



UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO
FACULTAD DE ECONOMÍA

**Monitoreo de la actividad económica en tiempo real: Propuesta
de un Indicador Semanal de la Actividad Económica Mexicana**

TESIS

**QUE PARA OBTENER EL TÍTULO DE
LICENCIADA EN ECONOMÍA**

**PRESENTA:
LUZ GABRIELA OROZCO NAVARRO**

**DIRECTOR DE TESIS:
DR. GERARDO ESQUIVEL HERNÁNDEZ**

CIUDAD DE MÉXICO, 2023





Universidad Nacional
Autónoma de México

Dirección General de Bibliotecas de la UNAM

Biblioteca Central



UNAM – Dirección General de Bibliotecas
Tesis Digitales
Restricciones de uso

DERECHOS RESERVADOS ©
PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL

Todo el material contenido en esta tesis esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

Agradecimientos

Agradezco a todas las personas que me han acompañado en este camino,
especialmente a mis padres.

Índice

I. Introducción	6
II. Modelos de Factores y Pronósticos	10
III. Datos.....	14
IV. Modelo de Factores	21
Análisis Factorial Dinámico.....	26
Análisis de Componentes principales (PCA).....	28
Estimación del número de factores	31
El modelo de factores.....	34
V. Resultados empíricos.....	42
VI. Conclusiones	47
Referencias	49
ANEXO A: Revisión de Literatura	53
ANEXO B: Contrucción de un indicador semanal que mida la evolución de los precios.....	66

Monitoreo de la actividad económica en tiempo real: Propuesta de un Indicador Semanal de la Actividad Económica Mexicana

I. Introducción

El comportamiento de la actividad económica mundial, a partir de 2020, se vio afectado, principalmente, por los choques derivados de la pandemia y del conflicto bélico entre Rusia y Ucrania. En este contexto, el PIB de México presentó una fuerte contracción en el segundo trimestre de 2020 como consecuencia de las medidas adoptadas para contener la crisis sanitaria, así como por la debilidad de la economía global y por las interrupciones en las cadenas globales de valor. De esta forma, después de una significativa caída del producto, a finales de 2020 el PIB comenzó a recuperarse y continuó con este comportamiento en los siguientes años, alcanzando, hasta el tercer trimestre de 2022, los niveles de crecimiento previos a la emergencia sanitaria. Ante la compleja coyuntura presentada por estos choques y un entorno de elevada incertidumbre, el monitoreo y la medición de los principales indicadores económicos –particularmente del PIB– junto con el rezago natural en su publicación, representaron mayores retos para la generación de información económica en un momento clave para la toma de decisiones.

Por su parte, en los últimos años, el creciente volumen de datos en tiempo real ha generado nuevos retos en el uso de metodologías que se adapten a este nuevo entorno y que permitan aprovechar, gestionar y optimizar el uso de esta información. Bajo este contexto, el presente trabajo tiene como objetivo evaluar si es posible conocer el estado de la actividad económica utilizando información oportuna en un modelo de factores.

Dentro de la literatura se han propuesto diferentes métodos econométricos para trabajar en este nuevo entorno de datos. Entre las diferentes metodologías propuestas, los basados en el Análisis Factorial han crecido significativamente y han demostrado ser muy útiles en el análisis y pronóstico macroeconómico. En particular, estos modelos suelen utilizarse para resumir, en un pequeño número de factores, información contenida en un gran número de series. A su vez, estas herramientas pueden ayudar a predecir el comportamiento de variables relevantes y útiles como el PIB, que, como ya se mencionó se publican con cierto rezago por la complejidad de su estimación. Ante el contexto económico descrito, el uso de estas herramientas permite agilizar la toma de decisiones aprovechando los datos de alta frecuencia correlacionados con la actividad económica y, de esta forma, conocer una imagen más actualizada de la situación económica del país.

Existen diferentes técnicas de reducción de los factores que permiten capturar la varianza de las variables en un conjunto más pequeño. La diferencia entre estas depende de la forma en que se extraen los factores de las series y del cálculo del componente común. Recientemente, una creciente literatura ha puesto énfasis en los métodos de Componentes Principales (CP), Modelos de Factores Dinámicos (MFD) y métodos híbridos como una herramienta para estimar los factores latentes. Estas técnicas han resultado útiles para sintetizar información de variables observadas en diferentes frecuencias y recientemente su uso se ha extendido para la incorporación de técnicas de *nowcasting* (o estimación actual) y pronósticos de la actividad económica.

A continuación, y con el fin de complementar el análisis que se ha documentado, en este trabajo se describen las métricas mencionadas con el propósito de implementarlas en el

modelo y construir un indicador dinámico oportuno y confiable de la actividad económica mexicana.

