US\$ (Billions) para el periodo comprendido entre enero de 2005 y septiembre de 2025.

- **FRED IPC trimestral de EEUU:** Datos del IPC para todos los consumidores urbanos producidos por la Reserva Federal de St. Louis (FRED), disponibles con una frecuencia trimestral. Esta variable mide el cambio promedio en el tiempo de los precios pagados por los consumidores por una canasta de bienes y servicios.

Figura 6. Índice de Precios al Consumidor de Estados Unidos.




Nota: Serie de tiempo de la tasa de variación trimestral del Índice de Precios al Consumidor (IPC) de Estados Unidos expresada en Tasa de Variación Porcentual (%) para el periodo comprendido entre 2005 y 2025.

2.3. Datos administrativos

La incorporación de variables administrativas como el comercio exterior, las remesas y el consumo eléctrico como predictores del crecimiento económico cuenta con amplio respaldo en la literatura. El vínculo entre remesas y actividad económica en El Salvador es particularmente estrecho dada su magnitud macroeconómica: la Reserva Federal (2025) y el BID (2024) documentan que los flujos de remesas hacia Centroamérica exhiben una correlación procíclica con el ciclo económico de los países receptores, comportándose como indicadores adelantados del consumo interno y de la demanda agregada. Respecto al comercio exterior, las exportaciones e importaciones capturan de forma directa la demanda externa y la dinámica de inserción en cadenas de valor globales, variables que resultan especialmente informativas en una economía pequeña y abierta como la salvadoreña. Finalmente, el consumo eléctrico es uno de los indicadores de alta frecuencia más utilizados en la literatura de modelos de predicción del PIB. Fezzi y Fanghella (2021) demostraron que el seguimiento en tiempo real de la demanda eléctrica permite estimar variaciones del PIB con una correlación de 0.98 respecto a las estadísticas oficiales durante el primer episodio de la pandemia COVID-19 en Europa, mientras que Álvarez et al. (2024) documentan una relación de largo plazo estadísticamente significativa entre consumo eléctrico y crecimiento económico para un panel de 31 países de América Latina y el Caribe, confirmando la validez de esta variable como proxy de alta sensibilidad para la actividad productiva.

- **Índice de Volumen Encadenado - Banco Central de El Salvador:** datos presentados como un índice normalizado (base 2014 = 100) producidos por el Banco Central de Reserva de El Salvador (BCR), disponibles con frecuencia trimestral hasta septiembre de 2025. Esta variable constituye el indicador clave de la actividad económica real a corto plazo, habiendo sido sometida a un proceso de desestacionalización para eliminar variaciones periódicas recurrentes.


Figura 7. *Índice de Volumen Encadenado del PIB para El Salvador (desestacionalizado).*



Nota: Serie de tiempo del Índice de Volumen Encadenado (IVE) desestacionalizado para El Salvador expresado como un índice normalizado (2014 = 100) para el periodo comprendido entre enero de 2005 y septiembre de 2025.

- Producto Interno Bruto trimestral - Banco Central de El Salvador:** datos del Producto Interno Bruto medidos a precios corrientes producidos por el Banco Central de Reserva de El Salvador (BCR), disponibles con una frecuencia trimestral hasta septiembre de 2025. Esta variable cuantifica el valor total de mercado de los bienes y servicios finales producidos dentro del territorio nacional durante un periodo determinado, sin ajustar por inflación.


Figura 8. *Producto Interno Bruto corriente para El Salvador.*



Nota: Serie de tiempo del Producto Interno Bruto (PIB) de El Salvador expresado en Millones de US\$ a precios corrientes para el periodo comprendido entre enero de 2005 y septiembre de 2025.

- Comercio Exterior - Banco Central de El Salvador:** datos de balanza comercial expresados en Millones de US\$ producidos por el Banco Central de Reserva de El Salvador (BCR), disponibles con una frecuencia trimestral hasta septiembre de 2025. Esta variable incluye las exportaciones valoradas como FOB (*Free On Board*) y las importaciones valoradas como CIF (*Cost, Insurance and Freight*).


Figura 9. *Comercio exterior para El Salvador.*



Nota: Serie de tiempo de las exportaciones e importaciones de El Salvador expresadas en Millones de US\$ (Dólares) para el periodo comprendido entre enero de 1994 y septiembre de 2025.

- Ingresos Mensuales de Remesas Familiares - Banco Central de El Salvador:** Datos expresados en Millones de US\$ producidos por el Banco Central de Reserva de El Salvador (BCR), disponibles con una frecuencia trimestral hasta septiembre de 2025. Esta variable registra el flujo de transferencias monetarias enviadas por residentes en el extranjero hacia hogares en El Salvador.


Figura 10. Remesas Familiares para El Salvador.



Nota: Serie de tiempo de los ingresos por remesas familiares expresados en Millones de US\$ para el periodo comprendido entre enero de 1991 y septiembre de 2025.

- Consumo de Electricidad:** Datos de demanda eléctrica medidos en Kilovatios-hora (kWh) para El Salvador, disponibles con frecuencia de actualización trimestral hasta septiembre de 2025. Esta variable funciona como proxy de alta sensibilidad para la actividad económica, desglosada en categorías que incluyen consumo residencial, al público, comercial, industrial y tarifas especiales.

Figura 11. Consumo Eléctrico para El Salvador (por categoría).



Nota: Serie de tiempo del consumo de energía eléctrica expresado en Kilovatios-hora (kWh) para el periodo comprendido entre enero de 1990 y septiembre de 2025.

3. Enfoque Metodológico

La presente sección detalla **la hoja de ruta técnica y los procedimientos estadísticos** seguidos para la construcción y validación de los modelos de estimación económica. Es importante precisar que este apartado tiene un carácter descriptivo de la metodología; por lo tanto, **no se presentan aquí los resultados ni hallazgos**, los cuales se presentan en la Sección 4. El flujo metodológico se ha estructurado para guiar al lector desde el tratamiento inicial de los datos crudos hasta la optimización de los modelos de predicción final.

Este proceso inicia en la Sección 3.1 con la **definición de las distintas especificaciones de la variable dependiente**, donde se evalúa el Índice de Volumen Encadenado (IVE) tanto en niveles como en sus diversas transformaciones (tasas de crecimiento, logaritmos y primeras diferencias) para garantizar las condiciones de estacionariedad requeridas para el análisis. Posteriormente, en la Sección 3.2, se describe el **análisis de estacionalidad y ajuste de las series**, para aislar componentes cíclicos y la adopción de un esquema de desestacionalización que asegure la estabilidad y comparabilidad de los factores estimados a lo largo del tiempo.

Una vez consolidada la base de datos ajustada, la **estrategia de modelado se despliega en dos etapas** complementarias:

- **Fase 1: Modelaje univariado.** Esta etapa inicial se concentra en encontrar el modelo de serie de tiempo que mejor captura la trayectoria de la serie de tiempo del PIB de El Salvador. Existen distintos modelos estadísticos para las series de tiempo, por lo que el objetivo de esta sección es tener una correcta modelación de la inercia y los patrones cíclicos propios de la serie de tiempo del PIB salvadoreño.
- **Fase 2: Integración de variables exógenas o explicativas.** Una vez establecida la base técnica, con los modelos de serie de tiempo que mejor responden al comportamiento del PIB de El Salvador, la segunda fase busca agregar las variables explicativas a las regresiones econométricas. Para ello, se incorporan las fuentes de información descritas en la Sección 2, como la intensidad lumínica satelital y el consumo eléctrico, para verificar cuáles son los modelos que muestran el mejor ajuste y poder de predicción.

3.1. Especificaciones de la Variable Dependiente

El PIB se mide con distintas especificaciones en todo el mundo. Por ejemplo, se publica en valores corrientes, en valores constantes, en índices de variación o incluso en cifras de paridad de poder adquisitivo (PPA) para hacer comparaciones internacionales. En este caso, **el modelo se construyó a partir de predecir la predicción del IVE desestacionalizado que publica el Banco Central de El Salvador**, ya que constituye el indicador técnico más adecuado para medir la actividad económica real en el corto plazo. La elección del IVE sobre otras mediciones del PIB radica en que el índice permite aislar exclusivamente las variaciones en el volumen de producción (cantidades), eliminando las distorsiones provocadas por las fluctuaciones de precios. A diferencia del PIB nominal, que refleja tanto cambios en las cantidades producidas como en los precios de mercado (inflación), el IVE ofrece una medida pura del crecimiento productivo, lo cual es esencial para que el modelo econométrico capture la dinámica real de la economía salvadoreña. Con el fin de garantizar la validez del modelaje, esta serie se evaluó tanto en niveles como en tasas de crecimiento, logaritmos y primeras diferencias del logaritmo, siendo esta última la especificación seleccionada por cumplir con las condiciones de estacionariedad requeridas.



De forma complementaria, se ha integrado el análisis de la serie del PIB a precios corrientes para realizar pruebas de robustez y contraste de los resultados. Esta parte complementaria de los resultados del modelo tiene como objetivo replicar el protocolo metodológico utilizando una medida distinta de la actividad económica al IVE para verificar si los predictores identificados y las relaciones estadísticas se mantienen estables y consistentes. Al someter el modelo a distintas métricas de producción, se asegura que las conclusiones del informe no sean sensibles a la elección de una única variable dependiente, aportando así una mayor solidez a las proyecciones generadas. Los detalles técnicos y las comparativas de estas pruebas de robustez utilizando el PIB nominal como variable dependiente se encuentran documentados en los Anexos R – AI.

3.2. Análisis de Estacionalidad y Ajuste de las Series

A partir de la inspección visual de las gráficas descriptivas presentadas en la sección de descripción de datos, se identificaron patrones cíclicos recurrentes, particularmente en los indicadores de consumo energético y variables climáticas. La detección de estos comportamientos cíclicos, que responden a periodicidades anuales predecibles, justificó la aplicación de procesos de desestacionalización a las series originales.

Para este fin, se utilizó el paquete *seasonal* del *software* estadístico R, el cual implementa los procedimientos del algoritmo *X-13ARIMA-SEATS*. Esta metodología permite descomponer la serie de tiempo para aislar de manera precisa el componente estacional, el efecto calendario y los valores atípicos.

Dado que la estrategia de validación del modelo contempla una separación explícita entre el período de entrenamiento y el período de prueba (véase la sección 3.3.3), el proceso de desestacionalización se implementó respetando dicha partición de la muestra. En particular, la serie fue tratada como dos segmentos independientes para efectos de la estimación de sus componentes estacionales y de tendencia.³

Para el conjunto de entrenamiento, la desestacionalización se realizó utilizando únicamente la información disponible dentro de ese período, de manera que la estimación de la tendencia y de los patrones estacionales reflejara exclusivamente la información que habría estado disponible en tiempo real. Posteriormente, el conjunto de prueba fue desestacionalizado por separado, empleando únicamente la información correspondiente a dicho segmento de la serie.

Este procedimiento evita que la estimación de los componentes estacionales incorpore información futura proveniente del período de prueba al momento de procesar los datos de entrenamiento. De esta manera, se elimina cualquier riesgo de filtración de información del periodo de prueba al periodo de entrenamiento y se garantiza que la evaluación fuera de muestra refleje de manera más fiel las condiciones bajo las cuales el modelo sería utilizado para generar predicciones en un entorno operativo real.

³ Como complemento, se presentan los resultados correspondientes a una desestacionalización completa de la serie en los anexos (ver Anexos H-M).

3.3. Fase 1: Modelos de Serie de Tiempo Univariados

La Fase 1 constituye el componente fundacional del sistema de estimación, cuyo propósito es capturar la dinámica histórica y las propiedades estadísticas intrínsecas del IVE. En este apartado 3.3 se describe el procedimiento y la metodología, mientras que los resultados se presentan en el mismo orden lógico, pero en la Sección 4.

3.3.1. Análisis de estacionariedad

Una vez tomada la decisión de la especificación principal del modelo (el IVE y sus transformaciones), así como las decisiones sobre las desestacionalizaciones de la serie, entonces comienza el proceso del armado del modelo predictivo. El primer paso metodológico consistió en realizar un análisis exhaustivo de la serie temporal del IVE trimestral. Se aplicaron pruebas formales de estacionariedad, como la prueba **Aumentada de Dickey-Fuller (ADF)** y la prueba **Kwiatkowski-Phillips-Schmidt-Shin (KPSS)**. El objetivo de estas pruebas es determinar si la serie posee una raíz unitaria y, en consecuencia, si requiere transformaciones como la diferenciación o la aplicación de logaritmos para convertirla en una serie estacionaria, condición necesaria para la mayoría de los modelos de series de tiempo.

3.3.2. Especificación y Evaluación de Modelos Candidatos

En la literatura econométrica, está documentado que el PIB suele tener un comportamiento de serie de tiempo; es decir, que su valor actual depende del valor de la misma serie en un periodo de tiempo anterior. La hipótesis es que la variable del PIB de El Salvador, en línea con lo observado en el resto de la literatura, también tenga un comportamiento de serie de tiempo. De esta manera, una vez comprobado que la serie es estacionaria, se plantearán distintos modelos candidatos para validar cuál de ellos captura mejor su dinámica. La gama de modelos de series de tiempo evaluados incluyó:

- **Modelos ARIMA (p, d, q):** Se explorarán distintas combinaciones de órdenes autorregresivos (p) y de media móvil (q), tales como ARIMA (1,0,0), ARIMA (0,0,1), ARIMA (1,0,1), ARIMA (2,0,1), ARIMA (1,0,2), entre otros.
- **Auto ARIMA:** Se utilizará la función *auto.arima* del *software* estadístico R como una herramienta automatizada para identificar la combinación óptima de órdenes (p,d,q) y componentes estacionales (P,D,Q) que mejor se ajuste a los datos.
- **Modelos ETS (Error, Trend, Seasonality):** Se evaluará la familia de modelos de suavizado exponencial para capturar posibles componentes de error, tendencia y estacionalidad en la serie.
- **Modelos de Regresión Lineal (OLS) con Rezagos:** Se construirán modelos autorregresivos simples utilizando entre 1 y 5 rezagos de la variable dependiente como predictores.

La selección del mejor modelo se basa en criterios de información estándar ampliamente utilizados en la literatura econométrica. Para cada modelo ajustado, **se calcularon tanto el Criterio de Información de Akaike (AIC) como el Criterio de Información Bayesiano (BIC)**. Ambos criterios buscan equilibrar la calidad del ajuste con la parsimonia del modelo, penalizando la inclusión de parámetros adicionales para evitar el sobreajuste (*overfitting*).

