

Nowcasting del Producto Interno Bruto Trimestral de Honduras

Celin Eliud Hernández Avila
Agosto 2021

NOTA ACLARATORIA

La información utilizada para la elaboración de este documento es la disponible a mayo de 2021, siendo algunas cifras de carácter preliminar.

El Banco Central de Honduras autoriza la reproducción total o parcial del texto, gráficas y cifras de esta publicación, siempre que se mencione la fuente. No obstante, esta Institución no asume responsabilidad legal alguna o de cualquier otra índole, por la manipulación, interpretación personal y uso de la información.

Lo expresado en este documento es responsabilidad exclusiva de los autores y no necesariamente representa la opinión del Banco Central de Honduras o de sus Autoridades.

Derechos Reservados © 2021

Contenido

1. Introducción.....	- 4 -
2. Metodología	- 5 -
2.1. Mixed Data Sampling Models (MIDAS):	- 5 -
2.2. Métodos de Ponderación de los Parámetros:	- 6 -
3. Datos	- 8 -
3.1. Análisis de Componentes Principales (ACP)	- 10 -
3.2. Disponibilidad de Información en el Trimestre de Estimación	- 10 -
4. Resultados.....	- 11 -
4.1. Escenario 1	- 11 -
4.2. Escenario 2	- 14 -
4.3. Escenario 3	- 16 -
5. Evaluación de Pronósticos.....	- 18 -
5.1. Medidas de Precisión de Pronóstico por el MSE	- 18 -
5.2. Test de Diebold y Mariano	- 18 -
5.3. Evaluación de Resultados según disponibilidad de datos.....	- 19 -
6. Combinación de Pronósticos.....	- 20 -
7. Conclusiones	- 22 -
8. Anexos.....	- 22 -
9. Bibliografía.....	- 37 -

1. Introducción

El Producto Interno Bruto (PIB) es una de las variables principales para la toma de decisiones de los agentes económicos, así como para el análisis y diseño de la política monetaria de un banco central; no obstante, en la mayor parte de los países avanzados y emergentes, los datos oficiales del PIB trimestral (PIBT) son publicados con cierto rezago de tiempo.

Dado lo anterior, surge la necesidad de desarrollar herramientas que permitan estimar el PIB del trimestre actual utilizando variables de mayor frecuencia y disponibilidad, con el fin de contar con un indicador que muestre el comportamiento reciente y anticipado de la actividad económica del país, previo a la publicación de las cifras oficiales. Sin embargo, los modelos econométricos “tradicionales” desarrollados por los bancos centrales para sus pronósticos y análisis de política establecen relaciones entre una variable dependiente Y_t , con otras variables independientes X_t , donde todas las variables están expresadas en la misma frecuencia y están disponibles con cierto rezago de tiempo.

Considerando lo anterior, la necesidad de datos tempranos se ha concretado en el Nowcasting, concepto que une los términos now (ahora) y forecasting (pronóstico), metodología que desde hace unos años ha sido implementada por diversos bancos centrales y otras instituciones de análisis económico para contar con herramientas cuantitativas para realizar pronósticos de corto plazo que brinden señales adelantadas de la evolución de la economía. Estas técnicas se caracterizan por maximizar la información económica contenida en variables publicadas con alta frecuencia (diaria, semanal o mensual) para generar estimaciones adelantadas de una variable disponible en una menor frecuencia (trimestral o anual). Es así que en la literatura destacan los modelos de frecuencia mixta, que incluyen los Bridge Equations, Mixed Data Sampling (MIDAS), Vectores Autoregresivos de frecuencia mixta, modelos de factores, entre otros, los cuales se han comprobado ser eficientes para predecir el comportamiento de la economía en el corto plazo.

Para el caso de Honduras, el Calendario de Publicaciones de Información Económica y Financiera del BCH establece que el PIBT se publicará 90 días después de finalizado el trimestre de referencia, lo cual implica que existe cierto rezago en la disponibilidad de información esencial para la toma de decisiones de política monetaria, crediticia o cambiaria del BCH.

En este sentido, el propósito de este trabajo es desarrollar modelos MIDAS para realizar el Nowcasting del PIB Trimestral de Honduras, a fin de contar con una señal adelantada de la evolución económica del país que pueda ser utilizado de manera oportuna para el análisis y toma de decisiones de política monetaria del BCH. Estos modelos, desarrollados en Ghysels et al. (2002), representan una forma simple, parsimoniosa y flexible de abordar el tema de combinar datos con periodicidad distinta, sin la necesidad de agregar datos mensuales, por ejemplo, vía promedios o sumatorias, para estimar series trimestrales.

El presente documento está organizado de la siguiente manera: en la sección II del documento se presenta la metodología MIDAS y los métodos de ponderación de los parámetros de cada una de las especificaciones y modelos estimados; la sección III presenta el conjunto de datos y variables utilizadas, así como el Análisis de Componentes de Principales (ACP) y la disponibilidad de dicha información a lo largo del trimestre; en la sección IV se muestran los resultados del ACP y los pronósticos de los MIDAS; en la sección V se expone la evaluación de los pronósticos y en la sección VI la combinación de pronósticos; en la sección VII, el ajuste estacional de las series temporales y finalmente en la sección VIII las conclusiones.

2. Metodología

2.1. Mixed Data Sampling Models (MIDAS):

El enfoque MIDAS consiste en formular modelos que relacionan una serie de menor frecuencia en función de los rezagos de series de alta frecuencia. La relación funcional se expresa como:

$$Y_t^q = f(X_{1,t}^m, X_{2,t}^m, X_{3,t}^m, \dots, X_{n,t}^m); \text{ para cada } X_{i,t}^m = X_{i,t}^m + X_{i,t-1}^m + \dots + X_{i,t-k}^m \quad (1)$$

La variable endógena Y_t^q , que se observa en una frecuencia baja (por ejemplo, cada trimestre), está explicada por n número de indicadores exógenos X_t^m que se observan en una frecuencia más alta (por ejemplo, mensualmente), los cuales a su vez tienen k rezagos.

Un MIDAS no restringido (U-MIDAS, por sus siglas en inglés) se puede expresar de la siguiente manera:

$$Y_t^q = \sum_{i=1}^n \sum_{t=0}^k \beta_j^i X_{i,t-k}^m + \varepsilon_t \quad (2)$$

Donde la variable Y_t^q trimestral en el período t será explicada por un conjunto de variables X_i^m mensuales desde 1 a n , con rezagos distributivos del período $t = 0$ hasta k . En este tipo de modelo para cada observación de la variable dependiente, existen m parámetros de la variable explicativa. Por ejemplo, para predecir una variable trimestral Y_t^q con datos mensuales de una variable X_t^m se estiman al menos tres (3) parámetros, que a su vez dependerá del número de rezagos distributivos; por lo cual, en una ecuación con dos (2) retardos, existirían al menos seis (6) coeficientes de regresión para estimar.

Dado lo anterior, la cantidad de parámetros en estos modelos puede llegar a ser alta, conforme al tamaño de la muestra, número de variables incluidas y los rezagos; para abordar esta situación, Ghysels et al. (2002) introdujeron una restricción paramétrica para reducir la cantidad de β_j^i a estimar (parsimonia) y así evitar problemas de sobre-parametrización.

Para poder proyectar una serie a partir de otra de diferente periodicidad, los modelos MIDAS restringidos requieren de un método de agregación que integre los coeficientes β_j^i conforme al número de retardos, para ello se utilizan "ponderadores" que determinan la forma como se incluyen los m parámetros dentro de la baja frecuencia.

Si Y_t^q esta explicador por X_t^m , existe un factor de ponderación θ^ρ , tal que:

$$Y_t^q = \sum_{i=0}^n \sum_{t=0}^k \theta^\rho \beta_j^i X_{i,t-k}^m \quad (3)$$

De manera que:

$$Y_t^q = \theta^1 \beta_1 X_t^m + \theta^2 \beta_2 X_{t-1}^m + \theta^3 \beta_3 X_{t-2}^m \quad (4)$$

El coeficiente θ^ρ debería ser menor a 1 y decreciente a medida que se aleje del período t , de manera que al multiplicar por los β_j^i se otorga un mayor peso a las observaciones más recientes.

Finalmente, considerando que los MIDAS generalmente incluyen un componente autorregresivo (Y_{t-i}^q), se pueden representar matemáticamente de la siguiente manera:

$$Y_t^q = \alpha + \sum_{i=1}^p \gamma_i Y_{t-i}^q + \sum_{t=0}^k \theta^\rho \beta_j^i X_{i,t-k}^m + \varepsilon_t \quad (5)$$

Donde:

- γ_i es el coeficiente del componente autorregresivo de y_t^q
- ρ son sus rezagos
- ε_t es el error estocástico y α es la constante del modelo

2.2. Métodos de Ponderación de los Parámetros:

Como se mencionó anteriormente, los modelos MIDAS pueden incorporar restricciones sobre la selección de las variables de alta frecuencia y sus rezagos, a fin de reducir y optimizar el número de parámetros a estimar (Ghysels et al, 2016).

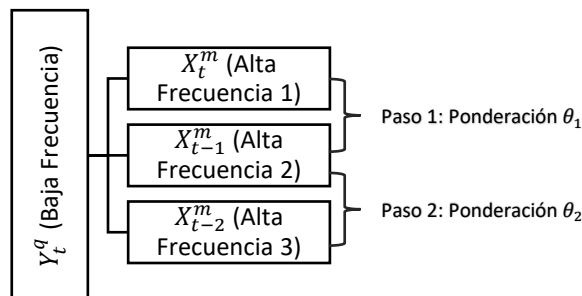
En la literatura empírica se encuentran diferentes formas funcionales para la estimación de los coeficientes $\theta^\rho \beta_j^i$ en los modelos MIDAS; a continuación se detallan los que serán de uso para efectos del Nowcasting del PIBT de Honduras:

2.2.1.1. Polinomios de rezagos de Almon exponencial normalizado: para estimar los θ^ρ , Ghysels et al. (2005) definieron la forma funcional con dos parámetros equivalente a $\theta = (\theta_1, \theta_2)$; en un contexto de k rezagos, los ponderadores (w_i) se estiman según:

$$w_i(\theta_1, \theta_2) = \frac{e^{\theta_{1i} + \theta_{2i}^2}}{\sum_{t=1}^k e^{\theta_{1i} + \theta_{2i}^2}} \quad (6)$$

Estos coeficientes pueden ser estimados conjuntamente con los β_j^i , a partir de los datos de alta frecuencia; los mismos tienden a declinar a medida que los rezagos se alejan del período t y la selección de la longitud de estos rezagos vendrá determinada por la relación estadística entre las variables.

2.2.1.2. Ponderaciones tipo Step functions (Función de Escalón de Heaviside o de Escalon Unitario): Las Step functions son funciones discontinuas definidas en un intervalo finito $[a, b]$, las cuales fueron introducidas por Forsberg y Ghysels (2004) en los modelos MIDAS para estimar ponderaciones en un espacio temporal comprendido por datos de alta frecuencia dentro de los de baja frecuencia.



Para el cálculo de las ponderaciones (θ^p) se utiliza la Función de Heaviside ($H_{(t)}$), la cual está definida por:

$$H_{(t)} = \begin{cases} 0, & \text{si } t < 0 \\ 1, & \text{si } t \geq 0 \end{cases} \quad (7)$$

$H_{(t)} = 0$, si t es un valor negativo (< 0) y $H_{(t)} = 1$, si t tiene valores positivos (≥ 0) y se representa por medio de una transformada de Laplace del tipo:

$$\mathcal{L}[H_{(t)}] = \int_0^{\infty} H_{(t)} e^{-st} dt \quad (8)$$

Cuya solución se obtiene mediante la integral entre los intervalos definidos. En el contexto de los MIDAS -en términos discretos- los ponderadores (θ^p), resultan de calcular las sumatorias parciales entre el Mes_t al Mes_{t-1} (paso1) y el Mes_{t-1} al Mes_{t-2} (paso2); por lo tanto, la cantidad de parámetros dependerá del número de sumas parciales (áreas entre curvas en términos continuos) o pasos determinados; en vista que este trabajo utiliza series mensuales para predecir el PIBT, se cuentan con dos parámetros y k rezagos.

2.2.1.3. MIDAS-GETS: En lugar de utilizar un esquema de ponderación, MIDAS-GETS controla la selección de variables y retardos con el algoritmo Auto-Search/GETS, el cual realiza la estimación con todas las variables incluidas y después verifica a partir de un conjunto de pruebas de diagnóstico para descartar o validar. Los test realizados son los siguientes:

- AR LM test Q-statistic: evalúa la significancia de los residuos para la determinación del número de rezagos.
- ARCH LM test Q-statistic: pruebas sobre los residuos al cuadrado para la selección del número de rezagos.
- Estadístico Jarque-Bera para las pruebas de normalidad.
- Parsimonious Encompassing test (PET), para evaluar los distintos modelos

Es importante mencionar que los modelos MIDAS-GETS incluyen un método para la detección automática de outliers y cambios estructurales mediante la incorporación de un “Indicador de Saturación”. En este trabajo se utilizó la opción Impulse-Indicator Saturation (IIS), cuya característica es similar a los outliers de tipo aditivo (AO) que afectan un punto de la serie donde se detectó la atipicidad.

Los parámetros β_j^i , en las distintas especificaciones, pueden ser estimados mediante Mínimos Cuadrados Ordinarios (MCO) para un modelo sin restricciones, tipo U-MIDAS; en tanto, al restringir la obtención de los parámetros, nos podemos encontrar en condiciones de no-linealidad, que requieran la utilización de Mínimos Cuadrados No lineales o Métodos Bayesianos.

3. Datos

Para el presente trabajo se construyó una base de datos de variables domésticas del Sector Real, Monetario, Fiscal y Externo; así como de variables externas, correspondientes a la economía de Estados Unidos de América (EUA), cuya evolución guarda una importante correlación con la economía hondureña. Por último, se introdujo la variable mensual correspondiente al número de casos de personas infectadas por Covid-19 que permitirá modelar el efecto de la pandemia sobre el comportamiento de las variables económicas registrado durante 2020.

Tomando los criterios enunciados por autores como Hair et al (1999) para el proceso de decisión de un análisis factorial, Gálvez-Soriano (2018) referente a la colinealidad de las variables seleccionadas y Hansen y Sargent (1993); entre otros, se identificó que los datos seleccionados deben cumplir con lo siguiente:

1. Series de tiempo históricas que permitan la inclusión de diferentes longitudes de retardos, sin la pérdida excesiva de grados de libertad ($n - k$).
2. El set de variables seleccionadas debe ser capaz de explicar la evolución del PIBT, bajos dos (2) perspectivas: (i) la económica: tener una relación lógica con el desempeño de la actividad económica; por ejemplo, se incluyeron indicadores como el consumo de energía y de combustibles, que, por su naturaleza, reflejan las fluctuaciones en la producción de bienes y servicios; (ii) la estadística: se evaluó la correlación entre las series propuestas con el PIBT, a partir de las variaciones interanuales de las series originales, y se aceptó un coeficiente de correlación de Pearson mayor al 30%¹ según lo establecido en Gálvez-Soriano (2018).
3. Del punto anterior, existe un largo y aún inconcluso debate sobre la conveniencia de modelar la economía usando variables originales o desestacionalizadas. Hansen y Sargent (1993) defienden la idea de que los agentes racionales toman decisiones en base a datos sin desestacionalizar y que remover la estacionalidad implica, en el muchos de los casos, eliminar información que podría ser útil para estimar los parámetros de un modelo.
4. Los datos utilizados deben de estar disponibles en tiempo y forma, con la robustez, calidad y confiabilidad suficiente.