Para lograr tal objetivo, se realizó una revisión de las variables de alta frecuencia que pudieran explicar el comportamiento de la actividad económica en México. Después, se ocupó la metodología de MFD para reducir la dimensión del conjunto a 5 factores facilitando su uso en la construcción del indicador semanal final. Una vez calculados los factores, a través del uso de componentes principales, se estimaron los pesos relativos de cada factor subyacente y se construyó un indicador de la actividad económica con frecuencia semanal.

En particular, al utilizar esta clase de modelos, se encontró el potencial de las variables seleccionadas para construir un indicador oportuno que describa el comportamiento general de la actividad económica agregada en México. De manera que, una vez aplicada la metodología descrita en la sección 4, el factor estimado explica poco más del 80 por ciento de la variación del conjunto seleccionado. Además, los resultados encontrados del modelo de nowcasting, presentan una correlación alta entre el factor dinámico semanal y el IGAE, además de un factor de ajuste de 0.8.

Los resultados obtenidos en este trabajo son consistentes con la literatura sobre indicadores oportunos para describir el comportamiento de la economía en México a través de Modelos de Factores. En este trabajo se hacen dos contribuciones a estos estudios. Por un lado, se presenta un indicador con frecuencia semanal, a diferencia de las estadísticas oficiales oportunas con frecuencias mensuales. Una consecuencia importante de esto es el ahorro de tiempo que esto implica para los hacedores de política y agentes económicos en la toma de decisiones de muy corto plazo. Por otro lado, utiliza datos que no han sido parte de los análisis

anteriores, por ejemplo, en este trabajo se incorporan variables de movilidad en el transporte público, de operaciones financieras y series proveídas a través del uso de aplicaciones.

Lo que resta del documento se organiza de la siguiente manera. En la sección 2 se presenta una breve revisión de la literatura de los Modelos de Factores y Pronósticos¹. En la Sección 3 se describen las variables seleccionadas y su transformación. En la sección 4 se definen las principales técnicas estadísticas multivariantes, se presentan las métricas utilizadas para calcular el número de factores dinámicos y se detalla la implementación del modelo a partir del cual se calcula el indicador semanal de la actividad económica para el caso de México. La sección 5 se centra en los resultados empíricos y se muestran los resultados de una estimación de tipo *nowcasting*. Finalmente, la sección 6 proporciona las conclusiones del trabajo.

¹ Para ver más detalle de la revisión de literatura consultar el Anexo A.

II. Modelos de Factores y pronósticos

El análisis factorial es una técnica estadística de reducción de dimensiones que permite concentrar las variaciones de un conjunto de variables. Este método fue introducido por Charles Spearman en 1904 para describir las capacidades cognitivas de un individuo a través de un factor no observable. Sin embargo, su aplicación en materia económica fue propuesta hasta 1946 por Burns y Mitchell, quienes notaron que el movimiento coordinado de las series de diferentes actividades económicas puede vincularse al ciclo económico.

Las primeras aplicaciones en macroeconomía de los MFD fueron desarrolladas por Geweke (1977) y Sargent y Sims (1977), el primero propuso a través de un modelo exploratorio determinar el número de factores latentes comunes que subyacen en variables económicas de corte transversal; los segundos a través de un modelo de dominio de frecuencia mostraron que dos factores dinámicos explicaban la varianza de algunas variables macroeconómicas como la producción, empleo y precios.

Los primeros modelos factoriales fueron desarrollados para un pequeño número de variables con movimientos comunes. Estos estudios clásicos, en su forma más simple, fueron representados de forma estática; en ellos se consideraba que la relación entre los factores y las variables es lineal con pesos que permanecen constantes en el tiempo Anderson (1984) y Bartholomew (1987). Posteriormente, esta versión tradicional de pequeña dimensión se adaptó a una versión exacta con dinámica temporal, como proponen Shumway y Stoffer (1982), Watson y Engle (1983), y Stock y Watson (1998a). A diferencia de las anteriores, esta versión en su forma de espacio-estado se puede estimar por máxima verosimilitud. Una

ventaja del dominio del tiempo sobre el dominio de la frecuencia es la facilidad de estimar los valores del factor latente utilizando el filtro de Kalman.

En las primeras versiones, la identificación de factores requería suposiciones estrictas principalmente por dos razones. Por un lado, la baja disponibilidad de datos limitaba la cantidad de variables y estas excedían el número de periodos de tiempo. La desventaja de este enfoque era la pérdida de información por la restricción de variables. Por otro lado, los estudios se basaban en el supuesto de que no había correlación cruzada entre los componentes idiosincrásicos.