El AIC combina la bondad de ajuste del modelo a los datos observados con una penalización proporcional al número de parámetros estimados, de modo que modelos más complejos solo son

preferidos si la mejora en el ajuste compensa el incremento en complejidad. El BIC, por su parte, introduce una penalización más estricta que depende no solo del número de parámetros, sino también del tamaño de la muestra, lo que tiende a favorecer especificaciones más parsimoniosas, especialmente en muestras grandes. Bajo ambos criterios, valores más bajos indican un mejor equilibrio entre ajuste y simplicidad.

Con base en estos indicadores, se seleccionaron los tres modelos univariados con los valores más bajos de AIC y BIC como candidatos para el análisis subsiguiente, priorizando aquellas especificaciones que mostraron consistencia en ambos criterios.

3.3.3. Estrategia de validación: segmentación de datos (periodos de entrenamiento y de prueba)

Para que el modelo econométrico sea una herramienta válida, su éxito no debe medirse por qué tan bien explica lo que ya ocurrió, sino por su capacidad de anticipar con precisión el comportamiento futuro de la economía. Por esta razón, se ha implementado una estrategia de validación que consiste en **dividir la información disponible en dos subconjuntos independientes: un periodo de entrenamiento (*train*) y un periodo de prueba fuera de muestra (*test*)**. Además, reservamos los últimos dos periodos disponibles para simular cómo hubiera sido el comportamiento del modelo si ya hubiera estado disponible al momento en el que terminaron esos trimestres.

Con base en el conjunto de datos del **periodo de entrenamiento, el modelo aprende y se ajusta a los patrones históricos de la economía salvadoreña, identificando cómo las distintas variables influyen en el crecimiento**. Por otro lado, utilizando el conjunto de datos del periodo de prueba, el modelo debe realizar proyecciones sobre un intervalo de tiempo que deliberadamente se le ha ocultado durante su construcción. Si el modelo es capaz de predecir correctamente estos datos que no conoce, se garantiza que posee un poder predictivo y que sus resultados no son producto de un simple ajuste estadístico a los datos del pasado (fenómeno conocido como *overfitting*). Además, dado que se utilizarán un número elevado de modelos distintos, el objetivo también es verificar cuál de todos los modelos presenta un mejor ajuste y mayor capacidad predictiva fuera de muestra de entrenamiento.

Para cumplir con este rigor metodológico, se han definido los siguientes cortes temporales:

- **Conjunto de Entrenamiento:** Abarcará el período desde el primer trimestre de 2012 (2012 Q1) hasta el cuarto trimestre de 2018 (2018 Q4). Este segmento se utilizará exclusivamente para la estimación de los parámetros de cada modelo candidato.
- **Conjunto de Prueba:** Comprenderá el período desde el primer trimestre de 2019 (2019 Q1) al primer trimestre de 2025 (2025 Q1). Este subconjunto de datos no se utiliza durante el ajuste del modelo y sirve para evaluar el desempeño predictivo en información no observada previamente.

Análisis de Sensibilidad al Período COVID-19

Para aislar el efecto de la volatilidad atípica introducida por la pandemia de COVID-19, se realizó un análisis de sensibilidad en las métricas de evaluación. Este consistió en calcular el desempeño predictivo (RMSE y error promedio) bajo dos escenarios: uno que incluye el período de la pandemia (2020 Q1 a 2021 Q4) y otro que lo excluye. El propósito de esta evaluación es diferenciar la capacidad predictiva del modelo en condiciones de mayor estabilidad económica de su comportamiento ante un shock exógeno extremo.

3.3.4. Métricas de Evaluación del Desempeño Predictivo

Para evaluar y comparar de la capacidad predictiva de los distintos modelos econométricos propuestos, se utilizaron métricas estándar en el campo del pronóstico de series de tiempo. A continuación, se explican las principales herramientas empleadas para la selección del modelo final.

Raíz del Error Cuadrático Medio (Root Mean Squared Error - RMSE)

La métrica principal para la evaluación de la precisión será el RMSE. Esta medida cuantifica la desviación promedio de los valores pronosticados con respecto a los valores reales y se expresa en las mismas unidades de la variable dependiente.

$$RMSE = \sqrt{\sum \frac{(Pronóstico_i - Real_i)^2}{N}}$$

Donde $Pronóstico_i$ es el valor predicho, $Real_i$ es el valor observado y N es el número de observaciones en el conjunto de prueba. Se seleccionará el modelo que minimice el valor del RMSE en el conjunto de prueba, indicando una mayor capacidad de generalización.

Evaluación del error promedio

Además de evaluar el RMSE, se analizará el comportamiento del error promedio a lo largo de todas las especificaciones de modelos evaluadas. Se calculará el error promedio tanto para el conjunto de entrenamiento como para el de prueba, lo que permitirá evaluar el desempeño general de la familia de modelos propuestos y la consistencia de su capacidad predictiva.

$$ErrorPromedio = \overline{Pronóstico_i - Real_i}$$

Si bien la combinación de múltiples variables explicativas y un número relativamente reducido de observaciones puede aumentar el **riesgo de sobreajuste**, el objetivo del ejercicio no es identificar relaciones causales entre las covariables y el PIB, sino maximizar la capacidad predictiva del modelo. Por esta razón, la selección de especificaciones no se basó en la significancia estadística individual de las variables, sino en criterios diseñados para balancear ajuste y complejidad, como los criterios de información (AIC y BIC), así como en la evaluación sistemática del desempeño fuera de muestra mediante el RMSE.

Adicionalmente, la validación del modelo se realizó utilizando una separación temporal explícita entre los períodos de entrenamiento y prueba. Este diseño permite verificar directamente la capacidad de generalización de los modelos en datos no observados y reduce la probabilidad de que los resultados respondan únicamente a patrones específicos de la muestra de entrenamiento. En consecuencia, la principal preocupación metodológica no es la presencia de correlaciones espurias en sí mismas, sino la posibilidad de sobreajuste, aspecto que fue monitoreado de forma continua mediante la comparación entre el desempeño dentro y fuera de muestra y la penalización explícita de la complejidad de los modelos.

3.4. Fase 2: Modelos con Covariables

Luego de identificar el mejor modelo de serie de tiempo univariado (un modelo de serie de tiempo que únicamente depende de esa misma variable en periodos de tiempo rezagados), se procedió a incorporar covariables externas (agregar las variables X). Se aplicó un tratamiento análogo a las covariables continuas para que reflejen la transformación de la variable dependiente. Por ejemplo, si el modelo emplea la tasa de crecimiento del PIB, las covariables continuas también se incorporan como tasas de crecimiento, garantizando así la consistencia en la especificación.

Con el fin de asegurar la robustez del ejercicio predictivo y cumplir con el periodo de prueba establecido, la selección de covariables se restringió a aquellas con información completa hasta el primer trimestre de 2025 (2025 Q1). Un factor determinante en esta selección fue la disponibilidad regular y el tiempo de publicación de los datos. Se priorizaron las variables cuyos ciclos de actualización permiten generar proyecciones del PIB de manera oportuna. Este enfoque es esencial para el ejercicio de proyección, **pues garantiza que el modelo proporcione señales económicas anticipadas.**

Para garantizar una selección objetiva y rigurosa de los predictores, se implementó un protocolo de optimización a gran escala que trascendió la simple selección manual de variables. Mediante un proceso de computación dinámica, el sistema generó y evaluó sistemáticamente **todas las combinaciones posibles derivadas de las 15 covariables seleccionadas**, lo que resultó en un **despliegue masivo de 32,768 modelos distintos**, incluyendo la especificación base. Este enfoque de búsqueda exhaustiva permitió someter cada una de las configuraciones a un marco de evaluación estandarizado. De este universo masivo de posibilidades, se filtraron y seleccionaron únicamente aquellas especificaciones que demostraron el mejor desempeño relativo y una estabilidad superior, asegurando que la solución final no sea producto de un ajuste arbitrario, sino el resultado de una validación competitiva entre miles de alternativas posibles.

La evaluación de estos modelos siguió el mismo esquema de validación aplicado en la Fase 1. En primer lugar, se calculó el **Criterio de Información de Akaike (AIC)** para cada modelo, seleccionando los cinco modelos con los valores más bajos. Posteriormente, se aplicó el proceso de entrenamiento y prueba, y finalmente se evaluó el desempeño predictivo en el conjunto de prueba utilizando la métrica de **Raíz del Error Cuadrático Medio (RMSE)**. Este enfoque garantiza que el modelo final no solo se ajuste adecuadamente a los datos históricos, sino que también tenga una capacidad de generalización robusta.

3.5. Análisis de Robustez

Con el objetivo de confirmar la validez y consistencia de los hallazgos, se llevó a cabo un análisis de robustez que consistió en **replicar todo el procedimiento metodológico descrito en la Fase 1 y Fase 2, pero haciendo uso de la serie del Producto Interno Bruto (PIB) a precios corrientes** y sus respectivas transformaciones (tasas de crecimiento, logaritmo y primera diferencia del logaritmo).

Este análisis permitió verificar si los predictores y las relaciones identificadas en el modelo principal se mantienen estables al modelar una medida nominal de la actividad económica. Asimismo, reforzaron la validez de los resultados al asegurar que las conclusiones no son sensibles a la elección de una única métrica de producción. Los resultados de este análisis de robustez se encuentran en los Anexos P-AI.

4. Resultados: Modelos Seleccionados y Desempeño

4.1. Evaluación de modelos de serie de tiempo

Se llevó a cabo un análisis exhaustivo de la serie temporal del IVE trimestral. Inicialmente, se realizaron pruebas de estacionariedad para comprender las propiedades de la serie en niveles (ver Tabla 1). La prueba Aumentada de Dickey-Fuller (ADF) concluyó **que la serie en niveles tiene una raíz unitaria**, indicando que no es estacionaria. Este resultado fue confirmado por la prueba KPSS donde se rechazó la hipótesis nula de estacionariedad. En consecuencia, **ambas pruebas coinciden en que la serie en niveles presenta un comportamiento dependiente del tiempo con media y varianza no constantes**.

Tabla 1. Resultados de las pruebas ADF y KPSS – IVE en niveles.

Prueba	H0	P-valor	Resultado
ADF	La serie tiene raíz unitaria	0.39	No se rechaza H0 (Raíz unitaria)
KPSS	La serie es estacionaria	0.01	Se rechaza H0 (No estacionaria)

Nota: Esta tabla presenta los resultados de las pruebas de raíz unitaria y estacionariedad aplicadas a la serie del Índice de Volumen Encadenado en niveles. Las columnas detallan el nombre de la prueba estadística utilizada, la hipótesis nula (H0) evaluada en cada caso, el p-valor obtenido y el resultado formal de la prueba según los niveles de significancia estándar.

Al aplicar los mismos procedimientos a la serie del IVE en logaritmos (ver Tabla 2), la prueba ADF nuevamente no rechazó la hipótesis de raíz unitaria, mientras que la prueba KPSS rechazó la hipótesis de estacionariedad. Estos resultados confirman que la transformación logarítmica por sí sola no es suficiente para corregir la no estacionariedad de la serie.

Tabla 2. Resultados de las pruebas ADF y KPSS –Logaritmo del IVE.

Prueba	H0	P-valor	Resultado
ADF	La serie tiene raíz unitaria	0.26	No se rechaza H0 (Raíz unitaria)
KPSS	La serie es estacionaria	0.01	Se rechaza H0 (No estacionaria)

Nota: Esta tabla resume los resultados de las pruebas de raíz unitaria y estacionariedad aplicadas a la serie del Índice de Volumen Encadenado con transformación logarítmica. Las columnas detallan el nombre de la prueba estadística utilizada, la hipótesis nula (H0) evaluada en cada caso, el p-valor obtenido y el resultado formal de la prueba según los niveles de significancia estándar.

Finalmente, se examinó la primera diferencia del logaritmo del IVE (ver Tabla 3). En esta instancia la prueba ADF rechazó la hipótesis de raíz unitaria con un p-valor de 0.01 y la prueba KPSS no rechazó la hipótesis nula de estacionariedad. **Tras evaluar estas distintas versiones se determinó que la primera diferencia del logaritmo es la variable dependiente adecuada para el análisis de proyecciones por cumplir con las condiciones de estacionariedad requeridas.**

Tabla 3. Resultados de las pruebas ADF y KPSS – Primera Diferencia del Logaritmo del IVE.

Prueba	H0	P-valor	Resultado
ADF	La serie tiene raíz unitaria	0.01	Se rechaza H0 (Estacionaria)
KPSS	La serie es estacionaria	0.1	No se rechaza H0 (Estacionaria)

Nota: Esta tabla resume los resultados de las pruebas de raíz unitaria y estacionariedad aplicadas a la serie del Índice de Volumen Encadenado en primera diferencia del logaritmo. Las columnas detallan el nombre de la prueba estadística utilizada, la hipótesis nula (H0) evaluada en cada caso, el p-valor obtenido y el resultado formal de la prueba según los niveles de significancia estándar.

Posteriormente se evaluaron 15 especificaciones sobre la primera diferencia del logaritmo para caracterizar su dinámica temporal (ver Anexo A). Para cada modelo se estimaron los valores ajustados utilizando datos históricos y se evaluó la calidad del ajuste mediante los criterios de información de Akaike (AIC) y el criterio bayesiano (BIC). **El objetivo de esta comparativa fue identificar las configuraciones que minimizan ambos criterios de forma simultánea. De las 15 propuestas se seleccionaron los tres modelos con mejor desempeño consistente para proceder con la etapa de validación.** Los resultados se presentan en el Anexo A.

Posteriormente, para medir la capacidad predictiva de estos tres modelos se realizó la validación fuera de muestra utilizando los periodos de entrenamiento y prueba descritos anteriormente. Los resultados de precisión en el conjunto de prueba se presentan en la Tabla 4. Se observa que el modelo ARIMA (1,0,2) alcanzó el mejor rendimiento al registrar el Error Cuadrático Medio (RMSE) más bajo. Por su parte los modelos ARIMA (2,0,1) y ARIMA (1,0,1) mostraron niveles de precisión ligeramente inferiores. Estos resultados confirman al modelo ARIMA (1,0,2) como la opción con mayor capacidad de pronóstico para la serie del IVE en El Salvador. La selección de este modelo de serie de tiempo permite avanzar hacia la siguiente etapa del análisis. En esta fase se evalúa el desempeño de los modelos que integran las covariables previamente descritas para determinar si su inclusión logra mejorar la capacidad de predicción del sistema.