La muestra de datos utilizada para el Nowcasting de Honduras comprende series desde el año 2000 a 2021, equivalente a 85 observaciones trimestrales y 257 mensuales. A continuación, se presentan las series utilizadas en los modelos de Nowcasting para pronósticos del PIBT:

¹ Ver Anexo 8.1.1, Tabla 11.

Tabla 1: Variables Utilizadas en el Nowcasting del PIBT

No.	Indicador	Unidad de Medida	Frecuencia	Publicación	Fuente	Web
1	Producto Interno Bruto Trimestral	Millones de L. Constantes, Serie Original	Trimestral	t+90 días	Departamento de Estadísticas Macroeconómicas, BCH.	https://www.bch.hn/estadisticas-y-publicaciones-economicas/sector-real/producto-interno-bruto-trimestral
2	Índice Mensual de Actividad Económica (IMAE)	Índice 2000=100, Serie Original	Mensual	t+40 días	Departamento de Estadísticas Macroeconómicas, BCH.	https://www.bch.hn/estadisticas-y-publicaciones-economicas/sector-real/indice-mensual-de-actividad-economica
3	Índice de Precios al Consumidor (IPC)	Índice 2000=100, Serie Original	Mensual	t+10 días	Departamento de Gestión de la Información Económica, BCH.	https://www.bch.hn/estadisticas-y-publicaciones-economicas/publicaciones-de-precios/indice-de-precios-al-consumidor
4	Remesas ^{1/}	Millones de L. Constantes	Mensual	t+20 días	Departamento de Estadísticas Macroeconómicas/Internacional, BCH.	https://www.bch.hn/politica-institucional/politica-cambiaría/estadística-cambiaría/balanza-cambiaría
5	Tipo de Cambio Nominal	Promedio Mensual de los TC diarios	Mensual	t+1 días	Departamento de Gestión de la Información Económica, BCH.	https://www.bch.hn/estadisticas-y-publicaciones-economicas/tipo-de-cambio-nominal
6	Flujos de Préstamos Nuevos ^{2/}	Millones de L. Constantes	Mensual	t+50 días	Departamento de Estabilidad Financiera, BCH.	https://www.bch.hn/estadisticas-y-publicaciones-economicas/boletin-estadistico-memoria-anual-y-otras-publicaciones/boletin-estadistico
7	Índice de Precios Importaciones de Combustible ^{3/}	Índice, referencia 2000=100	Mensual	t+35 días	Departamento de Estadísticas Macroeconómicas, BCH.	https://www.bch.hn/estadisticas-y-publicaciones-economicas/sector-externo/informes-y-publicaciones/informe-de-comercio-exterior-de-mercancias-generales
8	Consumo de Combustibles (Barriles) ^{4/}	Índice, referencia 2000=100	Mensual	t+40 días	Secretaría de Energía, Dirección General de Hidrocarburos y Biocombustibles	https://sen.hn/tag/hidrocarburos/
9	Índice de Producción Industrial (IPI), EUA	Índice 2017=100, Serie Original	Mensual	t+20 días	Reserva Federal de los Estados Unidos de América (FED)	https://www.federalreserve.gov/releases/G17/Current/
10	Índice de Precios al Consumidor (IPC), EUA	Índice 1982-84=100, Serie Original	Mensual	t+15 días	Bureau Laboral Statistic (BLS)	https://www.bls.gov/news.release/cpi.toc.htm
11	Agregado Monetario (M1) ^{5/}	SalDOS en Millones de L. Constantes	Mensual	t+50 días	Departamento de Estabilidad Financiera, BCH.	https://www.bch.hn/estadisticas-y-publicaciones-economicas/sector-monetario/agregados-monetarios-credito-y-captacion
12	Depósitos de Ahorro y Plazo en Moneda Nacional	SalDOS en Millones de L. Constantes	Mensual	t+50 días	Departamento de Estabilidad Financiera, BCH.	https://www.bch.hn/estadisticas-y-publicaciones-economicas/sector-monetario/estadisticas-monetarias-y-financieras-armonizadas-(emfa)
13	Índice de Precios de Exportaciones ^{6/}	Índice, referencia 2000=100	Mensual	t+30 días	Bureau Laboral Statistic (BLS) y Banco Mundial	https://www.worldbank.org/en/research/commodity-markets https://www.bls.gov/news.release/ximpim.t05.htm
14	Exportaciones ^{7/}	Millones de L. Constantes	Mensual	t+40 días	Departamento de Estadísticas Macroeconómicas, BCH.	https://www.bch.hn/estadisticas-y-publicaciones-economicas/sector-externo/informes-y-publicaciones/informe-de-comercio-exterior-de-mercancias-generales
15	Índice de Precios de Importaciones	Índice, referencia 2000=100	Mensual	t+35 días	Bureau Laboral Statistic (BLS) y Departamento de Estadísticas Macroeconómicas, BCH.	https://www.bch.hn/estadisticas-y-publicaciones-economicas/sector-externo/informes-y-publicaciones/informe-de-comercio-exterior-de-mercancias-generales
16	Importaciones ^{8/}	Millones de L. Constantes	Mensual	t+40 días	Departamento de Estadísticas Macroeconómicas, BCH.	https://www.bch.hn/estadisticas-y-publicaciones-economicas/sector-externo/informes-y-publicaciones/informe-de-comercio-exterior-de-mercancias-generales
17	Consumo de Energía	En Millones de Kilowatts/Hora	Mensual	t+20 días	Empresa Nacional de Energía Eléctrica (ENEE)	https://portalunico.iaip.gob.hn/portal/ver_documento.php?uid=MTA00DUSNTp5MzQ3NjM0ODcxMjQ2MTk4NzIzNDI=
18	Volumen de Producción de Cemento	En Bolsas de 42.5 Kilogramos	Mensual	t+30 días	Departamento de Estadísticas Macroeconómicas, BCH.	https://www.bch.hn/estadisticas-y-publicaciones-economicas/boletin-estadistico-memoria-anual-y-otras-publicaciones/boletin-estadistico
19	Impuestos Indirectos ^{9/}	Millones de L. Constantes	Mensual	t+30 días	Departamento de Estadísticas Macroeconómicas, BCH/Secretaría de Finanzas	https://www.sefin.gob.hn/cuentas-financieras/
20	Tasa de Interés Activa sobre Operaciones Nuevas ^{10/}	En porcentaje	Mensual	t+20 días	Departamento de Análisis Macroeconómico, BCH.	https://www.bch.hn/estadisticas-y-publicaciones-economicas/sector-monetario/tasas-de-interes/tasas-de-interes-sobre-operaciones-nuevas
21	Remuneraciones pagadas en el Sector Público ^{11/}	Millones de L. Constantes	Mensual	t+20 días	Departamento de Estadísticas Macroeconómicas, BCH/Secretaría de Finanzas	https://www.sefin.gob.hn/ejecucion-y-seguimiento/
22	Tasa Turística ^{12/}	Lempiras Constantes	Mensual	t+15 días	Sistema de Administración de Rentas (SAR)	https://portalunico.iaip.gob.hn/portal/index.php?portal=445
23	Permisos de Construcción ^{13/}	Metros ² Construidos	Mensual	t+30 días	Departamento de Estadísticas Macroeconómicas, BCH.	https://www.bch.hn/estadisticas-y-publicaciones-economicas/boletin-estadistico-memoria-anual-y-otras-publicaciones/boletin-estadistico
24	Índice del Tipo de Cambio Real	Índice, dic2017=100	Mensual	t+20 días	Departamento de Gestión de la Información Económica, BCH.	https://www.bch.hn/estadisticas-y-publicaciones-economicas/tipo-de-cambio-efectivo-real
25	Casos Covid-19	Numero de Personas InfeCTadas	Mensual	t+1 días	Organización Mundial de la Salud (OMS)	https://covid19.who.int/region/amro/country/hn

^{1/} Las remesas en US\$ se convirtieron a lempiras con el tipo de cambio promedio mensual y se deflataron entre el IPC

^{2/} Se obtuvo la diferencia mensual de los flujos acumulados ($F_t - F_{t-1}$) y el valor obtenido se deflactó entre el IPC

^{3/} Índice Promedio Ponderado de los Precios en Lempiras de las Importaciones de Gasolina, Diésel, Kerosene, Bunker y Gas LPG.

^{4/} Índice de volumen del consumo local de Gasolinas, Diésel, Kerosene, Bunker y Gas LPG.

^{5/} Los SalDOS en Millones de lempiras se deflataron entre el IPC

^{6/} Índice de Precios Ponderado, Referencia 2000=100, de los principales productos de exportación de Mercancías Generales (MG) y Bienes para Transformación (BT).

^{7/} Incluye MG y BT (Productos Textiles y Arneses y Cables Eléctricos), valoradas al TC promedio mensual y deflactadas por el Índice de Precios de Exportaciones (ver ítem anterior)

^{8/} Incluye MG valoradas al TC promedio mensual y deflactadas por el Índice de Precios de Importaciones.

^{9/} Incluye la recaudación tributaria de Impuestos a la Producción y Ventas (IVA), sobre Servicios Actividades Específicas, Aporte Vial y al Comercio Exterior, deflactados entre el IPC

^{10/} Tasas Anuales de Interés Activa Promedio Ponderado por Actividad Económica sobre Préstamos Nuevos en Moneda Nacional

^{11/} Incluye Remuneraciones pagadas en el Gobierno Central, Empresas y Sociedades Financieras Públicas, deflactadas entre el IPC

^{12/} Valor recaudado sobre los Servicios Turísticos (4% sobre el precio del alojamiento diario, arrendamiento de vehículo con fines turísticos e ingresos de agencias operadoras de turismo)

^{13/} Metros cuadrados diferidos de los permisos de construcción otorgados en las principales municipalidades del país.

3.1. Análisis de Componentes Principales (ACP)

Conforme a lo anterior, se dispone de 20 variables de frecuencia mensual para predecir la tasa de crecimiento interanual del PIBT real, las cuales se están introduciendo en las estimaciones en términos de sus diferencias interanuales, lo cual es importante ya que se cuenta con un conjunto de información para modelar las fluctuaciones presentadas en el corto plazo; sin embargo, existen algunas limitaciones de orden práctico al tener una relación entre:

$$Y_t^q = f(X_{1,t}^m, X_{2,t}^m, X_{3,t}^m, \dots, X_{20,t}^m) \quad (9)$$


Al contar con 20 variables, para los cuales se estarían estimando al menos tres (3) parámetros para el período t , sumado a los posibles rezagos distributivos seleccionados, es muy probable que la estimación no cumpla con el principio de parsimonia y presente problemas de sobreajuste y sobre-parametrización. Como medida alternativa, muchas de las estimaciones utilizan técnicas multivariadas para reducir la dimensionalidad de los datos, tal es el caso de Cobb et al (2020) del Banco de Chile, D'Amato et al (2015) del Banco Central de Argentina y Galvez-Soriano (2018) del Banco de México, autores que emplean Modelos de Factores Dinámicos y Análisis de Componentes Principales (ACP) para el Nowcasting del PIBT.

En la estimación de Nowcasting para el PIBT de Honduras, se empleó el ACP (ver Anexo 8.1.2), el cual proporciona la base estadística para crear una nueva serie de variables a incluir en los MIDAS, que refleje la naturaleza de los indicadores originales en una cantidad más pequeña. En el ACP, dadas n observaciones y p indicadores, se busca maximizar la variabilidad conjunta de los datos (Hair et al, 1999) representados por un número menor de variables. El uso del ACP como técnica multivariante de resumen de datos, no excluye la necesidad de contar con una base conceptual para el análisis a desarrollar.

3.2. Disponibilidad de Información en el Trimestre de Estimación

Un factor que enfrenta el Nowcasting para generar resultados tempranos es la disponibilidad de datos en tiempo real. Dadas las fechas de publicación de las variables consideradas para los modelos del PIBT de Honduras, podemos identificar que entre el inicio y cierre del período (trimestre) que deseamos estimar, el Nowcast generado a esa fecha contaría con alrededor del 55% de la información y que 50 días posterior al cierre del trimestre se dispondría del 100% de los datos. De manera que, se puede contar una estimación adelantada del PIBT con 40 días de antelación a la publicación oficial de las Cuentas Nacionales Trimestrales (CNT).

Gráfica 1: Disponibilidad de Información para el Nowcasting en el Trimestre



Fuente: Elaboración Propia

Cabe mencionar que, el Nowcast estimado para un trimestre determinado evolucionará en la medida se pueda actualizar con base a la publicación mensual de las variables consideradas; con lo cual se espera que al incorporar el 100% de la información, el pronóstico se acerque al valor observado del PIBT.

4. Resultados

Las estimaciones de Nowcasting para Honduras se realizaron utilizando modelos MIDAS según los métodos de ponderación descritos previamente y se elaboraron tres (3) escenarios de pronóstico:

4.1. Escenario 1:

Se utilizó la metodología de ACP para resumir las 20 series utilizadas en un solo agregado, el cual llamaremos Índice Sintético de Variables Económicas (ISVE). Para su cálculo se procedió de la siguiente manera:

4.1.1. En vista que los indicadores tienen diferentes unidades de medida (lempiras, volúmenes, índices, kilowatts, etc.), a fin de que el ACP capté de forma apropiada su variabilidad individual y conjunta, se estandarizaron cada una de las observaciones restando la media y dividiendo entre su desviación estándar.

$$z = \frac{X_i - \bar{X}_i}{\sigma} \quad (10)$$

La estandarización representa simplemente un cambio de escala en los datos, manteniendo su misma evolución, pero logrando que las magnitudes de los valores numéricos sean muy similares; no obstante, esto asegura que la serie tenga *media* = 0 y *varianza* = 1. Al obtener estas propiedades, las covarianzas se transforman en coeficientes de correlación y por ende podemos realizar el ACP, al calcular los valores y vectores propios de la matriz de correlación de $X_{1,t}^m, X_{2,t}^m, X_{3,t}^m, \dots, X_{20,t}^m$.

4.1.2. Validación de aplicación del ACP: En el ACP es deseable que exista cierto grado de colinealidad entre las series. Al examinar la matriz de correlaciones (ver Anexo 8.1.3, gráfica 7), se puede observar que en general los coeficientes son altos, indicando una asociación lineal aceptable y deseada entre variables; sin embargo, el ACP requiere de pruebas empíricas para validar su aplicación, para lo cual se calculó el Test de Kaiser's Measure of Sampling Adequacy (KMO), cuyos resultados afirman la viabilidad estadística del ACP (Ver Anexo 8.1.4, tabla 12).

Considerando los indicadores seleccionados para predecir la evolución del PIBT, se calcularon las raíces del polinomio característico de la matriz de correlaciones (valores propios), que corresponden a los componentes principales (CP). Para las 20 variables, se obtuvieron igual número de CP.