El incremento en la disponibilidad de datos ha permitido responder a algunas de estas limitaciones y, de esta forma, trabajar con supuestos menos estrictos. En este contexto, Chamberlain y Rothschild (1983) introducen el concepto de estructura factorial "aproximada" que tiene como característica principal permitir que los errores idiosincrásicos estén débilmente correlacionados. De acuerdo con estos autores, los errores en la estructura del componente idiosincrásico desaparecen conforme aumenta el número de observaciones, mientras se cumplan las siguientes dos condiciones: i) que la correlación cruzada de los procesos idiosincrásicos sea relativamente pequeña y ii) que los componentes comunes aumenten conforme se incrementa el número de observaciones. Algunos ejemplos de los modelos de factores aproximados se encuentran en Forni y Reichlin (2005), Stock y Watson (1998), Bai y Ng (2002) y Forni et al. (2007). Estos estudios sugirieron utilizar el análisis de componentes principales (PCA) para estimar el modelo factorial estático aproximado. Los detalles de este enfoque se describen en la cuarta sección.

Uno de los planteamientos más comunes en la literatura es el enfoque en el dominio del tiempo desarrollado por Doz, Giannone y Reichlin (2011). En estos estudios se propone un

modelo de factor dinámico que se puede representar en forma de espacio-estado utilizando dos enfoques diferentes. El primero es el llamado enfoque de dos pasos, que inicialmente consiste en extraer los factores comunes a través de CP y después, dadas las condiciones iniciales, el modelo se escribe en forma de estado espacial y se aplica el filtro de Kalman para obtener las nuevas estimaciones de los factores. En su segundo enfoque Doz, Giannone y Reichlin (2011) modifican esta técnica al considerar la estimación de verosimilitud cuasi-máxima, donde las estimaciones de los factores se calculan iterativamente usando el suavizador de Kalman a través del algoritmo de Esperanza-Maximización (EM).

Por último, es importante mencionar investigaciones recientes que se han desarrollado como extensiones de los MFD con metodologías más flexibles. Con el objetivo de solucionar el problema de valores faltantes, que generalmente se encuentra en Modelos de Vectores Autorregresivos (VAR), Bernanke, Boivin y Elias (2005) proponen utilizar modelos VAR aumentados por factores (FAVAR). Estos modelos han sido aplicados dentro del análisis de política monetaria (por ejemplo, Giannone et al., 2008, y Favero et al., 2005).

Otros autores, de forma complementaria, se han inclinado por modelos factoriales con parámetros que varían en el tiempo –como contribuciones de cada variable a los factores–. Particularmente, estos modelos son útiles para evaluar si los comportamientos cambian en el transcurso del ciclo económico (por ejemplo, Motta, Hafner y von Sachs, 2011). Finalmente, para el caso de conjuntos de datos con frecuencias mixtas, se ha propuesto como enfoque alternativo el manejo de una regresión de muestreo mixto de datos (MIDAS) para explicar una variable de mayor frecuencia por variables con una periodicidad mayor.

Una de las principales limitaciones del uso de múltiples series macroeconómicas es la frecuencia con la que se publican los datos. Sin embargo, diferentes autores han propuesto

otras formas de adaptar los modelos para poder manejar simultáneamente las diferentes periodicidades. Por ejemplo, Mariano y Murasawa (2003), Aruoba, Diebold y Scotti (2007) y Camacho y Pérez-Quirós (2009, 2012). En el anexo A se incluye una revisión complementaria a la literatura presentada en esta sección.

III. Datos

Las variables macroeconómicas de un país tienden a compartir patrones e información que permite explicar el estado general de la economía. Para la construcción del MFD aplicado a la economía mexicana, se seleccionaron 48 variables representativas de la actividad económica para el periodo de enero de 2011 a diciembre de 2022. Las variables seleccionadas y sus principales características se muestran en la siguiente Tabla:

Tabla 1. Panel de variables seleccionadas para la construcción del Índice Semanal de Actividad Económica.

Variable	Breve descripción
Afluencia diaria del Metrobús en la Ciudad de México	Afluencia diaria por línea del Metrobús de la Ciudad de México.
Afluencia diaria del Metro en la Ciudad de México	Afluencia diaria por línea del Metro de la Ciudad de México.
Afluencia a zonas arqueológicas	Número de visitantes a museos en México.
Afluencia a museos	Número de visitantes a Zonas Arqueológicas en México.
Cierre IPC	Índice de precios de las acciones más grandes y líquidas listadas en la Bolsa Mexicana de Valores.
Hoteles en centros turísticos	Porcentaje de ocupación en hoteles y moteles por centro turístico. Incluye todas las categorías de hoteles.
Hoteles en corredores turísticos	Porcentaje de ocupación en hoteles y moteles por corredores turísticos. Incluye todas las categorías de hoteles.
IGAE	Indicador Global de la Actividad Económica que muestra la evolución mensual del sector real de la economía.