Tabla 4. Precisión de pronósticos de modelos de series de tiempo en conjunto de prueba de la primera diferencia del logaritmo del IVE.

Modelo	RMSE
ARIMA (1,0,2) sobre el IVE	0.05189628615
ARIMA (2,0,1) sobre el IVE	0.05218628256
ARIMA (1,0,1) sobre el IVE	0.05218628274

Elaboración propia.

4.2. Identificación de mejores modelos con covariables

Tras optimizar el modelo univariado, se incluyeron 15 covariables explicativas, mencionadas en la Sección 2. Se generaron y estimaron de manera sistemática todas las combinaciones posibles de covariables, lo que implicó la evaluación de más de 32 mil especificaciones alternativas. Esto permitió que la selección de predictores no fuera de forma discrecional, sino mediante un protocolo de optimización a gran escala. Este ejercicio de búsqueda exhaustiva permitió comparar cada configuración bajo un marco homogéneo de evaluación, garantizando que la selección final emergiera de una validación competitiva entre miles de alternativas.

En esta etapa, la depuración del universo de modelos se realizó utilizando criterios de información Akaike (AIC) y Bayesiano (BIC), priorizando aquellas con los valores más bajos. Estos criterios permitieron identificar las cinco configuraciones con mejor equilibrio entre ajuste y parsimonia. La Tabla 5 resume las cinco especificaciones con mejor desempeño relativo, seleccionadas con base en los criterios AIC y BIC, dentro del universo total de más de 38 mil modelos evaluados.

El predominio de variables como la temperatura, el consumo eléctrico, las remesas y otros indicadores climáticos en las especificaciones de la Tabla 5 confirma su rol como *proxis* robustos de la actividad económica salvadoreña. La estructura ARIMA incorporada corresponde a la configuración univariada que presentó el mejor ajuste a la serie del IVE.

Tabla 5. *Identificación de mejores modelos con covariables.*

	Especificación
<i>Modelo 1</i>	ARIMA (1,0,2) + NDVI (GEE) + EVI (GEE) + Temperatura + Pluviosidad + Remesas (US\$) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)
<i>Modelo 2</i>	ARIMA (1,0,2) + Luces VIIRS BM + Temperatura + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)
<i>Modelo 3</i>	ARIMA (1,0,2) + Temperatura + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)
<i>Modelo 4</i>	ARIMA (1,0,2) + Luces VIIRS BM + Temperatura + Pluviosidad + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)
<i>Modelo 5</i>	ARIMA (1,0,2) + Temperatura + Pluviosidad + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)


Nota: Especificaciones de los cinco modelos con mejor desempeño predictivo. Cada modelo incluye una estructura ARIMA (1,0,2) y diferentes combinaciones de covariables seleccionadas mediante el protocolo de optimización.

4.3. Resultados en los conjuntos de entrenamiento y prueba

Para validar la capacidad productiva de los cinco mejores modelos propuestos, éstos se sometieron a una validación de su comportamiento utilizando en el conjunto de datos de entrenamiento y el conjunto de datos de prueba. Los resultados obtenidos muestran que la herramienta es sólida, arrojando estimaciones que se traducen en bajos niveles de Error Cuadrático Medio (RMSE) y que son mejores que el RMSE del modelo base univariado. Esta mejora en la precisión confirma que la integración de covariables alternativas y administrativas aporta un valor predictivo superior para capturar la realidad económica de El Salvador. La Figura 12 y la Tabla 6 muestran los resultados obtenidos y las mejoras observadas en la capacidad predictiva. El Modelo 5 presenta el mejor desempeño en términos de RMSE total.

No obstante, al analizar la trayectoria histórica de las estimaciones, se observa que las desviaciones más significativas se concentran puntualmente en el periodo de la pandemia de COVID-19. Este comportamiento es técnicamente esperado, dado que dicho fenómeno representó un choque exógeno de volatilidad extrema que resultó excepcionalmente difícil de predecir para cualquier modelo estadístico basado en patrones históricos. Es importante destacar que, al realizar un análisis de sensibilidad que excluye este periodo de distorsión atípica, las predicciones promedio mejoran de forma notable y el RMSE disminuye drásticamente, situándose en niveles de alta precisión cercanos al 0.01, como lo muestra la Tabla 6.

Figura 12. Entrenamiento y prueba de Modelos con Covariables, por modelo.



Nota: Predicciones de los mejores modelos contra los valores observados de la primera diferencia del logaritmo del IVE. La línea gris representa el valor observado, la línea roja el valor predicho del modelo base, y la línea azul el valor predicho del modelo con covariables. Se muestra el período de entrenamiento y el de prueba (azul).

Tabla 6. *Precisión de Pronósticos de Modelos con Covariables en Conjunto de Prueba.*

	Modelo	RMSE	RMSE (sin COVID)
Modelo 1	ARIMA (1,0,2) + NDVI (GEE) + EVI (GEE) + Temperatura + Pluviosidad + Remesas (US\$) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	0.032539	0.011186
Modelo 2	ARIMA (1,0,2) + Luces VIIRS BM + Temperatura + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	0.041396	0.010466
Modelo 3	ARIMA (1,0,2) + Temperatura + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	0.033144	0.01068
Modelo 4	ARIMA (1,0,2) + Luces VIIRS BM + Temperatura + Pluviosidad + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	0.042127	0.010567
Modelo 5	ARIMA (1,0,2) + Temperatura + Pluviosidad + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	0.031832	0.011295
Modelo Base	ARIMA (1,0,2) sobre el Índice Encadenado	0.051896	0.011038


Nota: Desempeño predictivo de los cinco mejores modelos con covariables en el conjunto de prueba. Se reporta el RMSE para la muestra completa y excluyendo el período COVID-19, junto con el modelo base de referencia.

Con el fin de evaluar si las predicciones presentan algún sesgo sistemático de sobreestimación o subestimación, se analiza el error promedio simple de los modelos, definido como la diferencia entre el crecimiento observado y el crecimiento estimado. A diferencia de métricas como el RMSE, este indicador permite verificar si los errores tienden a concentrarse persistentemente por encima o por debajo de cero, aun cuando su magnitud promedio sea reducida.

Para facilitar la interpretación de los resultados, la Figura 13 presenta una visualización consolidada construida a partir del promedio de los errores de los cinco modelos con mejor desempeño. Esta representación resume de manera sencilla el comportamiento agregado del conjunto de modelos y permite identificar posibles patrones de sesgo en las predicciones. Los resultados muestran que el error promedio se mantiene consistentemente alrededor de cero, tanto antes como después del punto de corte que separa los conjuntos de entrenamiento y prueba, indicado por la línea roja punteada. Asimismo, salvo por la volatilidad extraordinaria observada

durante el período asociado a la pandemia de COVID-19, sombreado en naranja, no se aprecia una tendencia persistente hacia la sobreestimación o la subestimación del crecimiento económico. En conjunto, estos resultados sugieren que las predicciones son, en promedio, insesgadas y que las variables incorporadas en los modelos contribuyen a generar estimaciones equilibradas a lo largo del tiempo.

Figura 13. Errores promedio de Modelos con Covariables.



Nota: Distribución de los errores promedio de predicción para los cinco mejores modelos. La línea punteada roja marca la separación entre el período de entrenamiento y prueba, y la zona de color naranja marca el período COVID (2020-2021).

En conclusión, la evidencia presentada confirma que el modelo propuesto posee una capacidad robusta para predecir el crecimiento del IVE, insesgada y operando con un margen de error pequeño y estadísticamente centrado en cero. Este nivel de estabilidad indica que el modelo propuesto es eficaz y capaz de generar señales económicas oportunas.

4.4. Análisis de Robustez

Con el objetivo de confirmar la robustez de los hallazgos presentados en términos de capacidad predictiva, se realizó un análisis complementario **mediante la aplicación del mismo protocolo metodológico a la serie del PIB a precios corrientes**. Este ejercicio se llevó a cabo sobre tres transformaciones específicas: el logaritmo del PIB corriente, la primera diferencia del logaritmo y la tasa de crecimiento trimestral. El propósito de este análisis es verificar si el protocolo propuesto es capaz de identificar modelos con mejoras consistentes en la predicción fuera de muestra, independientemente de la métrica de producción utilizada.

Para cada una de estas transformaciones, se replicaron las etapas que conforman el protocolo, que comprenden la verificación de condiciones de estacionariedad mediante pruebas formales de raíz unitaria, la Fase 1 de identificación y selección de modelos univariados, y la Fase 2 de incorporación de covariables. Este proceso garantiza que la comparación con los resultados del análisis principal sea metodológicamente coherente y que cualquier mejora observada sea atribuible al protocolo y no a decisiones ad hoc en alguna etapa particular.

Los resultados obtenidos son consistentes con los del análisis principal. En todas las transformaciones evaluadas, el protocolo metodológico logró identificar especificaciones con mejoras sistemáticas en la capacidad predictiva fuera de muestra respecto a los modelos base, confirmando que dichas mejoras no son exclusivas de una métrica particular de actividad económica, sino que se sostienen ante distintas representaciones de la variable dependiente (ver Anexo AI).

Este ejercicio de robustez valida que el enfoque propuesto es estable. Independientemente de la métrica del PIB utilizada, el protocolo demuestra una capacidad consistente para mejorar la predictibilidad fuera de muestra. Los detalles del análisis, incluyendo las pruebas de estacionariedad y los indicadores de desempeño predictivo para cada transformación, se presentan en los anexos (ver Anexos P-AI).

Adicionalmente, con el fin de aproximar las condiciones operativas bajo las cuales operará una herramienta en línea, se desarrolló un ejercicio específico de simulación en tiempo real para los trimestres más recientes. Dicho ejercicio considera las restricciones de disponibilidad de información asociadas a las distintas fuentes utilizadas y permite evaluar la factibilidad de producir estimaciones antes de la publicación oficial de las cuentas nacionales. Los supuestos operativos y resultados detallados de esta validación se presentan en la Sección 6.

5. Modelos de Aprendizaje de Máquina

Como complemento al protocolo descrito en las secciones 3 y 4, se entrenaron modelos de aprendizaje de máquina para utilizar técnicas distintas de modelación y predicción. Este ejercicio tiene como objetivo fortalecer la capacidad predictiva y adaptativa del sistema de estimación del crecimiento del PIB. Mientras que los modelos econométricos permiten interpretar correlaciones entre variables con base en fundamentos teóricos y económicos, los modelos de aprendizaje automático aportan flexibilidad, capacidad de ajuste dinámico y detección de patrones complejos que pueden no ser capturados por las especificaciones en las que los coeficientes de las estimaciones se mantienen estáticos.

A diferencia de los modelos tradicionales, los modelos de aprendizaje automático pueden captar relaciones no lineales y efectos cruzados entre variables sin necesidad de definirlos explícitamente, y se actualizan fácilmente conforme se dispone de nueva información, sin necesidad de depender de una actualización por parte de algún analista. Este elemento permite expandir la vigencia de las predicciones ante tendencias emergentes que no sean capturadas con los modelos originales. Además, sus mecanismos de regularización reducen el riesgo de sobreajuste y ayudan a identificar automáticamente las variables más relevantes, mientras que su capacidad para simular múltiples escenarios mejora la comprensión de la sensibilidad del PIB frente a distintas condiciones o políticas públicas.

Las variables explicativas incorporadas son las mismas que se utilizan en el protocolo descrito en las Secciones 2 a 4. Sin embargo, para el caso de los modelos de aprendizaje de máquina, no es necesario realizar un procedimiento de selección de variables. Los mecanismos de regularización incluidos en el entrenamiento de estos modelos son un sustituto a la selección de variables.

La evaluación del desempeño de estos modelos se realizó mediante la medida de Raíz del Error Cuadrático Médio (RMSE). Esta medida sirvió para la selección del mejor modelo, el cual tiene una capacidad predictiva histórica alta dado su valor de RMSE.




Los modelos de aprendizaje de máquina que se utilizaron fueron los siguientes:

- **Modelos de Ensamble:** Este grupo de modelos combina múltiples estimadores simples (como árboles de decisión) para mejorar la precisión de las predicciones. Cada iteración busca corregir los errores de la anterior, lo que da lugar a modelos más robustos.
 - **Decision Tree Regressors:** Construye un árbol de decisión único que divide los datos en función de las variables más relevantes para explicar la variable objetivo.
 - **Random Forest:** Combina varios árboles de decisión entrenados con diferentes muestras de los datos, y promedia sus resultados para obtener predicciones más estables y precisas.
 - **AdaBoost:** Asigna más peso a los casos que el modelo ha predicho mal, de manera que en las siguientes iteraciones el modelo se enfoque en corregirlos.
 - **XGBoost:** Es una versión más avanzada del método de boosting, que optimiza el proceso de aprendizaje y controla la complejidad del modelo para mejorar el rendimiento y evitar el sobreajuste.
- **Regresiones Regularizadas:** Estos modelos buscan una relación lineal entre las variables explicativas y la variable a predecir, pero añaden un “penalizador” para evitar que el modelo dependa demasiado de variables poco relevantes.
 - **Lasso:** Elimina automáticamente las variables menos útiles al ajustar el modelo.
 - **Ridge:** Reduce la influencia de las variables menos importantes sin eliminarlas completamente.

Se aplicó el mismo proceso de análisis de robustez y evaluación del desempeño predictivo descrito en la sección 3 y 4, con el objetivo de garantizar la consistencia y confiabilidad de los resultados obtenidos. Esto implica comparar las predicciones del modelo con los valores observados utilizando métricas cuantitativas como la Raíz del Error Cuadrático Medio (RMSE) y otras medidas complementarias de precisión. Asimismo, se realizaron pruebas con los mismos periodos de entrenamiento y de prueba fuera de muestra para verificar la capacidad del modelo de generalizar correctamente ante nuevos datos y evitar sobreajustes.