Para determinar el número de CP a extraer se utiliza el Criterio de Raíz Latente (Hair et al, 1999), que establece que raíces menores a 1 no son significativas y por tanto se desestima su incorporación al análisis realizado. El Scree Plot presentado en la gráfica 9 y tabla 13 (Anexo 8.1.5), indica que a partir del CP_4 los valores propios son inferiores a 1, de manera que solo se seleccionan los primeros tres CP. Los resultados muestran que el CP_1 acumula un 73.87% de la varianza global, el CP_2 el 81.45% y el CP_3 alcanza alrededor de 86.41% de la variabilidad completa de los datos.

Una vez determinado el número óptimo de eigenvalues, se obtienen los vectores propios, que representan el peso (ponderación) de cada variable en los CP. En términos matemáticos, es posible obtener tanto vectores propios como indicadores se utilicen en el ACP, en este trabajo se obtuvieron 20 eigenvectores por cada CP.

En el CP_1 , la variable de mayor peso es el IMAE, principal indicador de coyuntura para predecir el PIBT y recoge la mayor ponderación del conjunto de series agrupadas en este componente. Adicionalmente, destaca que en el CP_1 todos los eigenvectores son positivos, a excepción de la Tasa de Interés sobre Operaciones Nuevas (TAON), que es congruente con la teoría económica, ya que se espera una relación negativa entre las tasas de interés y el PIBT. El CP_2 muestra que los metros cuadrados derivados de los permisos de construcción es la variable de mayor peso en el mismo; en tanto, en el CP_3 , la principal contribución positiva viene dada por la variabilidad del IPI de EUA y los impuestos indirectos (ver Anexo 8.1.5, gráfico 11).

Es importante mencionar que el ACP es una técnica multivariada fundamentada principalmente en la trayectoria estocástica de un grupo de datos y de esta dinámica se extraen co-movimientos o factores latentes, por lo cual pueden presentarse resultados cuya explicación económica no será tan evidente de precisar.

La obtención de la serie de tiempo de los CP_t se calcula de la siguiente manera:

Componente Principal 1_(t)

$$X_{1,t}^{*m} = CP_{1,t}^m = X_{1,t}^m * CP_{1,1} + X_{2,t}^m * CP_{1,2} + X_{3,t}^m * CP_{1,3} + \dots + X_{20,t}^m * CP_{1,20} \quad (11)$$

$$CP_{1,t}^m = \sum_{i=1}^{20} (X_{i,t}^m * CP_{1,i}) \quad (12)$$

Componente Principal 2_(t)

$$X_{2,t}^{*m} = CP_{2,t}^m = X_{1,t}^m * CP_{2,1} + X_{2,t}^m * CP_{2,2} + X_{3,t}^m * CP_{2,3} + \dots + X_{20,t}^m * CP_{2,20} \quad (13)$$

$$CP_{2,t}^m = \sum_{i=1}^{20} (X_{i,t}^m * CP_{2,i}) \quad (14)$$

Componente Principal 3_(t)

$$X_{3,t}^{*m} = CP_{3,t}^m = X_{1,t}^m * CP_{3,1} + X_{2,t}^m * CP_{3,2} + X_{3,t}^m * CP_{3,3} + \dots + X_{20,t}^m * CP_{3,20} \quad (15)$$

$$CP_{3,t}^m = \sum_{i=1}^{20} (X_{i,t}^m * CP_{3,i}) \quad (16)$$

Como se observa en las ecuaciones anteriores, las series de los $CP_{i,t}^m$ se obtienen de multiplicar las observaciones de cada una de las variables por los vectores propios, que operan como ponderadores para la obtención de $X_{i,t}^{*m}$ (ver Anexo 8.1.5, gráfico 12).

Finalmente, para obtener el ISVE:

$$ISVE = CP_{1,t}^m * EigenValue_1 + CP_{2,t}^m * EigenValue_2 + CP_{3,t}^m * EigenValue_3 \quad (17)$$

Como se puede apreciar en la ecuación 17, el ISVE es la sumatoria de cada $CP_{i,t}^m$ ponderado por su varianza explicada. En vista que el $CP_{1,t}^m$ acumula el 71.46% de la variabilidad de los datos, es el de mayor contribución al indicador sintético (ver Anexo 8.1.5, gráfico 13).

4.1.3. Análisis de Raíz Unitaria: Se inició realizando pruebas de estacionalidad sobre la serie del PIBT, cuyos resultados indican la presencia de estacionalidad en los datos.

Tabla 2: Resumen de Test de Estacionalidad sobre el PIBT

Data have been differenced and corrected for mean

Test	Seasonality
1. Auto-correlations at seasonal lags	YES
2. Friedman (non parametric)	YES
3. Kruskal-Wallis (non parametric)	YES
4. Spectral peaks	?
5. Periodogram	YES
6. Seasonal dummies	YES
6bis. Seasonal dummies (AMI)	YES

Fuente: Cálculos propios en Jdemtra+ 2.2.2

Adicionalmente, se realizaron pruebas de raíz unitarias estacional a la serie del PIBT por medio del método de HEGY, cuyos resultados indican que no se rechaza la existencia de raíz unitaria estacional (Ver Anexo 8.1.6, tabla 14). Por lo anterior se procedió con la diferenciación estacional del tipo (previo a la diferenciación, a las variables se aplicó el logaritmo natural):

$$\Delta_4 y_t = (1 - L_4)y_t = y_t - y_{t-4} \quad (18)$$

De igual forma, en vista que se están utilizando series de diferente frecuencia, el análisis de raíz unitaria estacional se aplica a los datos mensuales; en este caso, la prueba HEGY aplicada a la variable ISVE (Ver Anexo 8.1.6, tabla 15) indica que ésta presenta raíces estacionales, de manera que se diferencia de la siguiente manera:

$$\Delta_{12} y_t = (1 - L_{12})y_t = y_t - y_{t-12} \quad (19)$$

4.1.4. Regresiones MIDAS Escenario 1: Todos los modelos están estimados en términos de las variaciones interanuales (diferenciación estacional) de las series originales de las variables y la variable de interés a pronosticar es la variación porcentual del PIB respecto al mismo trimestre del año anterior. En términos generales el PIBT se modelará como:


$$\Delta_4 PIBT_t = \vartheta_0 + \sum_{t=0}^k \alpha_i \Delta_4 PIBT_{t-k}^q + \sum_{t=0}^k \theta_j \beta_j \Delta_{12} ISVE_{t-k}^m + \delta_h \text{Log}(Covid)_t^m + \varepsilon_t \quad (20)$$

En estos modelos MIDAS, el PIBT es explicado por un parámetro autorregresivo ($t - k$), un indicador global (ISVE) construido en base al ACP y el logaritmo natural del número de casos Covid-19; esta última variable en las estimaciones con Polinomios de Almon y Stepfunction permitió corregir por el quiebre observado en las variables derivado del efecto de la pandemia sobre el comportamiento económico registrado en 2020.

Tal y como expresó en las ecuaciones 3, 4 y 5, los modelos MIDAS utilizan un factor de ponderación θ^p , cuya estimación y magnitud depende de la especificación polinomial seleccionada. De los resultados obtenidos en términos de los pronósticos dentro de muestra y los Errores Cuadráticos Medio (MSE por sus siglas en inglés) resultantes, se seleccionaron cinco (5) modelos MIDAS, de los cuales a continuación se presentan sus pronósticos:

Tabla 3 y Gráfica 2: PIBT Real y Comparativo de Pronósticos (Variaciones Interanuales)

Trim	Var_PIBT	GETS-IIS ^{2/1/}	GETS-IIS ^{2/2/}	PDL/Almon ^{3/}	Step ^{4/}	MCO ^{5/}
2018q1	2.85	4.24	4.30	4.80	3.67	2.54
2018q2	4.10	2.93	3.05	4.03	3.58	4.52
2018q3	3.95	4.02	4.06	2.69	3.09	3.47
2018q4	4.46	3.84	3.91	4.27	3.98	4.03
2019q1	2.96	3.74	3.81	3.42	4.03	3.61
2019q2	1.69	3.31	3.40	3.60	4.05	1.93
2019q3	3.33	2.55	2.66	3.25	3.56	3.23
2019q4	2.62	2.65	2.74	2.27	2.64	3.11
2020q1	-1.33	-1.33	-1.32	-2.17	-2.72	-0.45
2020q2	-19.20	-21.32	-21.32	-20.98	-20.83	-16.69
2020q3	-7.89	-8.60	-8.55	-8.91	-10.42	-8.40
2020q4	-7.78	-8.12	-8.12	-7.25	-3.35	-7.80
2021q1	1.23	1.04	0.94	0.93	-1.64	-4.16



Fuente: Elaboración propia

Nota: Los Modelos Midas-Gets no incluye como regresor el Log(Covid), dado que el quiebre estructural de 2020 lo captura el Indicador de Saturación

^{1/} Midas-Gets con Indicador Saturación encontrando 3 outlier y 2 términos seleccionados para el regresor, con un $R^2 = 89.7$ y normalidad en los residuos

^{2/} Midas-Gets con Indicador Saturación encontrando 4 outlier y 2 términos seleccionados para el regresor, con un $R^2 = 90.3$ y normalidad en los residuos

^{3/} Midas-Almon con 6 retardos seleccionados para el ISVE, variable log(Covid), un $R^2 = 85.2$ y normalidad en los residuos

^{4/} Midas-Stepfunction con 6 retardos seleccionados, la variable log(Covid), un $R^2 = 81.9$ y normalidad en los residuos

^{5/} Estimación por Mínimos Cuadrados Ordinarios, con el ISVE y el log(Covid) como regresores y un $R^2 = 86.3$

La estimación utilizando Mínimos Cuadrados Ordinarios (MCO), presenta los resultados en el siguiente cuadro:

Tabla 4: Ecuación de PIBT por Mínimos Cuadrados Ordinarios

Dependent Variable: DPIBT				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	2.82	0.31	9.17	0.00
D(PIBT(-1))	-0.26	0.13	-2.05	0.04
D(ISVE)	0.43	0.07	6.32	0.00
Log(CV_19)	-1.15	0.27	-4.23	0.00
R²	0.8636			

El coeficiente que relaciona el PIBT con el ISVE es de 0.43%; cada cambio porcentual del ISVE, corresponde a 0.43 puntos porcentuales en el producto; por el contrario, el Covid-19 guarda una relación negativa con la producción nacional y, en ambos casos, los parámetros son estadísticamente significativos.

4.2. Escenario 2:

Como se puede ver en la Tabla 2, las 20 variables seleccionadas para el Nowcasting del PIBT, se pueden categorizar según el sector macroeconómico relacionado. Trabajos como el de Bok et al (2017) del Banco de Reserva de New York realizan este procedimiento a fin de estimar un Modelo de Factores Dinámicos, obteniendo factores latentes por tipo de indicador; Mendieta-Alvarado (2017), del Banco Central de Nicaragua realiza una similar agrupación en su esquema de proyecciones de corto plazo.

Para efectos del presente trabajo, se continuó utilizando el ACP para la construcción de indicadores dentro de su área macroeconómica de referencia; es así que, siguiendo esta metodología, se obtuvieron 5 nuevas variables que reflejan la Colinealidad conjunta y máxima de las series agrupadas.

Para todos los sectores construidos, el CP_1 cumple con el criterio de raíz latente (valores propios > 1); como se aprecia en la Tabla 17 (Anexo 8.1.8), este componente acumula la mayor Colinealidad de los datos, lo cual es deseable en términos prácticos para las estimaciones econométricas.

La combinación lineal de las series temporales y los vectores propios derivan en el nuevo conjunto de variables subyacentes, los cuales expresan de forma reducida la información original, mediante la obtención de indicadores ponderados por sector de análisis. Para efectos del análisis de raíz unitaria de los indicadores sintéticos de cada sector macroeconómico, se aplicó el test de HEGY, encontrando presencia de raíces estacionales en las series (ver Anexo 8.1.9, tabla 18).

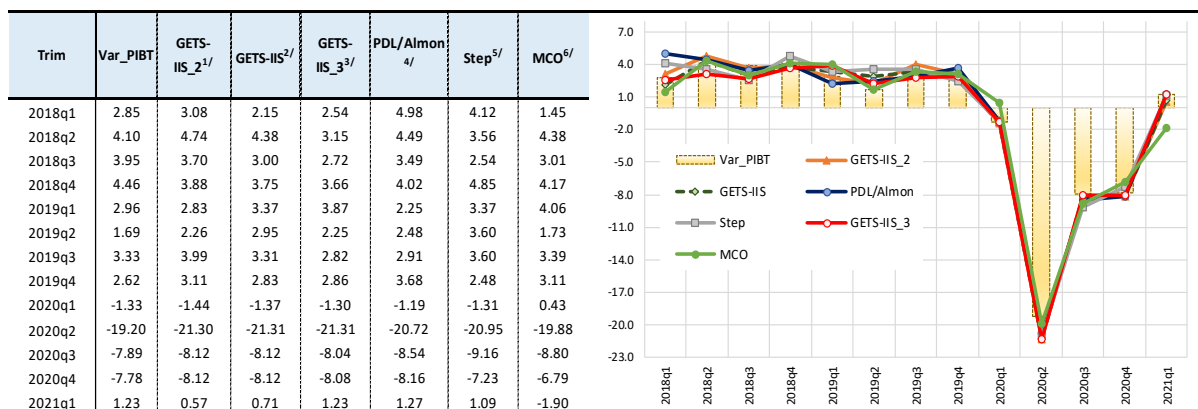
4.2.1. Regresiones MIDAS Escenario 2: El PIBT será explicado por un componente autorregresivo, 5 variables construidas del ACP y el logaritmo de los casos Covid-19; y, se modelará de la siguiente manera:

$$\Delta_4 PIBT_t = \vartheta_0 + \sum_{t=0}^k \alpha_i \Delta_4 PIBT_{t-k}^q + \sum_{t=0}^k \theta_1 \beta_{j,1} \Delta_{12} ISR_{t-k}^m + \sum_{t=0}^k \theta_2 \beta_{j,2} \Delta_{12} ISEx_{t-k}^m + \sum_{t=0}^k \theta_3 \beta_{j,3} \Delta_{12} ISM_{t-k}^m + \sum_{t=0}^k \theta_4 \beta_{j,4} \Delta_{12} ISF_{t-k}^m + \sum_{t=0}^k \theta_5 \beta_{j,5} \Delta_{12} VInt_{t-k}^m + \delta_n \text{Log}(Covid)_t^m + \varepsilon_t \quad (21)$$

Donde los regresores mensuales corresponde a los indicadores ponderados por sectores, siendo *ISR*: Sector Real; *ISEx*: Sector Externo; *ISM*: Sector Monetario; *ISF*: Sector Fiscal y *VInt*: Variables Internacionales.