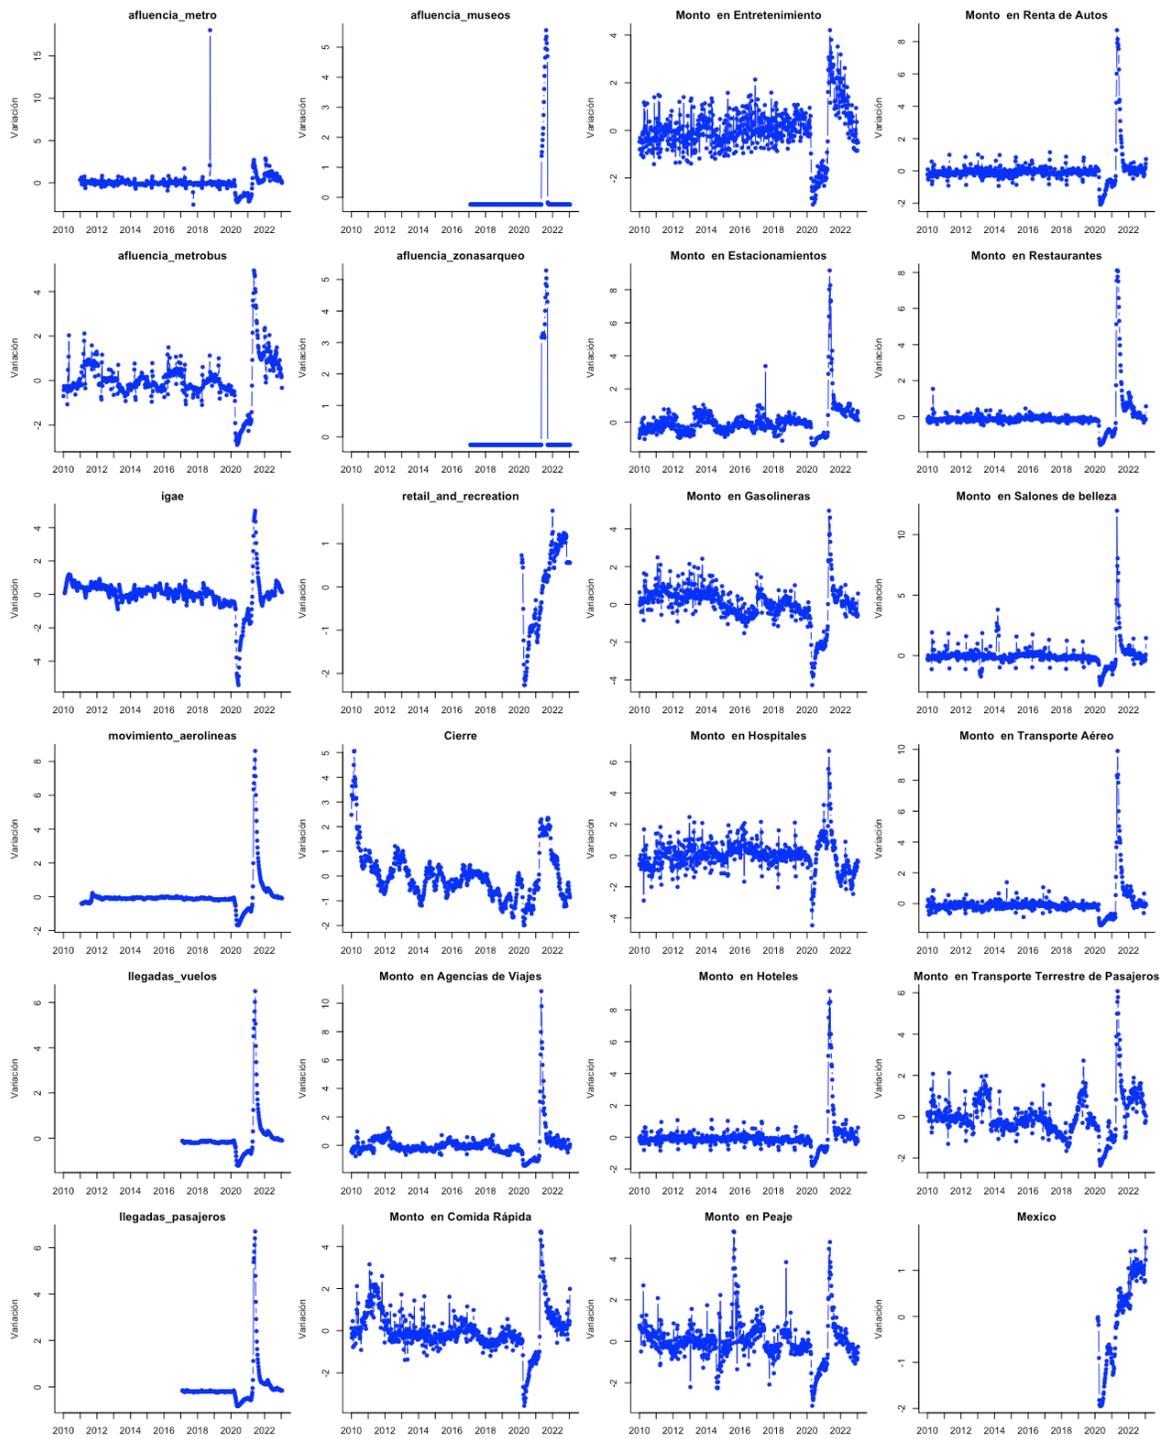
Variable	Breve descripción
Llegada de pasajeros	Volumen de llegadas de pasajeros transportados en los diferentes aeropuertos del país. Incluye pasajeros en vuelos nacionales e internacionales.
Llegada de vuelos	Volumen de llegadas de vuelos transportados en los diferentes aeropuertos del país. Incluye pasajeros en vuelos nacionales e internacionales.
Monto de operaciones	Conjunto de variables conformado por el monto de operaciones a través de tarjetas en transporte aéreo, agencias de viajes, comida rápida, entretenimiento, estacionamientos, gasolineras, hospitales, hoteles, peaje, renta de autos, restaurantes, salones de belleza y transporte terrestre de pasajeros.
Movimientos en aerolíneas	Flujo de pasajeros aéreos.
OpenTable	Mesas reservadas en restaurantes incluidos en la red de OpenTable a través de teléfono, en línea y de forma directa en Baja California Sur, Jalisco, México, Nuevo León y Quintana Roo.
Operaciones de tarjetas	Conjunto de variables conformado por el número de operaciones a través de tarjetas en transporte aéreo, agencias de viajes, comida rápida, entretenimiento, estacionamientos, gasolineras, hospitales, hoteles, peaje, renta de autos, restaurantes, salones de belleza y transporte terrestre de pasajeros.
Seated OpenTable	Variación de comensales sentados en restaurantes incluidos en la red OpenTable.
Retail and Recreation Google	Tendencias de movilidad de Google. Esta variable incluye el número de visitantes a parques y espacios al aire libre.