La Figura 14 presentan los resultados de los distintos modelos de aprendizaje de máquina propuestos. Estos modelos fueron entrenados para capturar relaciones no lineales y patrones complejos en la actividad económica de El Salvador, y se utilizó el periodo de entrenamiento y prueba descrito en las secciones anteriores. Este enfoque permite verificar no solo el ajuste retrospectivo, sino la robustez de las herramientas de cara a su implementación en la plataforma en línea para los tomadores de decisión.

Figura 14. Entrenamiento y prueba de modelos con covariables, por modelo.



Nota: Distribución de los valores observados (línea azul) y estimados (línea roja) con los modelos de aprendizaje de máquina. La línea amarilla marca la separación entre el período de entrenamiento y prueba, y la zona de color gris marca el período COVID (2020-2021).

La evaluación del desempeño predictivo se realizó utilizando la métrica de la Raíz del Error Cuadrático Medio (RMSE), la cual permite identificar con precisión qué tan cerca están las estimaciones de los valores reales del IVE. Según los datos recopilados en la Tabla 7, el modelo de *Decision Tree Regressor* destaca por presentar el menor RMSE de todo el grupo, consolidándose como la opción de mejor ajuste estadístico inicial. Por el contrario, el modelo de regresión regularizada *Ridge* mostró el desempeño más deficiente, con un error significativamente más alto que el resto de las especificaciones, lo que sugiere que su estructura lineal penalizada no logra capturar adecuadamente las rupturas estructurales de la economía nacional.

Al igual que en los resultados de los modelos lineales de la Sección 4, las desviaciones más importantes de los modelos predictivos ocurren en el periodo de Covid. Así, al realizar el ejercicio de eliminar el periodo COVID-19 de la muestra, se observa que la precisión de casi todos los modelos mejora de manera sustancial, situándose con niveles de RMSE por debajo del umbral de 0.01. Por ejemplo, el desempeño de modelos como *Random Forest* y *AdaBoost* se vuelve preciso en condiciones de estabilidad económica. La única excepción a esta tendencia de mejora es el modelo *Ridge*, cuyo desempeño, de hecho, empeora al excluir los datos de la pandemia, confirmando su falta de idoneidad para este sistema de estimación. La Tabla 7 resume los resultados de ambos ejercicios.


Tabla 7. Precisión de Pronósticos de Modelos de Aprendizaje de Máquina en Conjunto de Prueba

Modelo	RMSE	RMSE (Sin COVID)
Decision Tree Regresor	0.05473	0.00957
AdaBoost	0.05504	0.00881
Lasso	0.05512	0.00908
Random Forest	0.05531	0.00870
XGBoost	0.05535	0.00898
Ridge	0.13435	0.13849

Fuente: elaboración propia con datos del BCR.

Al igual que se observó en los modelos lineales tradicionales, la mayoría de las especificaciones de aprendizaje de máquina (con excepción de Ridge y Decision Tree) demuestran una alta capacidad predictiva y estabilidad. Como se aprecia en la Figura 15, los errores promedio de estos modelos oscilan consistentemente alrededor de cero, lo que indica la ausencia de sesgos sistemáticos de sobreestimación o subestimación. Este comportamiento se mantiene simétrico tanto en el periodo de entrenamiento como en el de prueba, confirmando que la volatilidad observada es atribuible exclusivamente al periodo atípico de la crisis sanitaria y no a una deficiencia estructural del modelado.

Figura 15. Errores promedio de los modelos de aprendizaje de máquina (2012 Q1-2024Q3).



Nota: Distribución de los errores promedio (línea azul) de los modelos de aprendizaje de máquina. La línea amarilla marca la separación entre el período de entrenamiento y prueba, y la zona de color gris marca el período COVID (2020-2021).

Sin embargo, algunos modelos de aprendizaje de máquina tienen algunos comportamientos que no son óptimos. El modelo *Lasso* en realidad hace una predicción lineal simple durante todo el periodo. El modelo *Ridge* inicia estable, pero al final del periodo se deteriora notablemente su capacidad de predicción, desviándose considerablemente de la realidad. El modelo de *Decision Tree Regressors*, que a lo largo de casi todo el periodo muestra un desempeño sobresaliente, al final del periodo ocurre un sesgo negativo, lo que podría limitar su capacidad predictiva en los periodos subsecuentes.

6. Simulación de la implementación del modelo predictivo


6.1. Evaluación de los modelos con enfoque estático

Esta sección presenta los resultados de los ejercicios de proyección realizados bajo un entorno de simulación de operación real, con el fin de evaluar la capacidad de la herramienta para anticipar la dinámica económica. Para este ejercicio, se reservaron datos de trimestres con datos disponibles a la fecha de elaboración de este reporte, correspondientes a un año de seguimiento (cuatro trimestres, del segundo de 2025 al primero de 2026). El objetivo de este procedimiento fue simular cómo se habrían comportado las predicciones de los modelos si la herramienta ya hubiera estado disponible en ese momento, permitiendo contrastar de forma directa la estimación frente a lo observado en el tiempo.

Uno de los mayores valores agregados de este sistema es la ganancia sustancial en la oportunidad de la información. Debido a que el modelo se nutre de indicadores administrativos y alternativos de alta frecuencia, estas proyecciones pueden actualizarse aproximadamente 45 días después de que finaliza un trimestre. En términos prácticos, esto significa que la herramienta podría proporcionar una estimación confiable del crecimiento del IVE un mes y medio (45 días) antes de que el Banco Central de Reserva (BCR) publique la serie oficial del crecimiento del PIB. Esta ventaja cronológica permite transformar los datos en una herramienta estratégica para la toma de decisiones, facilitando la identificación de tendencias económicas de manera proactiva y fortaleciendo las labores de promoción de inversiones antes de que las cifras tradicionales estén disponibles.

La Figura 16 presenta los resultados del ejercicio de simulación, comparando el desempeño de los modelos lineales durante el periodo de validación final. Este patrón es consistente con el comportamiento esperado en ejercicios de validación fuera de muestra. El desempeño de un modelo debe evaluarse en términos de su error promedio a lo largo de un horizonte temporal amplio, el cual tiende a oscilar alrededor de cero si el modelo está bien especificado. Sin embargo, en trimestres individuales pueden observarse desviaciones positivas o negativas respecto al dato observado, sin que ello invalide la capacidad predictiva general del modelo.


Figura 16. Valores estimados vs. observados de crecimiento económico (promedio de los cinco mejores modelos).



Nota: Comparación entre valores proyectados y observados de crecimiento económico para los trimestres 2025-Q2 al 2026-Q1.

En el mismo sentido, se realizó el ejercicio para los modelos de aprendizaje de máquina, para este último periodo de validación final. La Tabla 8 presenta los resultados de dicha estimación para el periodo de cuatro trimestres que va de 2025-Q2 al 2026-Q1, junto con una visualización de los pronósticos y el dato observado. Los resultados son consistentes con las conclusiones de la Sección 5. Por un lado, los modelos *Decision Tree* y *Ridge* muestran un desempeño inferior al resto de los modelos (y sobre todo modelo *Ridge*, cuyos pronósticos están completamente fuera de rango y por lo tanto no se incluyeron en la visualización). Los modelos que tienen mejor desempeño en este periodo (medido por el RMSE) fueron XGBoost, Random Forest y Ada Boost.

Tabla 8. Valores estimados vs. observados de crecimiento económico
(modelos de aprendizaje de máquina).



Fuente: elaboración propia.


6.2. Evaluación de los modelos de aprendizaje de máquina con enfoque dinámico

Una de las principales ventajas de los modelos de aprendizaje de máquina es su capacidad de incorporar nueva información de manera flexible, sin necesidad de modificar manualmente su especificación. A diferencia de modelos paramétricos tradicionales, estos algoritmos pueden ajustar sus patrones de aprendizaje conforme se amplía la base de datos, permitiendo capturar cambios estructurales, nuevas tendencias o choques económicos de forma más ágil.

Con este objetivo, se implementó un ejercicio de evaluación dinámica basado en ventanas móviles de entrenamiento y prueba. En cada iteración, se reservan únicamente los últimos ocho trimestres (dos años) como periodo de prueba, mientras que el resto de la muestra se utiliza para entrenamiento. A medida que avanza el tiempo, el conjunto de entrenamiento incorpora progresivamente nuevos datos, de modo que el modelo “aprende” con información más reciente en cada trimestre. Este procedimiento permite evaluar la capacidad adaptativa de los algoritmos frente a cambios en el entorno económico.

Bajo este esquema, se generaron pronósticos dinámicos del IVE en nivel desde el primer trimestre de 2021 hasta el tercer trimestre de 2025. La Figura 17 presenta las trayectorias estimadas por cada modelo de aprendizaje de máquina, comparadas con la serie observada. En términos generales, se observa un choque común en el trimestre 2024Q3; sin embargo, resulta relevante que los modelos ajustan rápidamente sus predicciones conforme incorporan la nueva información disponible. En particular, para los trimestres 2025Q2 y 2025Q3 las estimaciones convergen nuevamente hacia la trayectoria observada, reflejando una capacidad adecuada de adaptación.

Figura 17. Pronóstico dinámico para el IVE en nivel (*Modelos Aprendizaje de Máquina*).



Para cuantificar el desempeño predictivo bajo este enfoque dinámico, se calculó el RMSE entre los valores pronosticados y los observados del IVE. Los resultados, presentados en la Tabla 9, muestran una mejora significativa respecto al enfoque original que incluía el período de alta volatilidad asociado al COVID-19. Esto indica que el esquema dinámico permite amortiguar el impacto de choques extremos al recalibrar continuamente los parámetros con información reciente.

Figura 18. Errores de los modelos de aprendizaje de máquina con enfoque dinámico



Tabla 9. *RMSE de los modelos de aprendizaje de máquina*

Modelo	RMSE (enfoque dinámico)	RMSE (enfoque estático)	
		Normal	Sin Covid
Random Forest	0.0149	0.05473	0.00957
AdaBoost	0.0149	0.05504	0.00881
Decision Tree	0.0153	0.05512	0.00908
Lasso	0.0213	0.05531	0.00870
XGBoost	0.0273	0.05535	0.00898
Ridge	0.1258	0.13435	0.13849

Si bien el RMSE bajo este enfoque dinámico se mantiene ligeramente por encima del obtenido en el ejercicio que excluye el período de COVID, esta diferencia puede explicarse por la menor longitud del periodo de prueba en el enfoque dinámico (ocho trimestres), lo cual reduce el número de observaciones sobre las que se promedia el error. En muestras más cortas, las desviaciones individuales tienen mayor peso relativo, lo que puede elevar marginalmente la métrica de error. Además, una buena parte de la desviación de las estimaciones dinámicas ocurre durante el tercero y cuarto trimestre de 2024, en donde también se observa un comportamiento atípico en la serie original del IVE. No obstante, hacia el final del periodo las estimaciones de los modelos se recuperan y vuelven a estar bastante en línea con el nivel observado en el IVE. Esto muestra señales de resiliencia y adaptabilidad de los modelos, que es exactamente el objetivo que se está buscando agregar al incorporar estas técnicas.

En conjunto, los resultados sugieren que ambos enfoques, tanto estático como dinámico, aportan valor complementario. El esquema estático ofrece estabilidad y buen desempeño promedio en entornos relativamente normales, mientras que el enfoque dinámico mejora la capacidad de reacción ante choques recientes o cambios en tendencia. Por ello, se recomienda mantener ambas versiones dentro del sistema de monitoreo: el modelo estático como referencia base de desempeño estructural y el modelo dinámico como mecanismo de ajuste adaptativo ante nuevas condiciones económicas.

7. Modelo para la estimación del PIB subnacional

Ante la inexistencia de cifras oficiales de producción con desagregación departamental y municipal en El Salvador, se desarrolló una arquitectura metodológica orientada a estimar el dinamismo económico subnacional utilizando fuentes alternativas de información. El enfoque combina datos geoespaciales, registros administrativos y técnicas econométricas modernas para aproximar la evolución territorial de la actividad económica con frecuencia trimestral. La estrategia parte de un principio central: en ausencia de estadísticas regionales oficiales, es posible inferir la distribución espacial del producto a partir de variables observables que guardan una relación sistemática con la actividad económica.


El modelo se construye en seis etapas: (1) se adopta una base teórica de referencia para el PIB subnacional; (2) se validan empíricamente los indicadores proxy disponibles para El Salvador; (3) se homogeneizan las series a frecuencia trimestral; (4) se valida la relación entre el PIB nacional en PPP y el PIB nominal; (5) se estima un modelo econométrico para construir el PIB sub nacional; y (6) se utiliza la estructura espacial estimada para desagregar el PIB nacional corriente publicado oficialmente cada trimestre por el BCR.

Paso 1. Marco de referencia: base internacional de PIB subnacional en PPP

La base conceptual del ejercicio se apoya en el proyecto “Downscaled gridded global dataset for gross domestic product (GDP) per capita PPP over 1990–2022”, el cual genera estimaciones de PIB per cápita ajustado por paridad de poder adquisitivo (PPP) a nivel administrativo 2 (municipal) para un amplio conjunto de países. Dicho estudio construye series históricas combinando datos subnacionales reportados oficialmente con técnicas de extrapolación y desagregación espacial basadas en aprendizaje automático, garantizando consistencia entre niveles territoriales y agregados nacionales. La Figura X resume el marco metodológico y modelo de datos empleados por los autores para hacer sus estimaciones globales del PIB subnacional.

Para El Salvador, este estudio proporciona una serie anual de PIB per cápita municipal en PPP para el período 1990–2022. Si bien el modelo específico utilizado por los autores no es replicable en su totalidad y además se limita a frecuencia anual, sus estimaciones constituyen un punto de partida sólido para entrenar y validar un modelo propio que permita extender la información a frecuencia trimestral y a años más recientes.

Figura 19. Metodología empleada en el modelo de desagregación espacial, Kummu et. al. (2025)



Fuente: Kummu, M., Kosonen, M., & Masoumzadeh Sayyar, S. (2025). Downscaled gridded global dataset for gross domestic product (GDP) per capita PPP over 1990–2022. Scientific Data, 12(1), 178.

Paso 2. Selección y validación de indicadores proxy


La estimación integra cuatro fuentes principales de información:⁴

- PIB per cápita en PPP a nivel municipal (anual, 1990–2022), utilizado como variable objetivo para el entrenamiento inicial. Es la estimación generada por el proyecto *Downscaling*, descrito previamente.
- Datos de población provenientes del proyecto *WorldPop*, con resolución espacial de 100 metros (anual, 2015–2030).
- Radiancia nocturna del producto *VIIRS Black Marble* (mensual, 2012–2025), agregada a frecuencia trimestral.
- Consumo de electricidad medido en kilovatios-hora a nivel municipal (mensual, 2003–2025), agregado trimestralmente.