Siguiendo el apartado 2.1.2 de especificaciones Polinomiales, se estimaron 6 modelos MIDAS y 1 modelo por MCO, cuyos pronósticos se presentan a continuación:

Tabla 5 y Gráfica 3: PIBT Real y Comparativo de Pronósticos (Variaciones Interanuales)



Fuente: Elaboración propia

Nota: Los Modelos Midas-Gets no incluye como regresor el Log(Covid), dado que el quiebre estructural de 2020 lo captura el Indicador de Saturación

^{2/} Midas-Gets con Indicador Saturación con 11 outliers, 4, 3, 4, 2 y 6 retardos estadísticamente significativos para los regresores X1... X5, un R² = 98.9 y normalidad en los residuos

^{2/} Midas-Gets con Indicador Saturación con 7 outliers, 3, 1, 4, 3 y 4 retardos estadísticamente significativos para los regresores X1... X5, un R² = 97.3 y normalidad en los residuos

^{3/} Midas-Gets con Indicador Saturación con 6 outliers, 1, 2, 2, 1 y 1 retardos estadísticamente significativos para los regresores X1... X5, un R² = 93.3 y normalidad en los residuos

^{4/} Midas con función de Polinomios Exponenciales de Almon con 6, 6, 6, 3, 4 rezagos seleccionados para los regresores de X1... X5, la variable log(Covid) para captar el cambio estructural 2020, un R² = 92% y normalidad en los residuos

^{5/} Midas-Stepfunction con 6 retardos seleccionados para cada regresor, variable log(Covid), un R² = 86.9 y normalidad en los residuos.

^{6/} Estimación por MCO para los regresores X1... X5, la variable log(Covid) para captar el cambio estructural 2020, un R² = 91.6% y normalidad en los residuos

Considerando los R^2 de las estimaciones a partir de los bloques de variables, se evidencia una mejor bondad de ajuste en los datos, respecto al escenario 1, con una mayor cantidad de regresores se obtienen resultados más precisos para poder pronosticar la variación del PIBT.

Analizando la ecuación obtenida por Mínimos Cuadrados Ordinarios se puede observar que grupo de variables tiene un mayor aporte estadístico al pronóstico de PIBT.

Tabla 6: Ecuación de PIBT por Mínimos Cuadrados Ordinarios^{2/}

Dependent Variable: DPIBT				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	2.81	0.26	10.80	0.00
D(PIBT(-1))	-0.29	0.06	-4.59	0.00
D(ISR)	0.20	0.03	5.73	0.00
D(ISEX)	0.08	0.01	5.20	0.00
D(ISM)	-0.01	0.02	-0.47	0.64
D(ISF)	0.15	0.03	5.31	0.00
D(VInt)	0.09	0.02	4.01	0.00
Log(CV_19)	-0.60	0.14	-4.16	0.00
R²	0.9164			

Conforme a los resultados de la regresión, el sector real reporta el coeficiente más alto y estadísticamente significativo; por lo que, la trayectoria de las variables contenidas en este indicador son las más relevantes para predecir la evolución futura del PIBT; le sigue el sector fiscal y las variables internacionales; por otra parte, se observa que la influencia del sector monetaria es negativa, pero sin significancia estadística; finalmente, el Covid-19, como se esperaba guarda una relación negativa con la actividad económica.

4.3. Escenario 3:

Construcción de modelos MIDAS a partir de las variables que presentan mayor correlación con el PIBT Real.

$$Y_t^q = f(X_{1,t}^m, X_{2,t}^m, X_{3,t}^m, X_{4,t}^m, X_{5,t}^m, X_{6,t}^m, X_{7,t}^m, X_{8,t}^m, X_{9,t}^m, X_{10,t}^m) \quad (22)$$

Tabla 7: Variables Utilizadas para pronosticar el PIBT

Baja Frecuencia		Alta Frecuencia			
Variable Dependientes	Variables Independientes	Justificación como regresor del PIBT		Coef. Correlación con PIBT	
Y_t^q	PIBT Real	$X_{1,t}^m$	IMAE	Por sus características estadísticas es ideal para prever el desempeño de corto plazo de la actividad económica.	94.24%
		$X_{2,t}^m$	Remesas	Fundamentales para determinar el ingreso disponibles de las familias y por ende, el consumo final de los hogares.	49.19%
		$X_{3,t}^m$	IPL_USA	Por ser el principal destino de las exportaciones y de origen de las importaciones, las fluctuaciones en la producción de ese país afectan significativamente la economía hondureña.	65.92%
		$X_{4,t}^m$	Comercio Exterior	Comprende la sumatoria de las Exportaciones e Importaciones a precios constantes, referencia 2000=100.	66.36%
		$X_{5,t}^m$	Consumo de Energía Eléctrica	Por ser la electricidad es uno de los principales insumos intermedios de cualquier industria, su alzas o bajas reflejan los cambios en la economía.	60.00%
		$X_{6,t}^m$	Impuestos Indirectos	Tributos directamente relacionados con la producción de un país, una mayor/menor recaudación es señal de expansión, contracción o desaceleración en el ciclo económico.	56.97%
		$X_{7,t}^m$	Permisos de Construcción+Producción de Cemento	Índice de Volumen Ponderado (2000=100), entre los metros cuadrados diferidos de los permisos de construcción y la producción de cemento; esta variable es indicativa del comportamiento de la Inversión.	63.00%
		$X_{8,t}^m$	Tasa Turística	La trayectoria de este indicador denota el desempeño de las actividades económicas asociadas al turismo de origen nacional y extranjero	52.56%
		$X_{9,t}^m$	Consumo de Combustibles	Las fluctuaciones en el consumo final e intermedio de combustibles están altamente relacionada con la producción, consumo, importación y exportación de bienes y servicios.	42.59%
		$X_{10,t}^m$	Casos Covid-19 en Honduras	Se utilizó el logaritmo del numero de casos Covid-19 registrados desde marzo 2020, para captar el quiebre estructural que provocó la caída del PIBT a lo largo de ese año.	

Fuente: Elaboración propia

^{2/} Debido a que las estimaciones con Modelos MIDAS contienen una cantidad significativa de parámetros y sus rezagos distributivos, para fines de interpretar la relación de las variables y su contribución al pronóstico del PIBT Real, solo se presentarán los parámetros de las estimaciones por Mínimos Cuadrados Ordinarios; no obstante, se muestran los resultados de las proyecciones de todos los modelos.

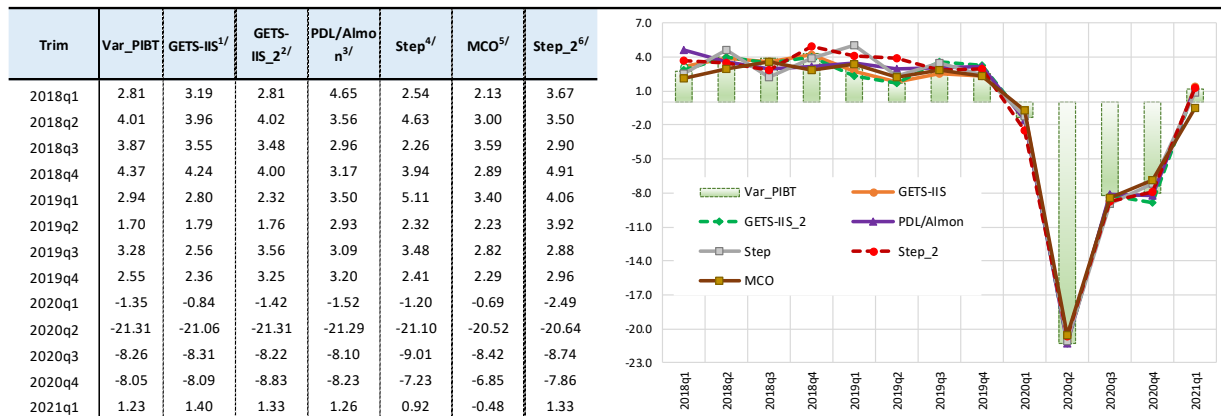
4.3.1. Regresiones MIDAS Escenario 3: El PIBT será explicado por un componente autorregresivo de orden $t - k$, 9 variables, que representan los indicadores de mayor correlación con la actividad económica y el logaritmo de los casos Covid-19; y, se modelará de la siguiente manera:

Los modelos están especificados de la siguiente manera:

$$\Delta_4 PIBT_t = \vartheta_0 + \sum_{t=0}^k \alpha_i \Delta_4 PIBT_{t-k}^q + \sum_{t=0}^k \theta_j \beta_i \Delta_{12} X_{i,t-k}^m + \delta_h \text{Log}(Covid)_t^m + \varepsilon_t \quad (23)$$

Los pronósticos de las especificaciones MIDAS con variables individuales se presentan en el siguiente cuadro y gráfica:

Tabla 8 y Gráfica 4: PIBT Real y Comparativo de Pronósticos (Variaciones Interanuales)



Fuente: Elaboración propia

Nota: Los Modelos Midas-gets no incluyen como regresor el Log(Covid), dado que el quiebre estructural de 2020 lo captura el Indicador de Saturación

^{1/} Midas-gets con Indicador Saturación encontrando 7 outliers y una detección de 3 y 6 rezagos distributivos entre variables, con un $R^2 = 97.6$ y normalidad en los residuos

^{2/} Midas-gets con Indicador Saturación encontrando 8 outliers y se especificaron las variable en t (sin rezagos), se obtuvo un $R^2 = 98.8$ y normalidad en los residuos

^{3/} Midas con función de Polinomios Exponenciales de Almon con 4, 3, 3, 3, 5, 3, 5, 4, 6 y 6 rezagos seleccionados para los regresores de $X_1 \dots X_9$, la variable log(Covid) para captar el cambio estructural 2020, un $R^2 = 96.7\%$ y normalidad en los residuos

^{4/} Midas-Stepfunction con 6 retardos máximos establecidos para cada regresor, variable log(Covid), un $R^2 = 89.5$ y normalidad en los residuos.

^{5/} Estimación por Mínimos Cuadrados Ordinarios con 9 variables regresoras y los casos covid-19, un $R^2 = 95.4\%$ y normalidad en los residuos.

^{6/} Midas-Stepfunction con de 3 a 6 retardos máximos establecidos para cada regresor, variable log(Covid), un $R^2 = 89.7$ y normalidad en los residuos.

En este escenario de Nowcasting, se analizará que variables que, de forma individual explican la evolución futura del PIBT Real, los parámetros obtenidos por MCO son los siguientes:

Tabla 9: Ecuación de PIB por Mínimos Cuadrados Ordinarios

Dependent Variable: DPIBT				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	1.86	0.35	5.37	0.00
D(PIBT(-1))	-0.30	0.05	-5.94	0.00
D(IMAE)	0.51	0.08	6.50	0.00
D(Remesas)	0.01	0.01	0.75	0.45
D(IPI_EUA)	0.13	0.04	2.95	0.00
D(X+M)	-0.02	0.03	-0.60	0.55
D(Cons_Energ.)	0.13	0.04	3.36	0.00
D(Imptos_Indir)	0.01	0.02	0.85	0.40
D(Per_Const+Q_Cmt)	0.02	0.02	1.46	0.15
D(Tasa_Turis)	0.03	0.01	3.96	0.00
D(Cons_Combust.)	-0.04	0.02	-2.44	0.02
Log(CV_19)	-0.33	0.14	-2.39	0.02
R²	0.9545			

El modelo de MCO reportó un $R^2 = 95.45$, superior al obtenido en los Escenario 1 y 2; es decir que existe un mejor ajuste estadístico en los datos a medida que incorporamos mayor detalle de la información, el IMAE con un $\beta_i = 0.51$ es el indicador de más aporte al proyección del PIBT, le sigue el consumo de energía eléctrica y el IPI de EUA, coherente con lo que estimó la ecuación de MCO por bloques de variables.

5. Evaluación de Pronósticos

5.1. Medidas de Precisión de Pronóstico por el MSE

La capacidad predictiva de los modelos será analizada mediante las medidas de precisión de pronóstico. Como primer punto, se analizará en cada ecuación el MSE que mide las desviaciones de las proyecciones respecto a los valores observado).

$$MSE = \frac{1}{N} \sum_{t=1}^N (PIB_t - \widehat{PIB}_t)^2 \quad (24)$$

Un modelo tendrá una mejor precisión si cuenta con un MSE bajo y al comparar un conjunto de modelos se elegirán aquellos con el menor MSE.

De los 17 modelos presentados (ver Anexo 8.1.10, tabla 19 y Anexo 8.1.11, tabla 20), se encuentra que las 2 ecuaciones más precisas en términos del MSE son estimadas bajo los criterios del Escenario 3. En este sentido se observa que en términos de la minimización del MSE los modelos del Escenario 3 superan tanto a los estimados dentro del Escenario 2 y Escenario 1, mientras que los del Escenario 2 presentan menores errores de pronósticos en comparación al Escenario 1.

Conforme los datos presentados en la tabla 19 (Anexo 8.1.10), se observa que en general, para las series temporales de Honduras las especificaciones de los modelos tipo GET-IIS presentan la mejor robustez estadística.

5.2. Test de Diebold y Mariano

En el presente trabajo se disponen de varios modelos, según Diebold y Mariano (1995), una manera de testear la precisión entre dos pronósticos es estableciendo una función de pérdidas en términos de los errores de pronóstico, en este sentido se propone una hipótesis nula que postula lo siguiente:

$$H_0 = [g(e_{it})] = [g(e_{jt})]; [d_t] = 0 \quad (25)$$

Donde, los errores de pronósticos del modelo i $[g(e_{it})]$ son iguales al error de pronóstico del modelo j $[g(e_{jt})]$, es decir, el diferencial $[d_t] = 0$. O, dicho de otra manera, igual precisión implicará que la media del diferencial de perdidas es igual a 0.

El Test de Diebold y Mariano (DM), permite determinar si existe igual precisión de pronósticos al comparar dos modelos^{3/}, o si estadísticamente se rechaza o no rechaza la H_0 . En el caso de no

^{3/} No rechazar la H_0 y validar que la EQ_i tiene -estadísticamente- una capacidad predictiva similar que la EQ_j no significa que el pronóstico es exactamente el mismo, sino que, en términos promedios tienen igual un desempeño; por otra parte, la superioridad predictiva de una modelo sobre otro, no implica que los menos precisos no contienen información que pueda ser importante, por eso en la literatura se recomienda la combinación de pronóstico.

rechazar la H_0 , y encontrar una precisión estadísticamente igual, para determinar cuál sería el modelo óptimo, correspondería analizar el MSE de ambos y seleccionar el más bajo.


Al aplicar el test DM a cada uno de los modelos presentados en los tres (3) escenarios, se observa que, por ejemplo, en el escenario 1, al 10% de significancia estadística, los modelos GET-IIS_2 y GET-IIS presentan un rendimiento de pronóstico estadísticamente sin diferencias (Anexo 8.1.12, tabla 21).

Para el escenario 2, los MIDAS GET-IIS, GET-IIS_2 y GET-IIS_3 continúan mostrando igual capacidad de pronóstico; asimismo, al comparar las ecuaciones con Stepfunction y PDL/Almon, reportan similares resultados; no se rechaza la H_0 , la función de pérdidas es estadísticamente igual entre ambos modelos (Anexo 8.1.12, tabla 22).

En el escenario 3 (Anexo 8.1.12, tabla 23), el Modelo GET-IIS_2, tiene una capacidad predictiva similar al GET-IIS; no obstante, es diferente a las demás especificaciones.