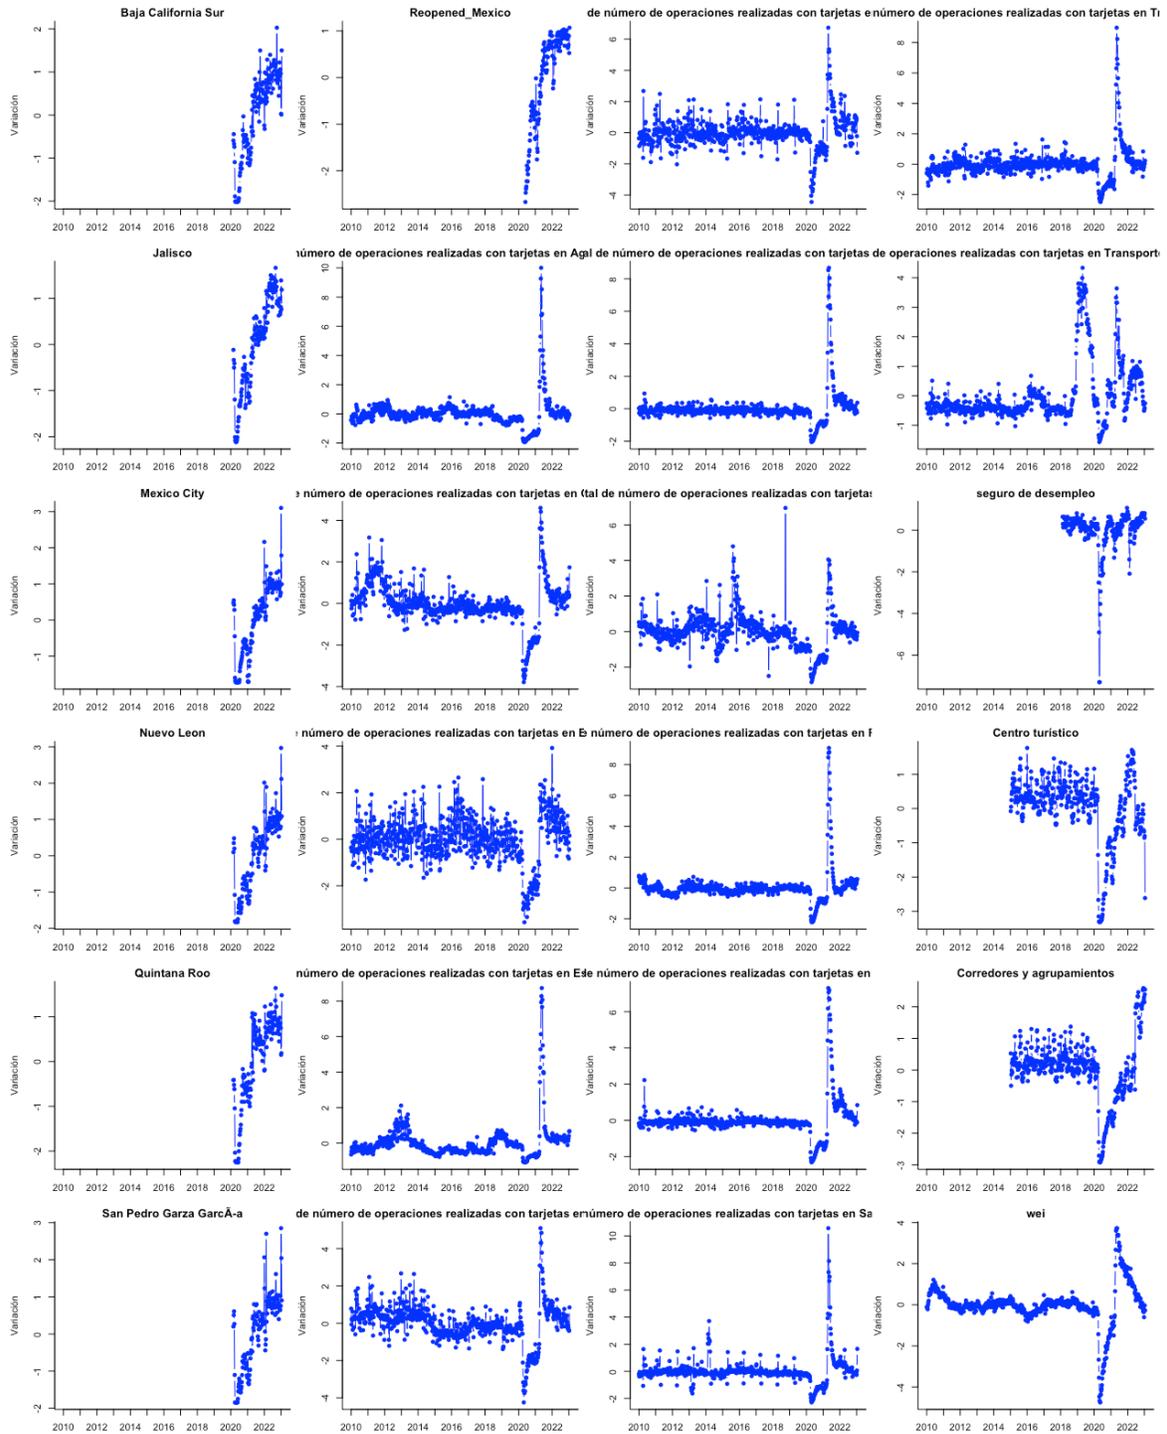
Variable	Breve descripción
Seguro de desempleo	Índice que refleja la búsqueda del término “seguro de desempleo” en Google por los usuarios.
WEI	Índice de actividad económica real que utiliza datos de alta frecuencia en Estados Unidos. Representa el componente común de series diarias y semanales que abarcan el comportamiento del consumidor, el mercado laboral y la producción.