Las luces nocturnas capturan intensidad de actividad económica y urbanización; el consumo eléctrico refleja directamente la dinámica productiva y de servicios; y la población permite controlar por escala demográfica y densidad económica. En conjunto, estas variables constituyen indicadores utilizados para aproximar la actividad económica territorial.

Antes de proceder con la estimación del modelo, se verificó que las variables seleccionadas mantuvieran una relación estadísticamente significativa con las estimaciones de PIB subnacional en PPP. Para el año 2022, se realizó un análisis de correlación cruzada a nivel municipal entre el PIB subnacional en PPP y las variables de población, consumo eléctrico e intensidad lumínica, trabajando en escala logarítmica. Los resultados muestran correlaciones positivas y robustas, particularmente elevadas en el caso de la población y el consumo eléctrico. La intensidad de luces nocturnas también presenta una relación significativa, capturando de manera consistente la infraestructura económica y el grado de urbanización. Esta validación confirma que las variables seleccionadas poseen capacidad explicativa suficiente para integrarse en un modelo econométrico de estimación territorial. La Figura 20 muestra estas tres correlaciones.

Figura 20. Correlaciones entre el PIB subnacional en PPP y los indicadores proxy




⁴ Fuentes: PIB per cápita: <https://doi.org/10.5281/zenodo.10976733>

Población: <https://hub.worldpop.org/project/categories?id=3>

Luces nocturnas (VIIRS): <https://blackmarble.gsfc.nasa.gov/>

Consumo eléctrico: Superintendencia General de Electricidad y Telecomunicaciones (SIGET)



Fuente: cálculos propios con datos de la NASA, Banco Central de Reserva, WorldPop y SIGET.


Paso 3. Homogeneización temporal de las series

Dado que el objetivo es producir estimaciones trimestrales, fue necesario transformar las series originalmente anuales a una frecuencia compatible con los indicadores de oportunidad. En el caso de la población, se realizó una interpolación lineal bajo el supuesto de ausencia de estacionalidad significativa. Para extender la serie hacia atrás, se incorporaron datos censales de 1992 a nivel departamental, utilizando proporciones municipales observadas en años posteriores para reconstruir la distribución territorial histórica de manera consistente. Para el PIB per cápita en PPP, cuya dinámica sí presenta componente cíclico, se utilizó el método de Chow-Lin para desagregación temporal. Esta técnica permite transformar datos de baja frecuencia en series de mayor frecuencia empleando un indicador de referencia. En este caso, se utilizó el IVE para utilizar su tendencia, pues sabemos que es el indicador clave de la actividad económica. Esta decisión permite preservar coherencia con los datos agregados (nacionales) y modelar la autocorrelación de los residuos. El resultado es una serie trimestral de PIB per cápita PPP a nivel municipal alineada con el ciclo económico nacional, y que permite ser comparable con cifras trimestrales de los indicadores *proxy*.

Paso 4. Relación entre PIB en PPP y PIB corriente


El modelo se entrena para estimar el PIB subnacional en términos de PPP, ya que esa es la variable disponible en la base internacional utilizada como referencia. Sin embargo, el Banco Central publica trimestralmente el PIB nacional en términos corrientes. Por tanto, es necesario validar la relación entre ambas variables. Al agregar las estimaciones municipales de PIB PPP y compararlas con el PIB corriente nacional, se observa una correlación de 0.95 y un coeficiente de determinación superior a 0.90 en una regresión lineal simple. Estos resultados sugieren que ambas series comparten una dinámica altamente consistente en el tiempo. La Figura 21 presenta la correlación entre ambas variables y la Figura 22 muestra ambas variables en sus valores en niveles históricos, y permiten validar visualmente una estrecha correlación entre ambas variables.

Figura 21. Correlaciones entre el PIB subnacional en PPP y el PIB corriente



Fuente: cálculos propios con datos del BCR y Kummu et. al. (2025)

Figura 22. PIB subnacional en PPP y PIB corriente, en logaritmos



Fuente: cálculos propios con datos del BCR y Kummu et. al. (2025)



El supuesto operativo del modelo es que la estructura relativa de generación de valor entre departamentos capturada en PPP es representativa de la estructura espacial del PIB corriente.

En ausencia de deflatores regionales diferenciados, este supuesto permite trasladar las participaciones estimadas en PPP al agregado nominal nacional de forma consistente. Es decir, utilizando los datos trimestrales de los indicadores proxys, se puede obtener una estimación del PIB PPP subnacional para cada trimestre y para cada departamento. Esos datos se pueden agregar para tener una estimación del PIB nacional en PPP. Con ello, es posible conocer la participación de cada departamento en el PIB nacional. Y así, finalmente, utilizando el dato publicado por el BCR del PIB nominal nacional, es posible estimar el valor del PIB subnacional cada trimestre.

Paso 5: Especificación y resultados del modelo econométrico


La arquitectura técnica para el pronóstico del PIB subnacional trimestral consiste en un modelo de Vectores Autorregresivos de Panel bajo un enfoque Bayesiano (BVAR-Panel). La información y especificación detallada del modelo se presentan en el Anexo AJ. La elección del modelo es estratégica por dos razones fundamentales:

1. Endogeneidad y relaciones espaciales: reconoce que variables como las luces, el consumo eléctrico y la población se determinan mutuamente. El enfoque de panel permite modelar no solo la inercia individual de cada departamento, sino también las interacciones y derrames económicos entre ellos, capturando así la dimensión espacial de la economía salvadoreña.
2. Eficiencia estadística: la estimación bayesiana soluciona el problema de los tamaños de muestra reducidos en series de tiempo cortas, permitiendo inferir parámetros robustos a pesar de contar con solo una década de información histórica.

El modelo fue entrenado utilizando el periodo de convergencia de todas las variables (2012 Q1 – 2022 Q4) en niveles logarítmicos. Posteriormente, se generaron proyecciones dinámicas para cada departamento para el intervalo 2023 Q1 – 2025 Q3. Los resultados muestran que las estimaciones se adaptan de forma ágil a los cambios recientes en la información disponible. Es notable cómo, tras un choque de volatilidad observado en 2024 Q3, los modelos de panel demuestran una capacidad de adaptación superior, estabilizando las trayectorias de crecimiento para los trimestres finales de 2025. Los resultados de la estimación del PIB subnacional en valores PPP para cada uno de los departamentos de El Salvador durante 2023 – 2025 se presentan en el Anexo AK.

Los resultados del modelo muestran que la relación entre el PIB departamental en PPP estimado y las variables proxy utilizadas se mantiene en niveles elevados y significativos a lo largo del período de estimación y proyección. En particular, las correlaciones trimestrales se ubican consistentemente en rangos altos, lo que confirma que los indicadores seleccionados conservan su capacidad explicativa incluso fuera del período estrictamente observado en la base internacional. Esta estabilidad sugiere que el modelo no depende de relaciones espurias o transitorias, sino que captura vínculos estructurales entre actividad económica y variables territoriales observables. La matriz de correlaciones presentada en la Figura 23 ilustra esta solidez empírica y refuerza la idoneidad de los proxys como fundamentos del sistema de estimación.


Figura 23. Matriz de correlaciones entre los indicadores proxy y el PIB subnacional estimado



Fuente: Cálculos propios, la matriz muestra el indicador de correlación para cada periodo entre las variables proxy y el PIB subnacional estimado por el modelo.

Adicionalmente, al comparar las trayectorias estimadas para el período 2023 en adelante con la serie histórica del proyecto internacional utilizado como referencia, se observa una continuidad coherente con la estructura típica del PIB de un país. No se identifican saltos abruptos ni quiebres estructurales en la transición entre 2022 (último año observado en la base original) y 2023 (inicio del período estimado mediante los indicadores proxy con el modelo propuesto). Por el contrario, las participaciones relativas departamentales y las dinámicas de crecimiento muestran una evolución gradual y consistente con los patrones históricos, lo que indica que el modelo logra extender la serie sin introducir distorsiones artificiales. Esta estabilidad intertemporal es un resultado clave, ya que sugiere que la arquitectura propuesta reproduce de manera verosímil la distribución territorial del valor agregado y preserva la coherencia macroeconómica del sistema.

Figura 24. Estimación de la participación del PIB departamental en el PIB total



Fuente: Elaboración propia con datos de Kummu et. al. (2025) y estimaciones propias del modelo de desagregación territorial.

Paso 6: Cálculo trimestral del PIB nominal subnacional

Una vez estimado el PIB en PPP para cada departamento, se calcula la participación relativa de cada territorio en el total nacional. Teniendo estas ponderaciones, entonces se pueden aplicar al valor oficial del PIB corriente nacional publicado trimestralmente, permitiendo obtener una estimación del PIB corriente subnacional. El procedimiento asume que la estructura espacial del valor agregado capturada por el modelo PPP refleja adecuadamente la distribución territorial del PIB nominal. Dado el alto grado de correlación observado entre ambas magnitudes a nivel agregado, este enfoque constituye una aproximación consistente y operativamente viable para desagregar el PIB nacional. La Tabla 10 muestra la desagregación subnacional del PIB corriente para el trimestre 2025Q3. Por ejemplo, para el departamento de La Libertad, el ponderador estimado con el modelo es que ese departamento contribuyó con el 12.7% del PIB total (en PPP, que es la variable que podemos estimar con el modelo construido). Así, asumiendo que esa proporción se mantiene, podemos inferir que el PIB en términos corrientes del departamento La Libertad es \$1,164 millones de dólares para el tercer trimestre del 2025.

Tabla 10. *Estimación del PIB sub nacional, tercer trimestre, 2025*
Dólares corrientes y contribución al total

Desagregación Subnacional del Producto Interno Bruto Trimestral				
Precios corrientes. Millones de US\$				
Departamento	2025Q3			
departamento	Ponderador	Nivel	5% quantile	95% quantile
Ahuachapán	4.60%	419.42	417.16	421.66
Cabañas	2.20%	198.99	198.04	199.96
Chalatenango	2.30%	207.39	206.8	207.94
Cuscatlán	3.80%	348.48	347.45	349.53
La Libertad	12.70%	1164.74	1161.08	1168.87
La Paz	5.20%	477.94	476.45	479.47
La Unión	2.40%	224.17	223.54	224.82
Morazán	2.10%	190.3	189.71	190.95
San Miguel	7.20%	664.82	662.29	667.32
San Salvador	35.10%	3229.54	3221.52	3237.21
San Vicente	2.10%	190.65	189.6	191.56
Santa Ana	8.20%	755.35	752.55	758.12
Sonsonate	7.30%	675.0	672.07	677.51
Usulután	4.90%	447.82	445.2	449.97

Fuente: estimaciones propias con base en el modelo de desagregación territorial.

El resultado final es una serie trimestral de PIB corriente por departamento que mantiene coherencia con el dato oficial nacional, respeta la dinámica económica capturada por los indicadores territoriales y ofrece una herramienta para el análisis regional y el seguimiento de la actividad económica. Las series departamentales pueden consultarse en el Anexo AK.

Conclusiones

Tras concluir el proceso de diseño, calibración y validación del sistema econométrico, los resultados obtenidos han sido positivos, demostrando que el modelo desarrollado posee una capacidad robusta para predecir la trayectoria real de la actividad económica salvadoreña con un margen de error pequeño y estadísticamente centrado en cero. El modelo fue basado en la selección de variables geoespaciales, económicas y administrativas que cuentan con evidencia en la literatura económica de estar vinculadas al comportamiento del PIB y que, al ser de alta frecuencia, garantizan una actualización oportuna. Gracias a esta arquitectura de datos, el sistema permite generar una estimación confiable apenas 45 días después del cierre de cada trimestre. Esto es un adelanto de un mes y medio con relación a la publicación de las cifras oficiales que publica el Banco Central de Reserva de El Salvador. La estimación pretende complementar y no sustituir las métricas oficiales.

Además, la implementación de la metodología para la estimación del PIB subnacional cierra una brecha histórica en las estadísticas del país, logrando una estructura de participación económica territorial plenamente consistente con las cuentas nacionales. Al integrar el consumo eléctrico local con la radiancia satelital, se puede disponer de una base para el seguimiento regional y el diseño de políticas de desarrollo diferenciadas por departamento. Asimismo, la innovación introducida mediante modelos de aprendizaje de máquina dota al sistema de una flexibilidad superior para capturar patrones complejos que los modelos estáticos no perciben, otorgando una capacidad de ajuste dinámico ante futuros cambios estructurales.

Los resultados obtenidos son consistentes y metodológicamente robustos, permitiendo elaborar un modelo de vanguardia en el uso de datos alternativos para la toma de decisiones estratégicas. Este producto constituye la definitiva para una herramienta en línea que fue implementada para el gobierno y los tomadores de decisión, proveyendo inteligencia económica moderna que transforma datos complejos en activos de alto valor para fortalecer el análisis económico, dar seguimiento a indicadores de coyuntura y proveer datos complementarios que actualmente no existen en publicaciones oficiales, como el PIB departamental.