5.3. Evaluación de Resultados según disponibilidad de datos

Gráfica 5: Ejercicio de Nowcasting al I Trimestre 2021
Resultados serie desestacionalizada (según avance en la obtención de datos)



Fuente: Elaboración propia

Nota: Las variaciones corresponden al promedio de pronósticos de los modelos estimados a medida que se avanza en la recolección de información

Con el propósito de evaluar el efecto de la disponibilidad de información (gráfica 1) sobre las estimaciones de Nowcasting, versus los datos observados del PIBT -Serie desestacionalizada- (ver Anexo 8.1.13), la gráfica 6 muestra los resultados de un ejercicio que permite observar la evolución del pronóstico con base a la publicación mensual de las diferentes variables consideradas dentro de los modelos. El ejercicio nos permite identificar que a medida que se incorpora una nueva publicación de las variables, el error de pronóstico (medido a través del MSE) se va reduciendo.

Por otra parte, al comparar la capacidad predictiva de los modelos MIDAS con el pronóstico generado con un modelo univariante para el PIBT, se observa que el nowcast generado por los modelos MIDAS también supera en términos de minimización del MSE al modelo ARIMA.

6. Combinación de Pronósticos

Existe una extensa literatura que indica la utilidad de combinar pronósticos, según Clements y Harvey (2010) una combinación lineal de dos o más proyecciones puede generar estimaciones más precisas que la utilización de una sola. La evaluación de esta práctica implica validar si una integración simple o ponderada de previsiones da como resultado una reducción estadísticamente significativa en el MSE versus la utilización de un pronóstico individual.

De acuerdo a Timmerman (2006) existen al menos tres (3) razones por las que combinar pronósticos entrega mejores resultados que los obtenidos por un modelo individual:

1. La información utilizada para cada modelo puede diferir y una forma de explotar la riqueza de cada estimación es combinándolas (Stock y Watson, 1999).
2. Pueden existir cambios estructurales que afecten o favorezcan a un modelo, respecto a otro.
3. Las mediciones econométricas pueden estar sujetos a sesgos por variables omitidas, así que la combinación entre modelos puede compensar el mayor o menor error de estimación.

Al disponer de un conjunto de pronósticos de diferentes modelos, una manera sencilla de unir sus observaciones es a través de un promedio simple; sin embargo, esto implícitamente supone que todos los modelos tienen la misma precisión estadística; sin embargo, las medidas de precisión están usualmente definidas en términos del error de pronóstico.


Para efectos de la combinación de pronósticos se utilizó el MSE computado del período 2000-2021; de los resultados se observa que el modelo con menor error de pronóstico es el GET-IIS_2 del escenario 3 (concentra el 26.1% de toda la ponderación, (Ver Anexo 8.1.11, tabla 20).

En el ejercicio de Nowcasting, ponderaremos cada modelo conforme al inverso del MSE:

$$\overline{PIBT}_{t+n} = \widehat{PIBT}_{1,t+n} * \left(\frac{1/MSE_1}{\sum_{i=1}^k 1/MSE} \right) + \widehat{PIBT}_{2,t+n} * \left(\frac{1/MSE_2}{\sum_{i=1}^k 1/MSE} \right) + \dots + \widehat{PIBT}_{k,t+n} * \left(\frac{1/MSE_k}{\sum_{i=1}^k 1/MSE} \right) \quad (26)$$

Conforme a lo sugerido por la literatura, los resultados indican que la combinación de pronósticos entrega resultados más precisos en comparación a las estimaciones individuales. El escenario 3 presenta las menores desviaciones respecto a PIBT observado y los estadísticos descriptivos de los errores de pronóstico evidencian la mejor robustez de este escenario respecto a los demás.

Gráfica 6 y Tabla 10:
PIBT Real y Comparativo de Combinación de Pronósticos (Variaciones Interanuales)
y Estadísticos de los Errores de Pronósticos



Fuente: Elaboración propia

El promedio global, que es la media ponderada de los 17 modelos calculados (Ver Anexo 8.1.11, tabla 20), proporciona una estimación menos precisa que el escenario 3; sin embargo, en términos de su MSE, brinda una serie aceptable estadísticamente.

Al aplicar los test de DM a los promedios de pronósticos (ver Anexo 8.1.14, tabla 25), asumiendo que existe igual desempeño de pronóstico, se rechaza la hipótesis nula, con lo cual se dice que las previsiones son estadísticamente diferentes al 10% de significancia, concluyendo que el escenario 3 presenta el mejor desempeño.

7. Conclusiones

El propósito del presente documento es presentar un marco de pronósticos de corto plazo (Nowcasting) para el PIBT a precios constantes, utilizando la metodología “Mixed Data Sampling (MIDAS)”, desarrollada principalmente por Eric Ghysels.

Se realizaron tres (3) escenarios, el primero se enfoca en reducir la dimensionalidad del conjunto de información en un indicador ISVE construido mediante el ACP que resume todas las variables. En este escenario se estimaron 5 ecuaciones cuyos resultados tiene una menor capacidad predictiva, respecto a los demás, en términos del mayor MSE.

El segundo escenario plantea la maximización de la variabilidad de las series, pero agrupando los datos conforme a diferentes áreas de análisis macroeconómico, para ello se construyeron conforme al ACP 5 nuevas variables, que operan como los regresores de pronóstico del PIBT, obteniendo de este enfoque 5 modelos que en forma general contienen una bondad de ajuste más alta y un MSE más bajo respecto a las estimaciones del ISVE.

Finalmente, se seleccionaron 9 variables cuya correlación respecto al PIB es en promedio mayor al 50%; con estos indicadores se elaboraron 6 ecuaciones, las cuales brindan las estimaciones con menores errores de pronósticos según el MSE.

Como se pudo constatar en los escenarios 2 y 3, si bien el uso del ACP es una práctica muy utilizada para la síntesis de información, al concentrar todas las variables en un único indicador hace perder cierta riqueza de la evolución de las variables individuales, concluyendo que en estos 2 escenarios se dispone de las mejores estimaciones.

Por otra parte, dentro de los esquemas de ponderación de los parámetros de los modelos MIDAS, se encontró que las especificaciones con el procedimiento GET con Indicador de Saturación (GET-IIS), entregan buenos resultados y con un mejor desempeño de pronóstico, respecto a los demás, le sigue en ese mismo orden estadístico, los que modelan las variables y sus rezagos con los Polinomios Exponenciales del ALMON y, en tercer lugar, los MIDAS con las funciones de escalón unitaria o Stepfunction.

Se logró identificar 6 Ecuaciones entre los escenarios 2 y 3 que serían de seguimiento para las estimaciones de Nowcasting para un trimestre t . Asimismo, conforme al análisis del MSE y los test DM, la combinación de pronósticos reduce la variabilidad de las estimaciones y facilita resultados con menores errores de pronóstico.

El esquema de proyecciones de Nowcasting es una herramienta econométrica nueva para el BCH, que facilitará disponer de una señal adelantada del comportamiento del PIBT a corto plazo, relevante para la adopción de medidas de política monetaria.

El propósito de los MIDAS es entregar pronósticos del trimestre inmediato, por lo cual es importante resaltar que el Nowcasting no tiene como propósito proporcionar proyecciones de mediano o largo plazo, para ello los bancos centrales utilizan otras herramientas que están fuera del alcance de este trabajo.

8. Anexos

8.1.1. Correlación de variables con el PIB Real

Tabla 11: Coeficientes de Correlación de Pearson

No.	Variable	Coef. de Correlación		Sector
		2000-2019	2000-2020	
1	IMAE	89.1%	94.2%	Real
2	Imptos_Indir	57.0%	75.0%	Fiscal
3	Tasa_Turis	52.6%	74.5%	Fiscal
4	Cons_Energ.	60.0%	73.9%	Real
5	IPI_EUA	65.9%	70.5%	Internacional
6	Per_Const	57.7%	66.7%	Real
7	Export	46.7%	64.9%	Externo
8	Import	69.1%	63.4%	Externo
9	IP_Comb	47.0%	51.7%	Externo
10	IPC_EUA	54.8%	46.7%	Internacional
11	Cons_Combust.	18.5%	42.6%	Real
12	Remesas	49.2%	42.5%	Internacional
13	Q_Cmt	45.4%	35.3%	Real
14	Fluj_Cart	34.3%	32.3%	Monetario
15	Remun. Pub.	1.5%	19.2%	Fiscal
16	Depos_A&P	51.5%	13.5%	Monetario
17	IPX	30.7%	12.8%	Externo
18	M1	52.0%	-6.9%	Monetario
19	TAON	-48.1%	-20.5%	Monetario
20	ITCER	-53.7%	-39.0%	Externo

Fuente: Elaboración propia

8.1.2. Análisis de Componentes Principales (ACP)

Los Componentes Principales (CP_i) serán una combinación lineal de los datos originales que tengan varianza máxima y se representará por el vector Z_1 , expresado como:

$$Z_1 = X\alpha_1 \quad (27)$$

En vista que las variables son ruido blanco; es decir $media = 0$ y $varianza = 1$, la varianza será:

$$Var(Z_1) = \frac{1}{n} Z_1' Z_1 = \frac{1}{n} \alpha_1' X' X \alpha_1 = \alpha_1' S \alpha_1 \quad (28)$$

Donde S es la matriz de varianzas y covarianzas de las observaciones. El propósito del ACP es maximizar la varianza, para contar con la más alta variabilidad en el CP_i , para ello imponemos una restricción al vector α_1 -sin pérdida de generalidad- de manera que $\alpha_1' \alpha_1 = 1$ y para resolver utilizamos el método del multiplicador de Lagrange:

$$L = \alpha_1' S \alpha_1 - \lambda (\alpha_1' \alpha_1 - 1) \quad (29)$$

Al obtener la condición del primer orden para maximizar la función respecto a α_1 e igualar a 0.

$$\frac{\partial L}{\partial \alpha_1} = 2S\alpha_1 - 2\lambda\alpha_1 = 0 \rightarrow S\alpha_1 = \lambda\alpha_1 \quad (30)$$

$$\alpha_1(S - \lambda I) = 0 \quad (31)$$

La expresión final se resuelve al encontrar los λ Valores Propios (Eigenvalues) y los α_1 Vectores Propios (Eigenvectors) de la matriz S de varianzas y covarianzas. En el ACP, λ representa la contribución del CP_i a la varianza global; en tanto, los α_j define los coeficientes de cada variable en los CP_i .

8.1.3. Correlaciones parciales entre variables

Gráfica 7: Matriz de Correlaciones de las Variables Estandarizadas

	IMAE	Remesas	Fluj_Cart	IP_Comb	Cons_Combust	IPI_EUA	IPC_EUA	M1	IPX	Export	Cons_Energ.	Q_Cmt	Imptos_Indir	Tasa_Turis	ITCER	TAON	Per_Const	Remun. Pub.	Depos_A&P	Import	r		
IMAE	1.00																						
Remesas	0.91	1.00	0.69																				r > 90%
Fluj_Prest	0.83	0.69	1.00																				
IP_Comb	0.66	0.54	0.76	1.00																			
Cons_Combust.	0.88	0.82	0.79	0.66	1.00																		
IPI_EUA	0.64	0.62	0.55	0.57	0.60	1.00																	70% < r < 89%
IPC_EUA	0.97	0.91	0.81	0.67	0.87	0.58	1.00																
M1	0.84	0.89	0.62	0.39	0.69	0.41	0.87	1.00															
IPX	0.96	0.90	0.80	0.66	0.86	0.70	0.84	0.87	1.00														
Export	0.90	0.80	0.75	0.66	0.88	0.68	0.89	0.71	0.87	1.00													
Cons_Energ.	0.92	0.88	0.75	0.68	0.87	0.62	0.94	0.74	0.91	0.86	1.00												
Q_Cmt	0.72	0.79	0.60	0.51	0.70	0.53	0.71	0.68	0.70	0.73	0.73	1.00	0.70										
Imptos_Indir	0.89	0.83	0.65	0.43	0.76	0.70	0.84	0.75	0.83	0.80	0.84	0.70	1.00										
Tasa_Turis	0.68	0.60	0.49	0.51	0.67	0.65	0.62	0.39	0.61	0.68	0.73	0.56	0.75	1.00									
ITCER	0.85	0.67	0.82	0.61	0.77	0.32	0.88	0.71	0.87	0.78	0.80	0.53	0.67	0.46	1.00								
TAON	-0.79	-0.84	-0.64	-0.63	-0.76	-0.58	-0.79	-0.71	-0.82	-0.67	-0.81	-0.66	-0.66	-0.57	-0.55	1.00							
Per_Const	0.38	0.39	0.43	0.64	0.43	0.41	0.36	0.16	0.36	0.34	0.48	0.48	0.29	0.53	0.22	-0.57	1.00						
Remun. Pub.	0.93	0.84	0.85	0.72	0.86	0.52	0.94	0.77	0.93	0.82	0.88	0.63	0.76	0.58	0.86	-0.82	0.43	1.00					
Depos_A&P	0.93	0.93	0.70	0.49	0.79	0.52	0.96	0.95	0.94	0.82	0.87	0.72	0.85	0.54	0.80	-0.74	0.22	0.85	1.00				
Import	0.92	0.87	0.81	0.75	0.87	0.71	0.90	0.73	0.87	0.87	0.90	0.76	0.84	0.71	0.74	-0.77	0.49	0.86	0.84	1.00			

Fuente: Elaboración Propia

8.1.4. Test de Kaiser's Measure of Sampling Adequacy (KMO) para el ISVE


Tabla 12: Parámetros Estadístico KMO

KMO ≥ 0.8	Superior, sobresaliente
$0.7 \leq$ KMO < 0.8	Superior, regular
$0.6 \leq$ KMO < 0.7	Superior, mediocre
$0.5 \leq$ KMO < 0.6	Superior, despreciable
KMO < 0.5	Inaceptable

Fuente: Analisis Multivariante, 5ta Edición, Hair (1999)

Nota: Este índice se encuentra entre 0 a 1 y se evalúa según los siguientes criterios indicados.