Fuente: Elaboración propia con información de diversas fuentes.

Con el objetivo de mejorar la comparación entre variables y de ajustar las diferentes escalas, se estandarizaron las series originales. La Figura 1 presenta el comportamiento de las series seleccionadas de forma estandarizada.

Figura 1: Conjunto de series seleccionadas para describir la actividad económica.





Fuente: Elaboración propia con información de Banco de México, INEGI, OpenTable, Google Trends, SEMOVI, SECTUR y Reserva Federal de Nueva York.

Antes de estimar el número de factores y extraerlos, se realizaron diferentes transformaciones a las series de tiempo originales. Primero, en caso de ser necesario, se ajustaron las series a frecuencia semanal. Lo anterior, se hizo con el uso de interpolaciones lineales. De esta forma, fue posible crear un conjunto continuo de observaciones. Posteriormente, las variables expresadas en términos nominales se transformaron a cifras en términos reales. Este cálculo se llevó a cabo mediante una propuesta de indicador de inflación semanal estimado descrito en el Anexo B. Después, se eliminaron los factores estacionales a través del algoritmo STL² y, por último, se calcularon las variaciones porcentuales anuales de todas las series. A continuación, se presenta un resumen del tratamiento que se le dio a cada serie:

Tabla 2: Tabla resumen con el tratamiento a cada variable

Indicador	Frecuencia	Rezago de publicación	Tratamiento de variable
Afluencia diaria del Metrobús CDMX	Diaria	t-25	(D1)
Afluencia diaria del Metro CDMX	Diaria	t-25	(D1)
Afluencia a zonas arqueológicas	Mensual	t-60	(A1)
Afluencia a museos	Mensual	t-60	(A1)
Grupo de variables de operaciones con tarjetas	Diaria	t-7	(D1)
Grupo de variables de montos con tarjetas	Diaria	t-7	(D1, D2)
Llegada de pasajeros. y vuelos	Mensual	t-60	(A1, D1)
Movimientos en aerolíneas	Mensual	t-60	(A1, D1)
IGAE	Mensual	t-60	(A1, D1)
Weekly Economic Index	Semanal	t-1	(A1, D2)

² STL es un acrónimo de “Descomposición estacional y de tendencias con Loess”.