Referencias

- Álvarez, Isaac, Javier Barbero, y José Luis Zofío. 2024. «Economic Growth and Electricity Consumption: Fresh Evidence of Panel Data for LAC». *Heliyon* 10(12). doi:10.1016/j.heliyon.2024.e32900.
- Beyer, Robert C. M., Sebastian Franco-Bedoya, y Virgilio Galdo. 2022. *Measuring Quarterly Economic Growth from Outer Space*. Vol. 2022. IMF Working Papers. International Monetary Fund. doi:10.5089/9798400210211.001.
- Chen, Xi, y William D. Nordhaus. 2019. «VIIRS Nighttime Lights in the Estimation of Cross-Sectional and Time-Series GDP». *Remote Sensing* 11(9):1057. doi:10.3390/rs11091057.
- Cravino, Javier, y Andrei A. Levchenko. 2021. *Output Spillovers through Trade and Financial Linkages*. Federal Reserve Bank of Boston Working Papers. Federal Reserve Bank of Boston. <https://www.bostonfed.org/-/media/Documents/Workingpapers/PDF/2021/wp2113.pdf>.
- Federal Reserve Board. 2025. *Global Remittances Cycle*. FEDS Notes. Board of Governors of the Federal Reserve System. <https://www.federalreserve.gov/econres/notes/feds-notes/global-remittances-cycle-20250227.html>.
- Fezzi, Carlo, y Valeria Fanghella. 2021. «Tracking GDP in Real-Time Using Electricity Market Data: Insights from the First Wave of COVID-19 across Europe». *European Economic Review* 139:103907. doi:10.1016/j.eurocorev.2021.103907.
- Gibson, John, Susan Olivia, y Geua Boe-Gibson. 2021. «Which Night Lights Data Should We Use in Economics, and Where?» *Journal of Development Economics* 149:102602. doi:10.1016/j.jdeveco.2020.102602.
- Henderson, J. Vernon, Adam Storeygard, y David N. Weil. 2012. «Measuring Economic Growth from Outer Space». *American Economic Review* 102(2):994-1028. doi:10.1257/aer.102.2.994.
- Inter-American Development Bank. 2024. *Remittances to Latin America and the Caribbean Moderate Their Growth in 2024*. Inter-American Development Bank. <https://www.iadb.org/en/news/remittances-latin-america-and-caribbean-moderate-their-growth-2024>.
- Johnson, David M. 2016. «A 2010 Map Estimate of Annually Tilled Cropland within the Conterminous United States». *Agricultural Systems* 149:99-108. doi:10.1016/j.agry.2016.09.001.
- Kotz, Maximilian, Anders Levermann, y Leonie Wenz. 2022. «The Effect of Rainfall Changes on Economic Production». *Nature* 601:223-27. doi:10.1038/s41586-021-04283-8.
- López, Arnaldo, y Jeffrey Serrano. 2025. *Productivity Spillovers through Trade Integration in Central America*. Inter-American Development Bank. doi:10.18235/0013391.



Organisation for Economic Co-operation and Development. 2025. *Global Drought Outlook: Impacts and Costs of Droughts*. OECD Publishing. doi:10.1787/28488e98-en.

World Bank. 2024. *El Salvador Overview*. World Bank Group.
<https://www.worldbank.org/en/country/elsalvador/overview>.


Anexos

Anexo A. *Criterios de Ajuste de los Modelos de Series de Tiempo de la Primera Diferencia del Logaritmo del IVE.*

Modelo	AIC	BIC
ARIMA (1,0,1) sobre el Índice Encadenado	-207.567	-199.611
ARIMA (2,0,1) sobre el Índice Encadenado	-205.833	-195.888
ARIMA (1,0,2) sobre el Índice Encadenado	-205.832	-195.887
Auto ARIMA Índice Encadenado ARIMA (0,0,0)	-205.348	-197.393
ARIMA (0,0,2) sobre el Índice Encadenado	-205.348	-197.393
ARIMA (0,0,1) sobre el Índice Encadenado	-201.104	-195.137
ARIMA (2,0,0) sobre el Índice Encadenado	-199.873	-191.917
ARIMA (0,0,0) sobre el Índice Encadenado	-199.449	-195.471
ARIMA (1,0,0) sobre el Índice Encadenado	-199.215	-193.248
OLS Lagged Índice Encadenado (1)	-194.502	-188.592
OLS Lagged Índice Encadenado (2)	-190.389	-182.584
OLS Lagged Índice Encadenado (3)	-185.567	-175.908
OLS Lagged Índice Encadenado (4)	-180.063	-168.591
OLS Lagged Índice Encadenado (5)	-174.155	-160.912
ETS sobre el Índice Encadenado	-135.283	-129.316


Nota: Criterios de información AIC y BIC para las especificaciones univariadas de series de tiempo aplicadas a la primera diferencia del logaritmo del Índice de Volumen Encadenado.

Anexo B. Ajuste de Mejores Modelos de Series de Tiempo de la Primera Diferencia del Logaritmo del IVE.



Nota: Visualización del ajuste de los mejores modelos univariados de series de tiempo para la primera diferencia del logaritmo del Índice de Volumen Encadenado. La línea gris representa el valor observado y las líneas punteadas representan los valores predichos de cada modelo.

Anexo C. Ajuste de Mejores Modelos de Series de Tiempo de la Primera Diferencia del Logaritmo del IVE (Error Promedio).



Nota: Visualización de los errores promedio de los mejores modelos de series de tiempo para la primera diferencia del logaritmo del Índice de Volumen Encadenado.


Anexo D. Criterios de Ajuste de los Modelos con Covariables de la Primera Diferencia del Logaritmo del IVE (desestacionalización parcial 2012 Q1 – 2024 Q3).

	Modelo	AIC	BIC
<i>Modelo 1</i>	ARIMA (1,0,2) + NDVI (GEE) + EVI (GEE) + Temperatura + Pluviosidad + Remesas (US\$) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	-333.976	-308.362
<i>Modelo 2</i>	ARIMA (1,0,2) + Luces VIIRS BM + Temperatura + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	-333.175	-309.531
<i>Modelo 3</i>	ARIMA (1,0,2) + Temperatura + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	-332.861	-311.188
<i>Modelo 4</i>	ARIMA (1,0,2) + Luces VIIRS BM + Temperatura + Pluviosidad + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	-332.568	-306.954
<i>Modelo 5</i>	ARIMA (1,0,2) + Temperatura + Pluviosidad + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	-332.43	-308.786

Nota: Criterios de información AIC y BIC para los cinco mejores modelos con covariables de la primera diferencia del logaritmo del Índice de Volumen Encadenado bajo el esquema de desestacionalización parcial.



Anexo E. Ajuste de Mejores Modelos con Covariables de la Primera Diferencia del Logaritmo del IVE (desestacionalización parcial 2012 Q1 – 2024 Q3).



Nota: Visualización del ajuste de los cinco mejores modelos con covariables para la primera diferencia del logaritmo del Índice de Volumen Encadenado bajo el esquema de desestacionalización parcial. La línea gris representa el valor observado y las líneas punteadas representan los valores predichos de cada modelo.

Anexo F. T-Test Errores promedio incluyendo COVID de la Primera Diferencia del Logaritmo del IVE (desestacionalización parcial 2012 Q1 – 2024 Q3).

	Modelo	Train Error Promedio	Train (P- valor)	Test Error Promedio	Test (P- valor)
Modelo 1	ARIMA (1,0,2) + NDVI (GEE) + EVI (GEE) + Temperatura + Pluviosidad + Remesas (US\$) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	0.0002	0.8847	0.0013	0.8377
Modelo 2	ARIMA (1,0,2) + Luces VIIRS BM + Temperatura + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	0.0001	0.8900	0.0009	0.9155
Modelo 3	ARIMA (1,0,2) + Temperatura + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	0.0001	0.9212	0.0014	0.8311
Modelo 4	ARIMA (1,0,2) + Luces VIIRS BM + Temperatura + Pluviosidad + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	0.0001	0.9051	0.0010	0.9074
Modelo 5	ARIMA (1,0,2) + Temperatura + Pluviosidad + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	0.0001	0.9026	0.0013	0.8411
Modelo Base	ARIMA (1,0,2) sobre el Índice Encadenado	0.0000	0.9748	0.0009	0.9292

Nota: Resultados de las pruebas T para evaluar la significancia estadística de los errores promedio en los períodos de entrenamiento y prueba (incluyendo COVID-19) para los cinco mejores modelos con covariables bajo el esquema de desestacionalización parcial.

Anexo G. T-Test Errores promedio excluyendo COVID de la Primera Diferencia del Logaritmo del IVE



(desestacionalización parcial 2012 Q1 – 2024 Q3).

	Model	Train Error Promedi o	Train (P-valor)	Test Error Promedi o	Test (P-valor)
Model o 1	ARIMA (1,0,2) + NDVI (GEE) + EVI (GEE) + Temperatura + Pluviosidad + Remesas (US\$) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	0.0002	0.8847	0.0017	0.4955
Model o 2	ARIMA (1,0,2) + Luces VIIRS BM + Temperatura + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	0.0001	0.8900	0.0007	0.7382
Model o 3	ARIMA (1,0,2) + Temperatura + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	0.0001	0.9212	0.0018	0.4503
Model o 4	ARIMA (1,0,2) + Luces VIIRS BM + Temperatura + Pluviosidad + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	0.0001	0.9051	0.0007	0.7366
Model o 5	ARIMA (1,0,2) + Temperatura + Pluviosidad + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	0.0001	0.9026	0.0017	0.4980
Model o Base	ARIMA (1,0,2) sobre el Índice Encadenado	0.0000	0.9748	0.0019	0.3936

Nota: Resultados de las pruebas t para evaluar la significancia estadística de los errores promedio en los períodos de entrenamiento y prueba (excluyendo COVID-19) para los cinco mejores modelos con covariables bajo el esquema de

desestacionalización parcial.

Anexo H. Identificación de mejores modelos (desestacionalización completa).

Especificación	
<i>Modelo 1</i>	ARIMA (1,0,2) + Luces VIIRS BM + EVI (GEE) + Temperatura + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)
<i>Modelo 2</i>	ARIMA (1,0,2) + EVI (GEE) + Temperatura + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)
<i>Modelo 3</i>	ARIMA (1,0,2) + Luces VIIRS BM + EVI (GEE) + Temperatura + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Especiales) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)
<i>Modelo 4</i>	ARIMA (1,0,2) + Temperatura + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)
<i>Modelo 5</i>	ARIMA (1,0,2) + Luces VIIRS BM + Temperatura + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)

Nota: Especificaciones de los cinco modelos con mejor desempeño predictivo bajo el esquema de desestacionalización completa. Cada modelo incluye una estructura ARIMA (1,0,2) y diferentes combinaciones de covariables seleccionadas mediante el protocolo de optimización.


Anexo I. Criterios de Ajuste de los Modelos con Covariables de la Primera Diferencia del Logaritmo del IVE (desestacionalización completa).

	Modelo	AIC	BIC
Modelo 1	ARIMA (1,0,2) + Luces VIIRS BM + EVI (GEE) + Temperatura + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	-336.121	-310.508
Modelo 2	ARIMA (1,0,2) + EVI (GEE) + Temperatura + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	-335.523	-311.879
Modelo 3	ARIMA (1,0,2) + Luces VIIRS BM + EVI (GEE) + Temperatura + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Especiales) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	-335.481	-307.897
Modelo 4	ARIMA (1,0,2) + Temperatura + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	-335.106	-313.433
Modelo 5	ARIMA (1,0,2) + Luces VIIRS BM + Temperatura + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	-335.076	-311.432

Nota: Criterios de información AIC y BIC para los cinco mejores modelos con covariables de la primera diferencia del logaritmo del Índice de Volumen Encadenado bajo el esquema de desestacionalización completa.




Anexo J. Ajuste de Mejores Modelos con Covariables de la Primera Diferencia del Logaritmo del IVE (desestacionalización completa).



Nota: Visualización del ajuste de los cinco mejores modelos con covariables para la primera diferencia del logaritmo del Índice de Volumen Encadenado bajo el esquema de desestacionalización completa. La línea gris representa el valor observado y las líneas punteadas representan los valores predichos de cada modelo.

Anexo K. Entrenamiento y prueba de Modelos con Covariables, por modelo (desestacionalización completa).



Nota: Comparación de las predicciones de los cinco mejores modelos con covariables contra los valores observados de la primera diferencia del logaritmo del Índice de Volumen Encadenado, bajo el esquema de desestacionalización completa. La línea gris representa el valor observado, la línea punteada roja el valor predicho del modelo base, y la línea punteada azul el valor predicho del modelo con covariables. Se muestran tanto el período de entrenamiento como el período de prueba.


Anexo L. Precisión de Pronósticos de Modelos con Covariables en Conjunto de Prueba (desestacionalización completa).

	Modelo	RMSE	RMSE (sin COVID)
<i>Modelo 1</i>	ARIMA (1,0,2) + Luces VIIRS BM + EVI (GEE) + Temperatura + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	0.044751	0.01413
<i>Modelo 2</i>	ARIMA (1,0,2) + EVI (GEE) + Temperatura + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	0.041888	0.01438
<i>Modelo 3</i>	ARIMA (1,0,2) + Luces VIIRS BM + EVI (GEE) + Temperatura + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Especiales) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	0.043709	0.01331
<i>Modelo 4</i>	ARIMA (1,0,2) + Temperatura + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	0.04146	0.014271
<i>Modelo 5</i>	ARIMA (1,0,2) + Luces VIIRS BM + Temperatura + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	0.044703	0.014102
<i>Modelo Base</i>	ARIMA (1,0,2) sobre el Índice Encadenado	0.051896	0.01103

Nota: Desempeño predictivo de los cinco mejores modelos con covariables en el conjunto de prueba bajo el esquema de desestacionalización completa. Se reporta el RMSE para la muestra completa y excluyendo el período COVID-19, junto con el modelo base de referencia.



Anexo M. Errores promedio de Modelos con Covariables (desestacionalización completa).



Nota: Distribución de los errores promedio de predicción para los cinco mejores modelos bajo el esquema de desestacionalización completa. La línea punteada roja marca la separación entre el período de entrenamiento y prueba, y la zona de color gris marca el período COVID (2020-2021).

Anexo N. T-Test Errores promedio incluyendo COVID de la Primera Diferencia del Logaritmo del IVE (desestacionalización completa).

	Model	Train Error Promedi o	Train (P- valor)	Test Error Promedi o	Test (P- valor)
Modelo 1	ARIMA (1,0,2) + Luces VIIRS BM + EVI (GEE) + Temperatura + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	-0.0002	0.8736	0.0007	0.9347
Modelo 2	ARIMA (1,0,2) + EVI (GEE) + Temperatura + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	-0.0002	0.8404	0.0012	0.8839
Modelo 3	ARIMA (1,0,2) + Luces VIIRS BM + EVI (GEE) + Temperatura + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Especiales) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	-0.0002	0.8553	0.0009	0.9181
Modelo 4	ARIMA (1,0,2) + Temperatura + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	-0.0002	0.8662	0.0012	0.8906
Modelo 5	ARIMA (1,0,2) + Luces VIIRS BM + Temperatura + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	-0.0001	0.8817	0.0007	0.9374
Modelo Base	ARIMA (1,0,2) sobre el Índice Encadenado	0.0000	0.9748	0.0009	0.9292

Nota: Resultados de las pruebas T para evaluar la significancia estadística de los errores promedio en los períodos de entrenamiento y prueba (incluyendo COVID-19) para los cinco mejores modelos con covariables bajo el esquema de desestacionalización completa.