Gráfica 8: Test Kaiser's Measure of Sampling Adequacy



Fuente: Elaboración propia

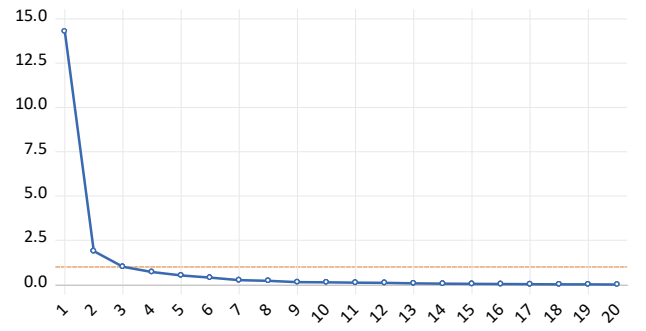
8.1.5. Resultados del ACP para el ISVE

Tabla 13: Componentes Principales
(Valores propios y proporción de varianza explicada)

Eigenvalues: (Sum = 20, Average = 1)					
Number	Value	Difference	Proportion	Cumulative Value	Cumulative Proportion
1	14.77496	13.26042	0.7387	14.77496	0.7387
2	1.514534	0.521770	0.0757	16.28949	0.8145
3	0.992764	0.274272	0.0496	17.28225	0.8641
4	0.718493	0.248428	0.0359	18.00075	0.9000
5	0.470065	0.070902	0.0235	18.47081	0.9235
6	0.399163	0.153567	0.0200	18.86998	0.9435
7	0.245596	0.036792	0.0123	19.11557	0.9558
8	0.208805	0.080304	0.0104	19.32438	0.9662
9	0.128501	0.015396	0.0064	19.45288	0.9726
10	0.113105	0.006513	0.0057	19.56598	0.9783
11	0.106592	0.018679	0.0053	19.67258	0.9836
12	0.087913	0.025714	0.0044	19.76049	0.9880
13	0.062199	0.009057	0.0031	19.82269	0.9911
14	0.053142	0.014081	0.0027	19.87583	0.9938
15	0.039061	0.005154	0.0020	19.91489	0.9957
16	0.033906	0.014038	0.0017	19.94880	0.9974
17	0.019868	0.002766	0.0010	19.96866	0.9984
18	0.017103	0.004809	0.0009	19.98577	0.9993
19	0.012294	0.010355	0.0006	19.99806	0.9999
20	0.001939	---	0.0001	20.00000	1.0000


Fuente: Elaboración Propia

Gráfico 9: Scree Plot (Ordered Eigenvalues)




Fuente: Elaboración Propia

Gráfico 10: Eigenvalues Cumulative Proportion




Fuente: Elaboración Propia

Gráfica 11: Vectores Propios de CP seleccionados (Ponderaciones de las variables)




Fuente: Elaboración propia

Gráfica 12: Series temporales de los Componentes Principales



Fuente: Elaboración propia

Gráfica 13: Evolución ISVE y sus Variaciones Interanuales $((ISVE_t/ISVE_{t-12}) - 1) * 100$



Fuente: Elaboración propia

8.1.6. Prueba de Raíz Estacional (Test de HEGY):

$$\Delta_4 y_t = (1 - L_4)y_t = y_t - y_{t-4}: \text{Series Trimestrales} \tag{32}$$

$$\Delta_{12} y_t = (1 - L_{12})y_t = y_t - y_{t-12}: \text{Series Mensuales} \tag{33}$$

Hylleberg, Engle, Granger & Yoo (1990), propusieron un Test para determinar la existencia de Raíces Unitarias Estacionales (*Seasonal Unit Roots en Ingles*). Una serie como el PIBT sigue un proceso de orden $AR(\rho)$, y, para el operador AR tenemos:

$$\alpha(L) = 1 - \alpha_1 L - \dots - \alpha_\rho L^\rho \tag{34}$$

Donde L es el número de raíces del polinomio característico, esta expresión que puede ser reorganizada y formularse para este Test, como:

$$\alpha(L) = (1 - L^4) - \pi_1 L(1 + L + L^2 + L^3) + \pi_2 L(1 - L + L^2 - L^3) + (\pi_3 + \pi_4 L)(1 - L^2) - \alpha^*(L)(1 - L^4) \tag{35}$$

Y, el operador AR puede factorizarse de la siguiente manera para π_i raíces:

$$\alpha(L) = \left\{ \begin{array}{l} \alpha^a(L)(1 - L), \text{ si } \pi_1 = 0 \\ \alpha^b(L)(1 + L), \text{ si } \pi_2 = 0 \\ \alpha^c(L)(1 - iL)(1 + iL), \text{ si } \pi_3 = \pi_4 = 0 \end{array} \right\}; \text{ en la que } i \text{ son raíces complejas} \tag{36}$$

Donde la serie podrá tener raíces unitarias regulares y/o estacionales conforme a la prueba de hipótesis sobre las π_i raíces.

Hylleberg et al. (1990), propuso para este test estimar el siguiente modelo:

$$\Delta_4 y_t = \pi_1 Z1_{t-1} + \pi_2 Z2_{t-1} + \pi_3 Z3_{t-1} + \pi_4 Z3_{t-2} + \sum_{j=1}^{\rho-4} \alpha_j^* \Delta_4 y_{t-j} + u_t \tag{37}$$

La Hipótesis nula es $H_0 = \pi_1 = \pi_2 = \pi_3 = \pi_4 = 0$; esta prueba es conocida como Hegy Test y se utilizará para las series temporales de Honduras.

Tabla 14: Test de Raíz Unitaria Estacional para el PIBT

Method: Traditional HEGY
 Null Hypothesis: Unit root at specified frequency
 Periodicity (Seasons): 4
 Lag Selection: 2 (Automatic: AIC, maxlags=12)
 Sample Size: 78

	Non-Seasonal Deterministics: None			Non-Seasonal Deterministics: Constant			Non-Seasonal Deterministics: Constant and trend		
	Test Stat.	Significance		Test Stat.	Significance		Test Stat.	Significance	
		5%	10%		5%	10%		5%	10%
Frequency 0	-0.74	-1.90	-1.59	-1.92	-3.35	-2.80	-2.64	-3.29	-3.03
Frequency 2PI/4 and 6PI/4	3.50	7.85	3.62	3.34	28.80	7.85	3.69	7.85	3.62
Frequency PI	-1.29	-1.90	-1.59	-1.26	-2.52	-1.90	-1.31	-1.90	-1.59
All seasonal frequencies	2.97	5.67	2.88	2.84	19.76	5.67	3.11	5.67	2.88
All frequencies	2.32	4.70	2.84	2.88	15.57	5.05	3.99	5.69	3.99

Fuente: Elaboración propia

Tabla 15: Test de Raíz Unitaria Estacional para el ISVE

Null Hypothesis: Unit root at specified frequency

Periodicity (Seasons): 12

Lag Selection: 2 (Automatic: AIC, maxlags=12)

Sample Size: 242

	Non-Seasonal Deterministics: None			Non-Seasonal Deterministics: Constant			Non-Seasonal Deterministics: Constant and trend			Freq.	Ciclos
	Test Stat.	Significance		Test Stat.	Significance		Test Stat.	Significance			
		5%	10%		5%	10%		5%	10%		
Frequency 0	-1.55	-1.94	-1.62	-1.17	-2.84	-2.54	-2.86	-3.36	-3.08	0	0
Frequency 2PI/12 and 22PI/12	12.69	8.13	3.70	12.86	8.13	3.70	11.65	8.13	3.70	pi/6	1
Frequency 4PI/12 and 20PI/12	17.44	8.13	3.70	17.52	8.13	3.70	15.77	8.13	3.70	pi/3	2
Frequency 6PI/12 and 18PI/12	8.82	8.13	3.70	8.86	8.13	3.70	8.40	8.13	3.70	pi/2	3
Frequency 8PI/12 and 16PI/12	6.64	8.13	3.70	6.64	8.13	3.70	6.30	8.13	3.70	2pi/3	4
Frequency 10PI/12 and 14PI/12	1.64	8.13	3.70	1.66	8.13	3.70	1.69	8.13	3.70	5pi/6	5
Frequency PI	-3.32	-1.94	-1.62	-3.30	-1.94	-1.62	-3.36	-1.94	-1.62	pi	6
All seasonal frequencies	9.73	7.49	3.45	9.78	7.49	3.45	9.06	7.49	3.45		
All frequencies	9.11	7.01	3.26	9.09	7.07	3.39	9.90	7.29	3.59		

Fuente: Elaboración propia

Raíces estacionales significativas

8.1.7. Test de Kaiser's Measure of Sampling Adequacy (KMO) para Sector

Tabla 16: Resultados Test KMO por Sector

	Kaiser's MSA
Sector Real	0.8419
Sector Externo	0.8489
Sector Monetario	0.7397
Sector Fiscal	0.6771
Variables Internacionales	0.6520

Fuente: Elaboración propia

Nota: Los coeficientes son superiores al parámetro de aceptación de 0.5, cumpliendo el criterio válido para el ACP.

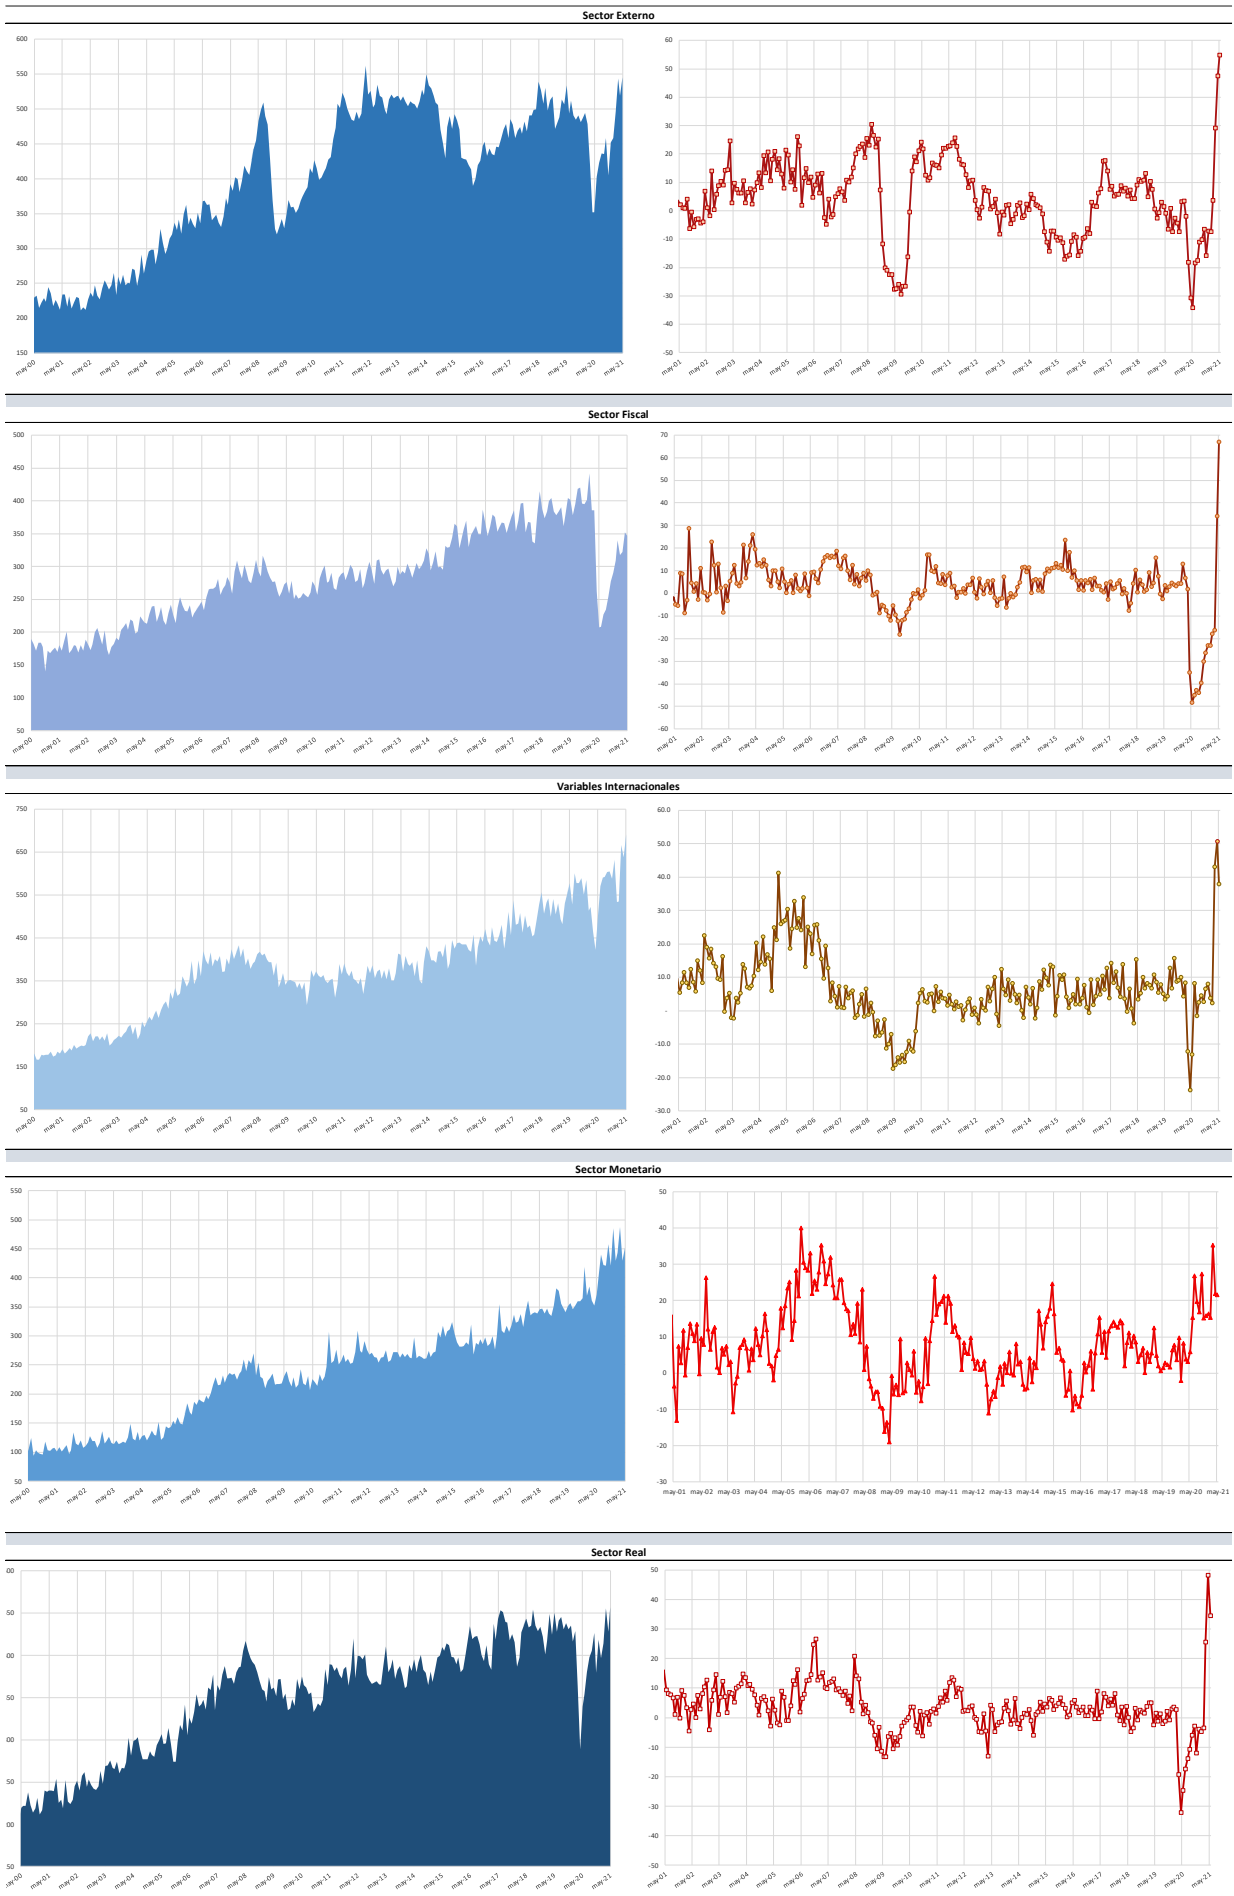
8.1.8. Resultados Análisis de Componentes Principales por Sector