Indicador	Frecuencia	Rezago de publicación	Tratamiento de variable
Ocupación hotelera en corredores turísticos y agrupamientos	Semanal	t-20	(A1, D2)
Ocupación en hoteles y moteles por centro turístico	Semanal	t-15	(A1, D2)
Ingresos del Sistema de Transporte Colectivo Metro, por línea	Diaria	t-25	(D1, D2)
S&P/BMV IPC	Diaria	t-1	-
Open table	Diaria	t-1	(D1)
Tendencia de búsqueda retail y entretenimiento	Semanal	t-0	(D1)
Tendencia de búsqueda de seguro de desempleo	Semanal	t-0	(D1)

D1: Factor estacional, D2: Deflactación, A1: Ajuste de periodicidad³

Fuente: Elaboración propia.

³ Las semanas se consideraron de viernes a viernes.

IV. Modelo de Factores

La estadística multivariante se ocupa del tratamiento de conjuntos de datos con un gran número de dimensiones. Esta rama se compone de un grupo de métodos estadísticos que se enfocan en estudiar múltiples variables y la variación que estas tienen en común, entre ellos se encuentra el análisis factorial. Esta técnica estadística multivariante permite agrupar un conjunto grande de variables en grupos homogéneos que se correlacionan entre sí.

El objetivo de esta técnica es estimar el menor número de dimensiones capaces de explicar la mayor parte de la información contenida en los datos. Para ello, supone que existe un factor común subyacente a las variables, que nos permite relacionar variables latentes y observadas. Una de sus generalizaciones es el Modelo Factorial Dinámico (MFD) y, dependiendo del análisis, se puede acompañar del análisis de Componentes Principales (CP) para la estimación del componente latente.

Las técnicas de CP y MFD son procedimientos estadísticos que se basan en las correlaciones de los elementos de una matriz de datos con el objetivo de reducir el conjunto general de elementos a un subconjunto más pequeño de factores. Como resultado de esta reducción, la complejidad del análisis disminuye al ocupar menos factores o componentes en lugar de las matrices de datos originales.

Estas técnicas de reducción permiten capturar la mayor parte de la varianza de las variables en un conjunto más pequeño. La varianza común es la parte de la variación de la variable que es compartida con las otras variables, mientras que la varianza única representa la parte propia de cada variable.

En particular, estas dos formas se apoyan en diferentes métodos de estimación. Por un lado, los CP extraen los factores que explican la varianza de las variables y son una combinación lineal de variables, mientras que el MFD intenta explicar las correlaciones entre variables y se basa en la medición de una variable latente. Así, dependiendo de la información y de la estructura de los datos se decide que método es más conveniente.

Para llevar a cabo este tipo de análisis, es necesario que estas variables tengan una cierta correlación. Una forma sencilla de ver qué tan relacionadas están las variables es a través de la matriz de correlación. Si bien esperamos una correlación entre todas las variables, puede ser que en algunos elementos este comportamiento no se presente. Como se puede representar en la Figura 2, existe una correlación positiva entre la mayor parte de las variables que se utilizan. Sin embargo, con el fin de complementar este primer resultado, se ocuparon otros procedimientos con mayor rigor estadístico.

Figura 2: Matriz de correlación.