Anexo O. T-Test Errores promedio excluyendo COVID de la Primera Diferencia del Logaritmo del IVE

(desestacionalización completa).

	Model	Train Error Promedio	Train (P- valor)	Test Error Promedio	Test (P- valor)
Model o 1	ARIMA (1,0,2) + Luces VIIRS BM + EVI (GEE) + Temperatura + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	-0.0002	0.873 6	-0.0016	0.6065
Model o 2	ARIMA (1,0,2) + EVI (GEE) + Temperatura + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	-0.0002	0.840 4	-0.0005	0.8713
Model o 3	ARIMA (1,0,2) + Luces VIIRS BM + EVI (GEE) + Temperatura + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Especiales) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	-0.0002	0.855 3	-0.0013	0.6708
Model o 4	ARIMA (1,0,2) + Temperatura + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	-0.0002	0.866 2	-0.0005	0.8660
Model o 5	ARIMA (1,0,2) + Luces VIIRS BM + Temperatura + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	-0.0001	0.881 7	-0.0017	0.5997
Model o Base	ARIMA (1,0,2) sobre el Índice Encadenado	0.0000	0.974 8	0.0004	0.8823

Nota: Resultados de las pruebas *T* para evaluar la significancia estadística de los errores promedio en los períodos de entrenamiento y prueba (excluyendo COVID-19) para los cinco mejores modelos con covariables bajo el esquema de desestacionalización completa.

Anexo P. Resultados de las pruebas ADF y KPSS – Logaritmo del PIB – Análisis de Robustez.

Prueba	H0	P-valor	Resultado
ADF	La serie tiene raíz unitaria	0.75	No se rechaza H0 (Raíz unitaria)
KPSS	La serie es estacionaria	0.01	Se rechaza H0 (No estacionaria)

Nota: Esta tabla presenta los resultados de las pruebas de raíz unitaria y estacionariedad aplicadas a la serie del Índice de Volumen Encadenado en niveles. Las columnas detallan el nombre de la prueba estadística utilizada, la hipótesis nula (H0) evaluada en cada caso, el p-valor obtenido y el resultado formal de la prueba según los niveles de significancia estándar.

Anexo Q. Resultados de las pruebas ADF y KPSS – Primera Diferencia del Logaritmo del PIB – Análisis de Robustez.

Prueba	H0	P-valor	Resultado
ADF	La serie tiene raíz unitaria	0.02	Se rechaza H0 (Estacionaria)
KPSS	La serie es estacionaria	0.1	No se rechaza H0 (Estacionaria)

Nota: Esta tabla resume los resultados de las pruebas de raíz unitaria y estacionariedad aplicadas a la serie del Índice de Volumen Encadenado con transformación logarítmica. Las columnas detallan el nombre de la prueba estadística utilizada, la hipótesis nula (H0) evaluada en cada caso, el p-valor obtenido y el resultado formal de la prueba según los niveles de significancia estándar.

Anexo R. Resultados de las pruebas ADF y KPSS – Tasa de Crecimiento Intertrimestral del PIB – Análisis de Robustez.

Prueba	H0	P-valor	Resultado
ADF	La serie tiene raíz unitaria	0.02	Se rechaza H0 (Estacionaria)
KPSS	La serie es estacionaria	0.1	No se rechaza H0 (Estacionaria)

Nota: Esta tabla resume los resultados de las pruebas de raíz unitaria y estacionariedad aplicadas a la serie del Índice de Volumen Encadenado en primera diferencia del logaritmo. Las columnas detallan el nombre de la prueba estadística utilizada, la hipótesis nula (H0) evaluada en cada caso, el p-valor obtenido y el resultado formal de la prueba según los niveles de significancia estándar.

Anexo S. Identificación de mejores modelos de Primera Diferencia del Logaritmo del PIB (desestacionalización completa) – Análisis de Robustez.

Especificación	
<i>Modelo 1</i>	ARIMA (1,0,0) + Luces VIIRS BM + Pluviosidad + Desastres Naturales (Binaria) + Remesas (US\$) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)
<i>Modelo 2</i>	ARIMA (1,0,0) + Luces VIIRS BM + Desastres Naturales (Binaria) + Remesas (US\$) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)
<i>Modelo 3</i>	ARIMA (1,0,0) + Luces VIIRS BM + Desastres Naturales (Binaria) + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)
<i>Modelo 4</i>	ARIMA (1,0,0) + Luces VIIRS BM + Pluviosidad + Desastres Naturales (Binaria) + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)
<i>Modelo 5</i>	ARIMA (1,0,0) + Pluviosidad + Desastres Naturales (Binaria) + Remesas (US\$) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)
<i>Modelo Base</i>	ARIMA (1,0,0) on Log Diff

Nota: Especificaciones de los cinco modelos con mejor desempeño predictivo de la Primera Diferencia del Logaritmo del PIB, bajo el esquema de desestacionalización completa. Cada modelo incluye una estructura ARIMA (1,0,0) y diferentes combinaciones de covariables seleccionadas mediante el protocolo de optimización.

Anexo T. Identificación de mejores modelos de Tasa de Crecimiento Intertrimestral del PIB (desestacionalización completa) – Análisis de Robustez.

Especificación	
<i>Modelo 1</i>	ARIMA (0,0,0) + Desastres Naturales (Binaria) + Importaciones (US\$ CIF) + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Total)
<i>Modelo 2</i>	ARIMA (0,0,0) + Desastres Naturales (Binaria) + Importaciones (US\$ CIF) + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio)
<i>Modelo 3</i>	ARIMA (0,0,0) + Desastres Naturales (Binaria) + Exportaciones (US\$ FOB) + Importaciones (US\$ CIF) + Remesas (US\$) + Consumo Eléctrico (Al público)
<i>Modelo 4</i>	ARIMA (0,0,0) + Desastres Naturales (Binaria) + Exportaciones (US\$ FOB) + Importaciones (US\$ CIF) + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio)
<i>Modelo 5</i>	ARIMA (0,0,0) + Desastres Naturales (Binaria) + Importaciones (US\$ CIF) + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)
<i>Modelo Base</i>	Auto ARIMA Log PIB ARIMA (0,0,0)

Nota: Especificaciones de los cinco modelos con mejor desempeño predictivo de la Tasa de Crecimiento Intertrimestral del PIB, bajo el esquema de desestacionalización completa. Cada modelo incluye una estructura ARIMA (1,0,0) y diferentes combinaciones de covariables seleccionadas mediante el protocolo de optimización.


Anexo U. Criterios de Ajuste de los Modelos con Covariables del Logaritmo del PIB Corriente (desestacionalización completa).

	Modelo	AIC	BIC
<i>Modelo 1</i>	OLS Lagged Log PIB (4) + Luces VIIRS BM + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	-216.579	-197.459
<i>Modelo 2</i>	OLS Lagged Log PIB (4) + Luces VIIRS BM + Desastres Naturales (Binaria) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	-216.471	-195.439
<i>Modelo 3</i>	OLS Lagged Log PIB (4) + Luces VIIRS BM + Desastres Naturales (Binaria) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	-215.985	-193.04
<i>Modelo 4</i>	OLS Lagged Log PIB (4) + Luces VIIRS BM + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	-215.848	-194.816
<i>Modelo 5</i>	OLS Lagged Log PIB (4) + Luces VIIRS BM + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Especiales) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	-215.633	-194.6

Nota: Criterios de información AIC y BIC para los cinco mejores modelos con covariables del logaritmo del PIB a precios corrientes bajo el esquema de desestacionalización completa.



Anexo V. *Ajuste de Mejores Modelos con Covariables del Logaritmo del PIB Corriente (desestacionalización completa).*



Nota: Visualización del ajuste de los cinco mejores modelos con covariables para el logaritmo del PIB a precios corrientes bajo el esquema de desestacionalización completa. La línea gris representa el valor observado y las líneas punteadas representan los valores predichos de cada modelo.



Anexo W. *T-Test Errores promedio incluyendo COVID del Logaritmo del PIB Corriente (desestacionalización completa).*

	Modelo	Train Error Promedi o	Train (P- valor)	Test Error Promedi o	Test (P- valor)
<i>Model o 1</i>	OLS Lagged Log PIB (4) + Luces VIIRS BM + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	0.0000	1.000 0	0.0141	0.314 2
<i>Model o 2</i>	OLS Lagged Log PIB (4) + Luces VIIRS BM + Desastres Naturales (Binaria) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	0.0000	1.000 0	0.0140	0.313 9
<i>Model o 3</i>	OLS Lagged Log PIB (4) + Luces VIIRS BM + Desastres Naturales (Binaria) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	0.0000	1.000 0	0.0153	0.280 2
<i>Model o 4</i>	OLS Lagged Log PIB (4) + Luces VIIRS BM + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	0.0000	1.000 0	0.0158	0.272 4
<i>Model o 5</i>	OLS Lagged Log PIB (4) + Luces VIIRS BM + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Especiales) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	0.0000	1.000 0	0.0152	0.280 1
<i>Model o Base</i>	OLS Lagged Log PIB (4)	0.0000	1.000 0	0.0011	0.948 2

Nota: Resultados de las pruebas T para evaluar la significancia estadística de los errores promedio en los períodos de entrenamiento y prueba (incluyendo COVID-19) para los cinco mejores modelos con covariables del logaritmo del PIB corriente.

Anexo X. *T-Test Errores promedio excluyendo COVID del Logaritmo del PIB Corriente (desestacionalización completa).*

	Modelo	Test Error Promedio	Test (P- valor)	Train Error Promedio	Train (P- valor)
<i>Modelo 1</i>	OLS Lagged Log PIB (4) + Luces VIIRS BM + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	0.0000	1.0000	0.0221	0.0153
<i>Modelo 2</i>	OLS Lagged Log PIB (4) + Luces VIIRS BM + Desastres Naturales (Binaria) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	0.0000	1.0000	0.0217	0.0184
<i>Modelo 3</i>	OLS Lagged Log PIB (4) + Luces VIIRS BM + Desastres Naturales (Binaria) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	0.0000	1.0000	0.0234	0.0138
<i>Modelo 4</i>	OLS Lagged Log PIB (4) + Luces VIIRS BM + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	0.0000	1.0000	0.0241	0.0115
<i>Modelo 5</i>	OLS Lagged Log PIB (4) + Luces VIIRS BM + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Especiales) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	0.0000	1.0000	0.0233	0.0106
<i>Modelo Base</i>	OLS Lagged Log PIB (4)	0.0000	1.0000	0.0101	0.2689

Nota: Resultados de las pruebas t para evaluar la significancia estadística de los errores promedio en los períodos de entrenamiento y prueba (excluyendo COVID-19) para los cinco mejores modelos con covariables del logaritmo del PIB corriente.

Anexo Y. Criterios de Ajuste de los Modelos con Covariables de Primera Diferencia del Logaritmo del PIB Corriente (desestacionalización completa).

	Modelo	AIC	BIC
Modelo 1	ARIMA (1,0,0) + Luces VIIRS BM + Pluviosidad + Desastres Naturales (Binaria) + Remesas (US\$) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	-226.655	-206.952
Modelo 2	ARIMA (1,0,0) + Luces VIIRS BM + Desastres Naturales (Binaria) + Remesas (US\$) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	-226.634	-208.902
Modelo 3	ARIMA (1,0,0) + Luces VIIRS BM + Desastres Naturales (Binaria) + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	-226.389	-206.686
Modelo 4	ARIMA (1,0,0) + Luces VIIRS BM + Pluviosidad + Desastres Naturales (Binaria) + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	-226.145	-204.472
Modelo 5	ARIMA (1,0,0) + Pluviosidad + Desastres Naturales (Binaria) + Remesas (US\$) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	-226.079	-208.347

Nota: Criterios de información AIC y BIC para los cinco mejores modelos con covariables de la primera diferencia del logaritmo del PIB a precios corrientes bajo el esquema de desestacionalización completa.

Anexo Z. Ajuste de Mejores Modelos con Covariables de Primera Diferencia del Logaritmo del PIB Corriente (desestacionalización completa).



Nota: Visualización del ajuste de los cinco mejores modelos con covariables para la primera diferencia del logaritmo del PIB a precios corrientes bajo el esquema de desestacionalización completa. La línea gris representa el valor observado y las líneas punteadas representan los valores predichos de cada modelo.

Anexo AA. *Precisión de Pronósticos de Modelos con Covariables en Conjunto de Prueba de Primera Diferencia del Logaritmo del PIB Corriente (desestacionalización completa).*

	Modelo	RMSE	RMSE (sin COVID)
<i>Modelo 1</i>	ARIMA (1,0,0) + Luces VIIRS BM + Pluviosidad + Desastres Naturales (Binaria) + Remesas (US\$) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	0.057766	0.048649
<i>Modelo 2</i>	ARIMA (1,0,0) + Luces VIIRS BM + Desastres Naturales (Binaria) + Remesas (US\$) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	0.058961	0.048699
<i>Modelo 3</i>	ARIMA (1,0,0) + Luces VIIRS BM + Desastres Naturales (Binaria) + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	0.057662	0.045564
<i>Modelo 4</i>	ARIMA (1,0,0) + Luces VIIRS BM + Pluviosidad + Desastres Naturales (Binaria) + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	0.055804	0.045004
<i>Modelo 5</i>	ARIMA (1,0,0) + Pluviosidad + Desastres Naturales (Binaria) + Remesas (US\$) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	0.057699	0.048803
<i>Modelo Base</i>	ARIMA (1,0,0) on Log Diff	0.069363	0.046484

Nota: Desempeño predictivo de los cinco mejores modelos con covariables en el conjunto de prueba para la primera diferencia del logaritmo del PIB a precios corrientes. Se reporta el RMSE para la muestra completa y excluyendo el período COVID-19, junto con el modelo base de referencia.