Tabla 17: Componentes Principales
(Valores, vectores propios y % de varianza explicada)

Number	Value	Difference	Proportion	Cumulative Value	Cumulative Proportion	Variable	PC 1	PC 2	PC 3	PC 4	PC 5
Sector Real											
Eigenvalues: (Sum = 5, Average = 1)						Eigenvectors (loadings):					
1	3.72	2.99	0.74	3.72	0.74	IMAE	0.48	-0.30	0.18	-0.30	0.75
2	0.73	0.39	0.15	4.44	0.89	Cons_Combust.	0.48	-0.22	0.26	0.80	-0.14
3	0.34	0.20	0.07	4.78	0.96	Cons_Energ.	0.49	-0.15	0.22	-0.52	-0.64
4	0.14	0.06	0.03	4.92	0.98	Q_Cmt	0.44	0.08	-0.89	0.04	-0.03
5	0.08	---	0.02	5.00	1.00	Per_Const	0.32	0.91	0.24	0.01	0.11
Sector Externo											
Eigenvalues: (Sum = 5, Average = 1)						Eigenvectors (loadings):					
1	4.08	3.63	0.82	4.08	0.82	Export	0.46	-0.16	-0.48	0.73	0.00
2	0.45	0.18	0.09	4.53	0.91	IP_Comb	0.40	0.84	0.32	0.14	-0.12
3	0.27	0.15	0.05	4.80	0.96	IPX	0.47	-0.28	0.01	-0.35	-0.76
4	0.12	0.04	0.02	4.92	0.98	ITCER	0.44	-0.42	0.68	0.08	0.40
5	0.08	---	0.02	5.00	1.00	Import	0.46	0.12	-0.46	-0.56	0.50
Sector Monetario											
Eigenvalues: (Sum = 4, Average = 1)						Eigenvectors (loadings):					
1	3.19	2.75	0.80	3.19	0.80	Fluj_Prest	0.46	-0.81	0.35	0.11	
2	0.44	0.11	0.11	3.63	0.91	M1	0.52	0.49	0.25	0.66	
3	0.33	0.29	0.08	3.96	0.99	TAON	-0.48	0.10	0.87	-0.02	
4	0.04	---	0.01	4.00	1.00	Depos_A&P	0.54	0.31	0.25	-0.75	
Sector Fiscal											
Eigenvalues: (Sum = 3, Average = 1)						Eigenvectors (loadings):					
1	2.40	1.98	0.80	2.40	0.80	Imptos Indir	0.61	-0.01	-0.79		
2	0.42	0.24	0.14	2.82	0.94	Tasa Turis	0.56	-0.70	0.44		
3	0.18	---	0.06	3.00	1.00	Remun. Pub.	0.56	0.71	0.42		
Variables Internacionales											
Eigenvalues: (Sum = 3, Average = 1)						Eigenvectors (loadings):					
1	2.42	1.92	0.81	2.42	0.81	Remesas	0.61	-0.32	-0.73		
2	0.50	0.41	0.17	2.91	0.97	IPI_EUA	0.51	0.86	0.06		
3	0.09	---	0.03	3.00	1.00	IPC_EUA	0.60	-0.41	0.69		

Fuente: Elaboración propia

Gráfica 14: Evolución Indicadores Ponderados por Sector y sus Variaciones Interanuales



Fuente: Elaboración propia

8.1.9. Prueba de Raíz Estacional (Test de HEGY) para los Indicadores Ponderados por Sector

Tabla 18: Test de HEGY para los Indicadores Ponderados

Method: Traditional HEGY

Null Hypothesis: Unit root at specified frequency

Non-Seasonal Deterministics: Constant and trend

Periodicity (Seasons): 12

Lag Selection: 2 (Automatic: AIC, maxlags=12)

Sample Size: 243

Frecuencys	Test Stat.					Significance		Freq.	Ciclos
	SReal	SExt	SMon	SFis	VInt	5%	10%		
Frequency 0	-2.34	-2.21	-2.20	-2.74	-1.09	-3.36	3.08	0	0
Frequency 2PI/12 and 22PI/12	6.38	13.24	9.18	11.70	6.53	8.15	3.71	pi/6	1
Frequency 4PI/12 and 20PI/12	17.77	14.47	4.45	15.01	11.12	8.15	3.71	pi/3	2
Frequency 6PI/12 and 18PI/12	16.62	10.15	3.02	4.58	6.66	8.15	3.71	pi/2	3
Frequency 8PI/12 and 16PI/12	8.09	13.08	1.99	14.85	6.01	8.15	3.71	2pi/3	4
Frequency 10PI/12 and 14PI/12	1.05	6.61	3.85	12.01	2.27	8.15	3.71	5pi/6	5
Frequency PI	-2.59	-3.09	-2.43	-3.51	-4.06	-1.94	-1.62	pi	6
All seasonal frequencies	10.19	11.93	4.78	11.88	8.11	7.51	3.46		
All frequencies	10.28	12.33	4.75	13.59	7.50	7.31	3.60		

Fuente: Elaboración propia

Raíces estacionales significativas al 5%

8.1.10. Error Cuadrático Medio (MSE)

Tabla 19: Error Cuadrático Medio ($\widehat{PIB}_t - PIB_t$)² para el período 2018-2021

Trim	Escenario 1						Escenario 2						Escenario 3						Promedio Global	
	GETS-IIS_2	GETS-IIS	PDL/Almon	Step	MCO	Promedio Esc. 1	GETS-IIS_2	GETS-IIS	PDL/Almon	GETS-IIS_3	Step	MCO	Promedio Esc. 2	GETS-IIS_2	GETS-IIS	PDL/Almon	Step	MCO		Step_2
2018q1	1.926	2.086	3.807	0.670	0.095	2.011	0.052	0.490	4.538	0.096	1.596	1.955	0.020	0.114	0.002	3.244	0.100	0.517	0.670	0.060
2018q2	1.358	1.098	0.004	0.265	0.178	0.588	0.411	0.085	0.149	0.890	0.291	0.078	0.010	0.020	0.007	0.290	0.281	1.203	0.358	0.035
2018q3	0.005	0.012	1.587	0.737	0.229	0.085	0.060	0.879	0.209	1.511	1.990	0.875	0.558	0.160	0.216	0.969	2.842	0.131	1.085	0.314
2018q4	0.387	0.306	0.036	0.227	0.184	0.235	0.333	0.499	0.191	0.635	0.152	0.081	0.291	0.049	0.207	1.647	0.270	2.455	0.207	0.179
2019q1	0.600	0.715	0.212	1.139	0.422	0.545	0.016	0.166	0.494	0.817	0.168	1.196	0.054	0.027	0.407	0.290	4.590	0.195	1.215	0.002
2019q2	2.621	2.916	3.650	5.568	0.055	2.846	0.327	1.584	0.620	0.306	3.663	0.002	0.700	0.008	0.004	1.523	0.394	0.285	4.935	0.102
2019q3	0.618	0.450	0.006	0.050	0.011	0.251	0.435	0.001	0.172	0.266	0.072	0.003	0.010	0.595	0.054	0.060	0.023	0.261	0.205	0.111
2019q4	0.001	0.014	0.122	0.001	0.242	0.000	0.234	0.042	1.121	0.058	0.020	0.242	0.144	0.068	0.395	0.339	0.047	0.109	0.112	0.012
2020q1	0.000	0.000	0.716	1.953	0.767	0.051	0.013	0.002	0.018	0.001	0.000	3.069	0.002	0.240	0.010	0.037	0.015	0.402	1.353	0.026
2020q2	4.489	4.487	3.191	2.656	6.298	3.209	4.402	4.468	2.320	4.472	3.076	0.459	3.837	3.448	4.439	4.389	3.612	1.746	2.077	3.631
2020q3	0.494	0.433	1.032	6.394	0.261	0.722	0.052	0.054	0.422	0.023	1.597	0.828	0.140	0.174	0.109	0.043	1.241	0.278	0.725	0.195
2020q4	0.113	0.117	0.279	19.674	0.000	0.018	0.115	0.111	0.149	0.088	0.296	0.993	0.042	0.096	1.097	0.200	0.303	0.871	0.007	0.185
2021q1	0.040	0.085	0.092	8.289	29.052	0.429	0.438	0.271	0.001	0.000	0.021	9.798	0.228	0.027	0.008	0.001	0.099	2.958	0.008	0.000
MSE	0.973	0.978	1.134	3.663	2.907	0.845	0.530	0.666	0.800	0.705	0.996	1.506	0.464	0.387	0.535	1.002	1.063	0.878	0.997	0.373

Fuente: Elaboración propia

8.1.11.combinación de Pronósticos, Modelos MIDAS

Tabla 20: Combinación de Pronósticos de cada Escenario y Modelos

Trim	MSE	1/MSE	Pond. 1 ^{1/}	Pond. 2	Escenario 1										Escenario 2										Escenario 3										Media Pond Global.
					GETS-IIS_2		PDI/Almon		Step		MCO		Promedio Esc. 1		GETS-IIS_2		PDI/Almon		Step		MCO		Promedio Esc. 2		GETS-IIS_2		PDI/Almon		Step		MCO		Promedio Esc. 3		
					GETS-IIS_2	PDI/Almon	Step	MCO	Promedio Esc. 1	GETS-IIS_2	PDI/Almon	Step	MCO	Promedio Esc. 1	GETS-IIS_2	PDI/Almon	Step	MCO	Promedio Esc. 2	GETS-IIS_2	PDI/Almon	Step	MCO	Promedio Esc. 2	GETS-IIS_2	PDI/Almon	Step	MCO	Promedio Esc. 3	GETS-IIS_2	PDI/Almon	Step	MCO	Promedio Esc. 3	
2018q1	2.85	10.6974	34.0%	3.9%	0.0935	10.4727	33.3%	2.3%	0.1422	0.5728	0.6508	2.54	3.67	4.27	3.08	2.15	4.98	2.54	4.12	1.45	2.99	3.19	2.81	4.65	2.54	2.13	3.10	3.21							
2018q2	4.10	10.4727	33.3%	3.8%	0.0955	7.0308	1.7457	1.5365	0.1422	1.7457	1.5365	4.52	3.58	3.33	4.74	4.39	4.48	3.15	3.56	4.38	4.20	3.96	4.02	3.56	3.00	3.50	3.97								
2018q3	3.95	10.4727	33.3%	3.8%	0.0955	7.0308	1.7457	1.5365	0.1422	1.7457	1.5365	3.47	3.09	3.65	3.70	3.01	3.49	2.72	2.54	3.01	3.20	3.55	3.48	2.96	3.58	2.90	3.37								
2018q4	4.46	10.4727	33.3%	3.8%	0.0955	7.0308	1.7457	1.5365	0.1422	1.7457	1.5365	4.03	3.98	3.97	3.88	3.75	4.02	3.66	4.85	4.17	3.92	4.24	4.00	3.17	2.89	4.91	4.01								
2019q1	2.96	10.4727	33.3%	3.8%	0.0955	7.0308	1.7457	1.5365	0.1422	1.7457	1.5365	3.61	4.03	3.70	2.83	3.37	2.26	3.87	3.37	4.06	3.20	2.80	2.32	3.50	3.40	4.06	3.12								
2019q2	1.69	10.4727	33.3%	3.8%	0.0955	7.0308	1.7457	1.5365	0.1422	1.7457	1.5365	1.93	4.05	3.38	2.27	2.95	2.48	2.25	3.61	1.73	2.53	1.79	1.76	2.93	2.23	3.92	2.01								
2019q3	3.33	10.4727	33.3%	3.8%	0.0955	7.0308	1.7457	1.5365	0.1422	1.7457	1.5365	3.23	3.56	2.83	3.99	3.30	2.92	2.82	3.60	3.39	3.43	2.56	3.56	3.09	2.82	2.88	3.15								
2019q4	2.62	10.4727	33.3%	3.8%	0.0955	7.0308	1.7457	1.5365	0.1422	1.7457	1.5365	3.11	2.64	2.62	3.11	2.83	3.68	2.86	2.48	3.11	3.00	2.36	3.25	3.20	2.29	2.96	2.83								
2020q1	-1.33	10.4727	33.3%	3.8%	0.0955	7.0308	1.7457	1.5365	0.1422	1.7457	1.5365	-0.45	-2.72	-1.55	-1.44	-1.37	-1.19	-1.30	-1.32	0.43	-1.29	-0.84	-1.42	-1.52	-0.69	-2.49	-1.26								
2020q2	-19.20	10.4727	33.3%	3.8%	0.0955	7.0308	1.7457	1.5365	0.1422	1.7457	1.5365	-16.69	-20.83	-20.99	-21.30	-21.31	-20.72	-21.31	-20.95	-19.88	-21.16	-21.06	-21.31	-21.29	-20.52	-20.64	-21.21								
2020q3	-7.89	10.4727	33.3%	3.8%	0.0955	7.0308	1.7457	1.5365	0.1422	1.7457	1.5365	-8.40	-10.42	-8.74	-8.12	-8.12	-8.54	-8.04	-9.16	-8.80	-8.27	-8.31	-8.22	-8.10	-8.42	-8.74	-8.40								
2020q4	-7.78	10.4727	33.3%	3.8%	0.0955	7.0308	1.7457	1.5365	0.1422	1.7457	1.5365	-7.80	-3.35	-7.65	-8.12	-8.12	-8.17	-8.08	-7.24	-6.79	-7.99	-8.09	-8.83	-8.23	-6.85	-7.86	-8.11								
2021q1	1.23	10.4727	33.3%	3.8%	0.0955	7.0308	1.7457	1.5365	0.1422	1.7457	1.5365	-4.16	-1.64	0.58	0.57	0.71	1.27	1.23	1.09	-1.90	0.76	1.40	1.33	1.26	-0.49	1.32	1.00								
2021q2	12.86	10.4727	33.3%	3.8%	0.0955	7.0308	1.7457	1.5365	0.1422	1.7457	1.5365	6.15	7.04	3.34	15.67	18.18	8.30	8.33	3.19	15.95	12.89	24.06	4.69	6.91	19.09	5.85	12.86								

Fuente: Elaboración propia

^{1/} La Ponderación 1 corresponde al peso de cada MSE dentro de cada escenario de pronóstico.