Anexo AB. *T-Test Errores promedio incluyendo COVID de Primera Diferencia del Logaritmo del PIB Corriente (desestacionalización completa).*

	Modelo	Train Error Promedio	Train (P- valor)	Test Error Promedio	Test (P- valor)
Modelo 1	ARIMA (1,0,0) + Luces VIIRS BM + Pluviosidad + Desastres Naturales (Binaria) + Remesas (US\$) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	0.0006	0.8806	0.0119	0.3029
Modelo 2	ARIMA (1,0,0) + Luces VIIRS BM + Desastres Naturales (Binaria) + Remesas (US\$) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	0.0006	0.8801	0.0119	0.3119
Modelo 3	ARIMA (1,0,0) + Luces VIIRS BM + Desastres Naturales (Binaria) + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	0.0006	0.8763	0.0120	0.2963
Modelo 4	ARIMA (1,0,0) + Luces VIIRS BM + Pluviosidad + Desastres Naturales (Binaria) + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	0.0006	0.8763	0.0120	0.2808
Modelo 5	ARIMA (1,0,0) + Pluviosidad + Desastres Naturales (Binaria) + Remesas (US\$) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	0.0006	0.8809	0.0120	0.2978
Modelo Base	ARIMA (1,0,0) on Log Diff	-0.0005	0.9048	0.0038	0.7882

Nota: Resultados de las pruebas T para evaluar la significancia estadística de los errores promedio en los períodos de entrenamiento y prueba (incluyendo COVID-19) para los cinco mejores modelos con covariables de la primera diferencia del logaritmo del PIB corriente.

Anexo AC. T-Test Errores promedio excluyendo COVID de Primera Diferencia del Logaritmo del PIB Corriente (desestacionalización completa).

	Modelo	Train Error Promedi o	Train (P- valor)	Test Error Promedi o	Test (P- valor)
Model o 1	ARIMA (1,0,0) + Luces VIIRS BM + Pluviosidad + Desastres Naturales (Binaria) + Remesas (US\$) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	0.0006	0.8806	0.0053	0.6291
Model o 2	ARIMA (1,0,0) + Luces VIIRS BM + Desastres Naturales (Binaria) + Remesas (US\$) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	0.0006	0.8801	0.0051	0.6446
Model o 3	ARIMA (1,0,0) + Luces VIIRS BM + Desastres Naturales (Binaria) + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	0.0006	0.8763	0.0052	0.6149
Model o 4	ARIMA (1,0,0) + Luces VIIRS BM + Pluviosidad + Desastres Naturales (Binaria) + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	0.0006	0.8763	0.0055	0.5881
Model o 5	ARIMA (1,0,0) + Pluviosidad + Desastres Naturales (Binaria) + Remesas (US\$) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	0.0006	0.8809	0.0055	0.6195
Model o Base	ARIMA (1,0,0) on Log Diff	-0.0005	0.9048	0.0025	0.8104

Nota: Resultados de las pruebas T para evaluar la significancia estadística de los errores promedio en los períodos de


entrenamiento y prueba (excluyendo COVID-19) para los cinco mejores modelos con covariables de la primera diferencia del logaritmo del PIB corriente.

Anexo AD. Criterios de Ajuste de los Modelos con Covariables de Tasa de Crecimiento Intertrimestral del PIB Corriente (desestacionalización completa).

	Model	AIC	BIC
<i>Modelo 1</i>	ARIMA (0,0,0) + Desastres Naturales (Binaria) + Importaciones (US\$ CIF) + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Total)	297.61	312.74
<i>Modelo 2</i>	ARIMA (0,0,0) + Desastres Naturales (Binaria) + Importaciones (US\$ CIF) + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio)	297.70	310.95
<i>Modelo 3</i>	ARIMA (0,0,0) + Desastres Naturales (Binaria) + Exportaciones (US\$ FOB) + Importaciones (US\$ CIF) + Remesas (US\$) + Consumo Eléctrico (Al público)	298.00	311.25
<i>Modelo 4</i>	ARIMA (0,0,0) + Desastres Naturales (Binaria) + Exportaciones (US\$ FOB) + Importaciones (US\$ CIF) + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio)	298.29	313.43
<i>Modelo 5</i>	ARIMA (0,0,0) + Desastres Naturales (Binaria) + Importaciones (US\$ CIF) + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	298.49	315.51

Nota: Criterios de información AIC y BIC para los cinco mejores modelos con covariables de la tasa de crecimiento intertrimestral del PIB a precios corrientes bajo el esquema de desestacionalización completa.

Anexo AE. Ajuste de Mejores Modelos con Covariables de Tasa de Crecimiento Intertrimestral del PIB Corriente (desestacionalización completa).



Nota: Visualización del ajuste de los cinco mejores modelos con covariables para la tasa de crecimiento intertrimestral del PIB a precios corrientes bajo el esquema de desestacionalización completa. La línea gris representa el valor observado y las líneas punteadas representan los valores predichos de cada modelo.

Anexo AF. Precisión de Pronósticos de Modelos con Covariables en Conjunto de Prueba de Tasa de Crecimiento Intertrimestral del PIB Corriente (desestacionalización completa).

	Modelo	RMSE	RMSE (sin COVID)
<i>Modelo 1</i>	ARIMA (0,0,0) + Desastres Naturales (Binaria) + Importaciones (US\$ CIF) + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Total)	5.1651	4.3849
<i>Modelo 2</i>	ARIMA (0,0,0) + Desastres Naturales (Binaria) + Importaciones (US\$ CIF) + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio)	4.5378	4.2714
<i>Modelo 3</i>	ARIMA (0,0,0) + Desastres Naturales (Binaria) + Exportaciones (US\$ FOB) + Importaciones (US\$ CIF) + Remesas (US\$) + Consumo Eléctrico (Al público)	19.0118	20.0485
<i>Modelo 4</i>	ARIMA (0,0,0) + Desastres Naturales (Binaria) + Exportaciones (US\$ FOB) + Importaciones (US\$ CIF) + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio)	28.8470	31.7305
<i>Modelo 5</i>	ARIMA (0,0,0) + Desastres Naturales (Binaria) + Importaciones (US\$ CIF) + Remesas (US\$) + Consumo Eléctrico	15.1843	4.6050



	(Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)		
<i>Modelo</i> <i>Base</i>	Auto ARIMA Log PIB ARIMA (0,0,0)	5.1651	5.6553

Nota: Desempeño predictivo de los cinco mejores modelos con covariables en el conjunto de prueba para la tasa de crecimiento intertrimestral del PIB a precios corrientes. Se reporta el RMSE para la muestra completa y excluyendo el período COVID-19, junto con el modelo base de referencia.

Anexo AG. *T-Test Errores promedio incluyendo COVID de Tasa de Crecimiento Intertrimestral del PIB Corriente (desestacionalización completa).*

	Modelo	Train Error Promedio	Train (P- valor)	Test Error Promedio	Test (P- valor)
<i>Modelo 1</i>	ARIMA (0,0,0) + Desastres Naturales (Binaria) + Importaciones (US\$ CIF) + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Total)	0.0000	1.0000	0.0087	0.9933
<i>Modelo 2</i>	ARIMA (0,0,0) + Desastres Naturales (Binaria) + Importaciones (US\$ CIF) + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio)	0.0000	1.0000	-0.2975	0.7453
<i>Modelo 3</i>	ARIMA (0,0,0) + Desastres Naturales (Binaria) + Exportaciones (US\$ FOB) + Importaciones (US\$ CIF) + Remesas (US\$) + Consumo Eléctrico (Al público)	0.0000	1.0000	0.8965	0.8153
<i>Modelo 4</i>	ARIMA (0,0,0) + Desastres Naturales (Binaria) + Exportaciones (US\$ FOB) + Importaciones (US\$ CIF) + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio)	0.0000	1.0000	1.7730	0.7607
<i>Modelo 5</i>	ARIMA (0,0,0) + Desastres Naturales (Binaria) + Importaciones (US\$ CIF) + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	0.0000	1.0000	1.5224	0.6188
<i>Modelo Base</i>	Auto ARIMA Log PIB ARIMA (0,0,0)	0.0000	1.0000	0.4148	0.7769

Nota: Resultados de las pruebas T para evaluar la significancia estadística de los errores promedio en los períodos de entrenamiento y prueba (incluyendo COVID-19) para los cinco mejores modelos con covariables de la tasa de crecimiento intertrimestral del PIB corriente.

Anexo AH. *T-Test Errores promedio excluyendo COVID de Tasa de Crecimiento Intertrimestral del PIB Corriente (desestacionalización completa).*

	Modelo	Train Error Promedio	Train (P- valor)	Test Error Promedio	Test (P- valor)
<i>Modelo 1</i>	ARIMA (0,0,0) + Desastres Naturales (Binaria) + Importaciones (US\$ CIF) + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Total)	0.0000	1.0000	-0.5683	0.5654
<i>Modelo 2</i>	ARIMA (0,0,0) + Desastres Naturales (Binaria) + Importaciones (US\$ CIF) + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio)	0.0000	1.0000	-0.4168	0.6657
<i>Modelo 3</i>	ARIMA (0,0,0) + Desastres Naturales (Binaria) + Exportaciones (US\$ FOB) + Importaciones (US\$ CIF) + Remesas (US\$) + Consumo Eléctrico (Al público)	0.0000	1.0000	1.3214	0.7707
<i>Modelo 4</i>	ARIMA (0,0,0) + Desastres Naturales (Binaria) + Exportaciones (US\$ FOB) + Importaciones (US\$ CIF) + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio)	0.0000	1.0000	2.9003	0.6858
<i>Modelo 5</i>	ARIMA (0,0,0) + Desastres Naturales (Binaria) + Importaciones (US\$ CIF) + Remesas (US\$) + Consumo Eléctrico (Al público) + Consumo Eléctrico (Comercio) + Consumo Eléctrico (Industria) + Consumo Eléctrico (Total)	0.0000	1.0000	0.8484	0.4118
<i>Modelo Base</i>	Auto ARIMA Log PIB ARIMA (0,0,0)	0.0000	1.0000	0.0682	0.9575

Nota: Resultados de las pruebas t para evaluar la significancia estadística de los errores promedio en los períodos de entrenamiento y prueba (excluyendo COVID-19) para los cinco mejores modelos con covariables de la tasa de crecimiento intertrimestral del PIB corriente.



Escuela de Gobierno y
Transformación Pública
Tecnológico de Monterrey

Anexo AI. Comparación de RMSE entre Modelos Base y Mejores Modelos con Covariables - Análisis de Robustez.

Transformación del PIB corriente	Modelo Base	RMSE Modelo Base	RMSE Modelo Base (sin COVID)	Mejor Modelo con Covariables	RMSE Mejor Modelo	RMSE Mejor Modelo (sin COVID)
<i>Primera Diferencia del Logaritmo</i>	ARIMA (1,0,0)	0.069363	0.046484	Modelo 4	0.055804	0.045004
<i>Tasa de Crecimiento Intertrimestral</i>	ARIMA (0,0,0)	5.1651	5.6553	Modelo 2	4.5378	4.2714

Nota: Comparación del desempeño predictivo entre modelos base univariados y los mejores modelos con covariables para dos transformaciones del PIB a precios corrientes. Se reporta el RMSE en el conjunto de prueba tanto para la muestra completa como excluyendo el período COVID-19.

Anexo AJ. Especificación del modelo de predicción del PIB sub nacional

Para el pronóstico de la serie de tiempo del PIB subnacional, se realizó un pronóstico bayesiano de datos panel a nivel departamento. La elección de este modelo y el nivel de agregación se debe a dos consideraciones:

1. Tanto las regresoras como la variable dependiente se correlacionan y explican unas a otras. Las luces se correlacionan con el PIB, pero también con el consumo eléctrico, y este último se correlaciona con la población, y la población con las luces. La naturaleza de los datos sugiere modelarlos como un sistema de ecuaciones de series de tiempo, con un modelo VAR (Vector Autoregresivo). En principio se podrían hacer 14 modelos VAR para los 14 departamentos. Sin embargo, dado que contamos con pocos datos, no podríamos inferir los parámetros de un modelo VAR. Si agregamos las luces al modelo, las series sólo consideraría 10 años, abarcando el periodo 2012-2022. Pero como contamos los datos longitudinales, podemos estimar un Panel VAR, con el cual no sólo se modelarían las relaciones entre las series individuales de los departamentos, sino también las relaciones de las series entre departamentos. De alguna forma estaríamos capturando también las relaciones espaciales de los departamentos salvadoreños. Con la estimación bayesiana, se libra el problema del tamaño de muestra pequeño de las observaciones de series de tiempo y se aprovecha la información espacial de sección cruzada.
2. La decisión del nivel de agregación se debe, por un lado, para eliminar ruido y comportamientos atípicos de municipios heterogéneos y por la inestabilidad numérica que generan los modelos panel con más observaciones de sección cruzada que de series de tiempo.

Además, los modelos Bayesianos VAR de Panel presentan las siguientes características (citar bvarPANELs):

- Funcionan con variables no estacionarias.
- Enfoque de modelación de sistemas.
- Enfoque dinámico.
- Formulación de lo global a lo local.



- Pronóstico con variables condicionales.
- La estimación puede incorporar variables exógenas.

El vector autorregresivo a nivel departamento estaría especificado de la siguiente manera:

$$y_{d,t} = [\text{gdp}_{d,t} \quad \text{pop}_{d,t} \quad \text{consumo electrico}_{d,t} \quad \text{viirs}_{d,t}]'$$

$$y_{d,t} = A_{d,1}y_{d,t-1} + A_{d,c}x_{d,t} + \epsilon_{d,t}$$

$$\epsilon_{d,t} \vee y_{d,t-1} \sim N_4(0_4, \Sigma_d)$$

donde d corresponde al subíndice de departamento y t al subíndice de tiempo.

El modelo global para la media a priori es:

$$E_{\pi}[A_c] = A, A_c = [A_{c,1} \quad A_{d,c}]'$$

$$E_{\pi}[\Sigma_c] = \Sigma$$

$$\begin{array}{l} y_{c,t} \quad \quad \quad A_1 y_{c,t-1} + A_d x_{c,t} + \epsilon_{c,t} \\ \epsilon_{c,t} \vee y_{c,t-1} \quad \quad \quad \sim N_4(0_4, \Sigma) \end{array}$$

El modelo funciona con una estructura jerárquica a tres niveles:

- Estimación de parámetros específicos a nivel departamento A_d y Σ_d
- Estimación de parámetros globales A y Σ
- Estimar otros priors y niveles de shrinkage.

Anexo AK. Resultados de la estimación del PIB sub nacional trimestral en PPP para cada departamento de El Salvador, 2023 – 2025.