^{2/} La Ponderación 2 corresponde al peso de cada MSE, respecto a todos los modelos MIDAS estimados

8.1.12. Prueba de Diebold y Mariano, desarrollo Algebraico

Dado la trayectoria de la variable d , definida como el diferencial de perdidas entre el modelo 1 y 2, los resultados estándar pueden usarse para deducir la distribución asintótica de d . Con media (poblacional) $\mu = 0$ y varianza $2\pi f_d(0)$; primero definiremos el promedio de la muestra analizada:

$$\bar{d} = \frac{1}{N} \sum_{t=1}^N [g(e_{it}) - g(e_{jt})] \quad (38)$$

Y la varianza que sigue una función de densidad espectral a frecuencia 0, que representa la autocovarianza del diferencial de pérdidas y es modelada por:

$$f_d(0) = \frac{1}{2\pi} \sum_{\tau=-\infty}^{\infty} E[(d_t - \mu)(d_{t-\tau} - \mu)] \quad (39)$$

En muestras grandes la media muestral (\bar{d}) se distribuye normalmente con $N(0,1)$; es así que para el testeo de la H_0 de la ecuación 35, Diebold y Mariano (1995), plantearon el siguiente estadístico:

$$DM = \frac{\bar{d}}{\sqrt{\frac{2\pi \hat{f}_d(0)}{N}}} \quad (40)$$

Donde $\hat{f}_d(0)$ muestral es el estimador de $f_d(0)$ poblacional y será la varianza de los datos muestrales, tal que:

$$2\pi \hat{f}_d(0) = \frac{1}{N} \sum_{\tau=-(N-1)}^{N-1} (d_t - \bar{d}_t)(d_{t-\tau} - \bar{d}_t) \quad (41)$$

Tabla 21: Test de DM, Escenario 3

	GETS-IIS_2	GETS-IIS	PDL/Almon	Step	MCO	Step_2
GETS-IIS_2		-0.5514	1.7994	1.8073	2.6267	1.9390
		0.2907	0.0360	0.0354	0.0043	0.0263
GETS-IIS	0.5514		2.0068	1.7806	2.6910	2.0846
	0.2907		0.0224	0.0375	0.0036	0.0186
PDL/Almon	-1.7994	-2.0068		0.2955	0.3946	0.5834
	0.0360	0.0224		0.3838	0.3466	0.2798
Step	-1.8073	-1.7806	-0.2955		0.0142	0.1541
	0.0354	0.0375	0.3838		0.4943	0.4388
MCO	-2.6267	-2.6910	-0.3946	-0.0142		0.1381
	0.0043	0.0036	0.3466	0.4943		0.4451
Step_2	-1.9390	-2.0846	-0.5834	-0.1541	-0.1381	
	0.0263	0.0186	0.2798	0.4388	0.4451	

Fuente: Elaboración propia

La Hipótesis Nula es $H_0 = ei = ej$

Nota 1: Los valores en negrita corresponde a los Test DM

Nota 2: Los valores en rojo corresponde a los **p_value** del Estadístico DM

Nota 3: Si los **p_value** son mayores a 0.05 y 0.1, a estos niveles de significancia el pronóstico i es estadísticamente igual al pronóstico j .

Tabla 22: Test de DM, Escenario 2

	GETS-IIS_2	GETS-IIS	GETS-IIS_3	PDL/Almon	Step
GETS-IIS_2		0.9627	1.1812	1.3741	2.1036
		0.1678	0.1188	0.0847	0.0177
GETS-IIS	-0.9627		0.1992	1.0541	2.7102
	0.1678		0.4210	0.1459	0.0034
GETS-IIS_3	-1.1812	-0.1992		0.8899	1.6479
	0.1188	0.4210		0.1868	0.0497
PDL/Almon	-1.3741	-1.0541	-0.8899		0.3790
	0.0847	0.1459	0.1868		0.3524
Step	-2.1036	-2.7102	-1.6479	-0.3790	
	0.0177	0.0034	0.0497	0.3524	

Fuente: Elaboración propia

Tabla 23: Test de DM, Escenario 1

	GETS-IIS_2	GETS-IIS	PDL/Almon	Step
GETS-IIS_2		0.3473	1.2861	1.6121
		0.3642	0.0992	0.0535
GETS-IIS	-0.3473		1.3613	1.6082
	0.3642		0.0867	0.0539
PDL/Almon	-1.2861	-1.3613		1.4841
	0.0992	0.0867		0.0689
Step	-1.6121	-1.6082	-1.4841	
	0.0535	0.0539	0.0689	

Fuente: Elaboración propia

8.1.13. Datos Desestacionalizados

En los datos de coyuntura económica, como las de las CNT, el enfoque analítico se hace sobre las series ajustadas por estacionalidad y efectos del calendario, tal y como se presentan los resultados en el informe del PIBT. En el presente documento, la obtención de los datos desestacionalizados del trimestre pronosticado, se realizará utilizando el factor estacional proyectado proporcionado por las CNT.

Los cálculos del Nowcasting para Honduras se realizaron con las series originales, para derivar series ajustados por estacionalidad, se utilizó el principio fundamental que subyace el análisis univariado de series de temporales y extracción de señales, una serie se puede descomponer en componentes no observables, siguiendo la siguiente ecuación:

$$Y_t = T_t + C_t + S_t + I_t \quad (42)$$

En donde T_t, C_t, S_t y I_t designan respectivamente, la tendencia, el ciclo, la estacionalidad y lo irregularidad a lo largo del período de tiempo, Ladiray y Quenneville (2000-2001). Estos componentes se combinan siguiendo los esquemas de composición aditivos o multiplicativos:

$$\text{Esquema Aditivo} = Y_t = T_t + C_t + S_t + I_t \quad (43)$$

$$\text{Esquema Multiplicativo} = Y_t = T_t * C_t * S_t * I_t \quad (44)$$

En el modelo multiplicativo la serie desestacionalizada se obtiene de la siguiente manera:

$$SA_t = Y_t/S_t \quad (45)$$

Una serie desestacionalizada implícitamente contiene movimientos motivados por la tendencia-ciclo y la irregularidad, y excluye las fluctuaciones periódicas intra-anual derivadas de patrones estacionales que se repiten todos los años y efectos relacionados con el calendario, como la semana santa, feriados y días trabajados (trading day).

Si reordenamos la ecuación 45, el factor estacional es el cociente:

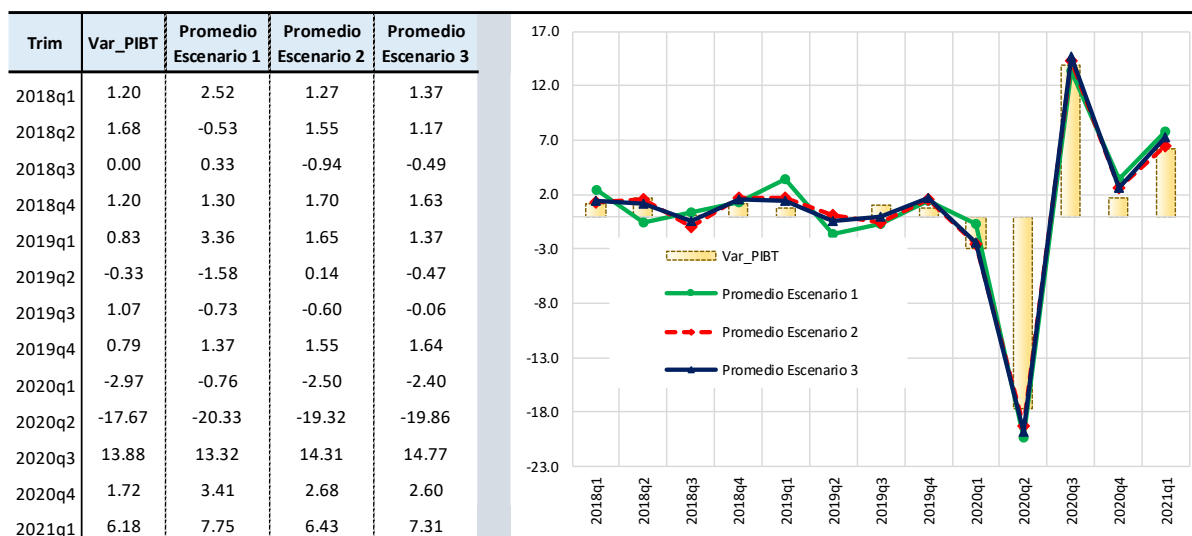
$$S = SA_t/Y_t \quad (46)$$

Al aplicar a la serie original del PIBT el Factor Estacional, se obtiene la serie desestacionalizada, a la cual, para el análisis coyuntural, calcularemos las variaciones trimestrales:

$$\text{Var} - \text{Trim} = \left(\left(\frac{PIBT_t}{PIBT_{t-1}} \right) - 1 \right) * 100 \quad (47)$$


Para el período 2018-2021, las variaciones trimestrales de las series ajustadas estacionalmente se presentan a continuación:

Tabla 24 y Gráfica 15: Series Destacionalizadas, PIBT Real y Promedios de Combinación de Pronósticos (Variaciones Trimestrales) y sus MSE



Fuente: Elaboración propia

Gráfica 16: Factor Estacional del PIBT = Serie Desestacionalizada/Serie Original



Fuente: Elaboración propia

8.1.14. Prueba de Diebold y Mariano a los promedios de Pronósticos

Tabla 25: Test de DM, para los Promedios de Pronósticos de cada Escenario

	Escenario 1	Escenario 2	Escenario 3
Escenario 1		1.9609 0.0499	2.1000 0.0470
Escenario 2	-1.9609 0.0499		1.7587 0.0786
Escenario 3	-2.1000 0.0470	-1.7587 0.0786	

Fuente: Elaboración propia

9. Bibliografía

Armesto, M., Engemann, K., & Owyang, M. (December 2010). Forecasting with Mixed Frequencies. Federal Reserve Bank of St. Louis *Review*. (pp. 521-36).

<https://files.stlouisfed.org/files/htdocs/publications/review/10/11/Armesto.pdf>

Alonso, J. & Semaán P. (junio 2010). Prueba de HEGY en R: Una guía. (Apuntes de Economía No. 23). Universidad Icesi. <https://www.icesi.edu.co/departamentos/economia/images/hegy.pdf>

Banco Central de Honduras. Calendario de Divulgación de Información Económica y Financiera. <https://www.bch.hn/estadisticos/GIE/LIBCalendario%20PDF/Calendario%20de%20Divulgaci%C3%B3n%20de%20Informaci%C3%B3n%20Econ%C3%B3mica%20y%20Financiera.pdf>

Barhoumi, K., Antipa, P., Brunhes-Lesage, V., & Olivier Darné. (October 2012). Nowcasting german GDP: A Comparison of Bridge and Factor Models. (Document de Travail N° 401). Banque de France. https://publications.banque-france.fr/sites/default/files/medias/documents/working-paper_401_2012.pdf

Barhoumi, K., Darne, O., Ferrara L., & Pluyaud, B. (2011). Monthly GDP Forecasting Using Bridge Models: Application for the French Economy. *Bulletin of Economic Research* (Volume 64). (Pp. s53-s70) <https://onlinelibrary.wiley.com/doi/full/10.1111/j.1467-8586.2010.00359.x>

Bok, B., Caratelli, D., Giannone, D., Sbordone, A., & Tambalotti, A. (November 2017). Macroeconomic Nowcasting and Forecasting with Big Data. (Staff Report No. 830). Federal Reserve Bank of New York. https://www.newyorkfed.org/medialibrary/media/research/staff_reports/sr830.pdf

Clements, M., & Harvey, D. (2010). Forecast Encompassing tests and probability Forecasts. *Journal of Applied Econometrics*, 25(6), 1028-1062. from <http://www.jstor.org/stable/40865276>

Cobb, M., & Peña, P. (abril 2020). Proyecciones de corto plazo para el PIB trimestral: Desempeño reciente de una serie de modelos estándar. (Working Paper, No. 871). Banco Central de Chile. <https://www.bcentral.cl/contenido/-/detalle/documento-de-trabajo-n-871>

D'Amato, L., Garegnani, L., & Blanco, E. (2015) Nowcasting de PIB: Evaluando las condiciones cíclicas de la economía argentina. (Working Paper, No. 2015/69). Banco Central de La Republica de Argentina. <http://bcra.gob.ar/Institucional/Resumen.asp?id=1017&prevPage=1>

Diebold, F., & Lopez, J. (March 1996). Forecast and Evaluation Combination. (Working Paper No. 192). National Bureau of Economic Research. https://www.nber.org/system/files/working_papers/t0192/t0192.pdf

Diebold, F., & Mariano, R. (1995). Comparing Predictive Accuracy. *Journal of Business & Economic Statistics*, 13(3), 253-263. doi:10.2307/1392185 from <https://www.jstor.org/stable/1392185>

Gálvez-Soriano, O. (2018). Nowcasting del PIB de México usando Modelos de Factores y Ecuaciones Puente. (Working Paper, No. 2018-06). Banco de México. <https://www.banxico.org.mx/publicaciones-y-prensa/documentos-de-investigacion-del-banco-de-mexico/%7BD88CC75C-2CF7-F3F5-5BFA-D0B9BE3D75C6%7D.pdf>

Ghysels, E., Sinko, A., & Valkanov, R. (February 2006). Midas Regressions: Further Results and New Directions. <https://dx.doi.org/10.2139/ssrn.885683>

Ghysels, E., Kvedaras, V., & Zemlys V. (August 2016). Mixed Frequency Data Sampling Regression Models: The R Package midasr. *Journal of Statistical Software* (Volume 72).
<https://www.jstatsoft.org/article/view/v072i04>

Hair, J., Anderson, R., Tatham, R., & Black, W. (1999). *Análisis Multivariante* (Vol. 491). Madrid: Prentice Hall.

Higgins, P. (July 2014). GDPNow: A Model for GDP “Nowcasting” (Working Paper 2014-7). Federal Reserve Bank Of Atlanta. <https://www.atlantafed.org/-/media/documents/research/publications/wp/2014/wp1407.pdf>

Hylleberg, S., Engle, R., Granger, C., & Yoo, B. (1990). Seasonal integration and cointegration. *Journal of Econometrics* (Vol. 44(1-2)). (pp 215-238).

Ladiray, D., & Quenneville, B. (2000-2001). *Methodologica*. Desestacionalizar con el Método X-11. Laboratoire de Méthodologie du Traitement des Données. Université Libre de Bruxelles.

Lutkepohl, H., & Kratzig, M. (2004). *Applied Times Series Econometrics*. Cambridge University Press

Pesaran, M., & Pick, A. (2011). Forecast Combination Across Estimation Windows. *Journal of Business & Economic Statistics*, 29(2), 307-318. Retrieved August 9, 2021, from <https://www.jstor.org/stable/25800802>

Peña, D. (2002). *Análisis de datos Multivariantes*. McGraw-Hill Interamericana de España S.L.; 1er edición.

Mendieta, W. (2017). Esquema de proyecciones de corto plazo del PIB usando modelos de frecuencia mixta. (DT-051). Banco Central de Nicaragua. https://www.bcn.gob.ni/system/files/force/documentos/DT-51_Esquema_de_proyecciones_de_corto_plazo.pdf?download=1

Stock, J., & Watson, M. (2004). Combination Forecasts of Output Growth in a Seven-Country Data Set. *Journal of Forecasting*. J. Forecast. 23. (pp.405-430).
https://www.princeton.edu/~mwatson/papers/Stock_Watson_JoForc_2004.pdf

Timmermann., A. & Pesaran, H. (2007). Selection of Estimation Window in the Presence of Breaks. *Journal of Econometrics*. (pp.134-161)
<http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.153.2619>

Vargas, A. (2014). Pronóstico del crecimiento trimestral de Costa Rica mediante modelos de Frecuencia Mixta. *Revista de Ciencias Económicas* (Vol. 32 Núm. 2).
<https://revistas.ucr.ac.cr/index.php/economicas/article/view/17267>