	afiliencia metro	afiliencia a metros	igpe	movimiento aerolíneas	legados vuelos	legados pasajeros	afiliencia a metros	afiliencia a metros	retail google	cierre IPC	monto agencias	monto comida	monto entretenimiento	monto estaciones	monto gasolineros	monto hospitales	monto hoteles	monto peaje	monto renta autos	monto restaurantes	monto salones belleza	monto aéro	monto terec	OpenTable México	OpenTable BCS	OpenTable Jalisco	OpenTable CdMX	OpenTable NL	OpenTable Q Roo	OpenTable San Pedro G.	Responde 4 OpenTa	operaciones agencias	operaciones comida	operaciones entreten	operaciones estacion	operaciones gasolin	operaciones hospital	operaciones hoteles	operaciones peaje	operaciones renta	operaciones restaur	operaciones salones	operaciones aéro	operaciones pasaje	seguro de desp	hoteles centros turísticos	hoteles corredores	WEI					
afiliencia metro	1.00	0.58	0.51	0.39	0.40	0.36	0.13	0.17	0.80	0.27	0.39	0.41	0.47	0.43	0.49	0.05	0.37	0.46	0.37	0.41	0.41	0.41	0.43	0.82	0.79	0.81	0.77	0.78	0.81	0.79	0.76	0.43	0.48	0.42	0.39	0.50	0.49	0.42	0.58	0.41	0.49	0.45	0.46	0.20	0.29	0.40	0.37	0.54					
afiliencia a metros	0.58	1.00	0.77	0.74	0.80	0.75	0.44	0.51	0.70	0.39	0.70	0.75	0.69	0.71	0.72	0.22	0.67	0.51	0.67	0.73	0.68	0.74	0.67	0.74	0.71	0.68	0.72	0.77	0.73	0.72	0.75	0.79	0.79	0.62	0.67	0.74	0.75	0.74	0.53	0.68	0.82	0.74	0.78	0.33	0.41	0.48	0.41	0.81					
igpe	0.51	0.77	1.00	0.74	0.80	0.74	0.43	0.50	0.63	0.46	0.62	0.69	0.56	0.56	0.73	0.27	0.64	0.61	0.65	0.63	0.60	0.63	0.59	0.67	0.69	0.64	0.60	0.65	0.75	0.65	0.67	0.72	0.75	0.57	0.57	0.71	0.64	0.68	0.62	0.68	0.72	0.64	0.71	0.18	0.49	0.55	0.51	0.82					
movimiento aerolíneas	0.39	0.74	0.74	1.00	1.00	0.98	0.64	0.76	0.32	0.54	0.69	0.57	0.60	0.78	0.52	0.28	0.79	0.52	0.79	0.80	0.60	0.82	0.63	0.37	0.42	0.34	0.30	0.36	0.47	0.38	0.38	0.77	0.56	0.45	0.80	0.57	0.62	0.83	0.50	0.76	0.82	0.67	0.84	0.32	0.21	0.20	0.09	0.72					
legados vuelos	0.40	0.80	0.80	1.00	1.00	0.99	0.61	0.73	0.30	0.60	0.71	0.70	0.64	0.81	0.65	0.33	0.80	0.71	0.80	0.80	0.65	0.82	0.69	0.36	0.40	0.33	0.29	0.35	0.45	0.37	0.36	0.79	0.70	0.53	0.86	0.68	0.67	0.83	0.69	0.78	0.82	0.72	0.87	0.32	0.20	0.21	0.10	0.71					
legados pasajeros	0.36	0.75	0.74	0.98	0.99	1.00	0.56	0.71	0.21	0.55	0.72	0.65	0.58	0.81	0.60	0.36	0.81	0.67	0.81	0.81	0.65	0.83	0.66	0.27	0.32	0.25	0.21	0.27	0.38	0.29	0.27	0.79	0.64	0.45	0.88	0.63	0.64	0.83	0.65	0.78	0.80	0.72	0.85	0.30	0.13	0.12	0.02	0.63					
afiliencia a metros	0.13	0.44	0.43	0.64	0.61	0.56	1.00	0.97	0.07	0.51	0.35	0.42	0.36	0.40	0.27	0.22	0.40	0.36	0.40	0.41	0.29	0.47	0.37	0.10	0.15	0.08	0.05	0.09	0.19	0.11	0.13	0.40	0.39	0.31	0.39	0.31	0.39	0.44	0.33	0.33	0.43	0.33	0.47	0.15	0.04	-0.01	-0.10	0.42					
afiliencia arqueológica	0.17	0.51	0.50	0.76	0.73	0.71	0.97	1.00	0.06	0.53	0.45	0.47	0.40	0.52	0.34	0.29	0.52	0.45	0.53	0.53	0.39	0.58	0.45	0.10	0.16	0.09	0.05	0.09	0.21	0.11	0.12	0.52	0.44	0.32	0.54	0.38	0.46	0.55	0.41	0.46	0.53	0.44	0.59	0.19	0.04	-0.02	-0.11	0.46					
retail google	0.80	0.70	0.63	0.32	0.30	0.21	0.07	0.06	1.00	0.34	0.22	0.58	0.69	0.35	0.65	-0.20	0.24	0.50	0.24	0.25	0.28	0.24	0.56	0.93	0.88	0.92	0.92	0.89	0.86	0.88	0.94	0.31	0.64	0.80	0.21	0.67	0.52	0.31	0.60	0.28	0.43	0.35	0.38	0.47	0.64	0.86	0.84	0.71					
cierre IPC	0.27	0.39	0.46	0.54	0.60	0.55	0.51	0.53	0.34	1.00	0.37	0.46	0.30	0.25	0.43	0.10	0.38	0.37	0.35	0.41	0.33	0.40	0.35	0.37	0.42	0.33	0.30	0.34	0.49	0.38	0.35	0.38	0.43	0.28	0.28	0.47	0.35	0.41	0.32	0.40	0.45	0.35	0.33	-0.10	0.24	0.26	-0.02	0.57					
monto agencias	0.39	0.70	0.62	0.69	0.71	0.72	0.35	0.45	0.22	0.37	1.00	0.70	0.55	0.83	0.61	0.49	0.90	0.55	0.90	0.93	0.85	0.93	0.67	0.31	0.33	0.30	0.25	0.32	0.40	0.34	0.25	0.96	0.70	0.43	0.79	0.66	0.72	0.91	0.53	0.88	0.90	0.86	0.87	0.30	0.14	0.17	0.08	0.64					
monto comida	0.41	0.75	0.69	0.57	0.70	0.65	0.42	0.47	0.58	0.46	0.70	1.00	0.65	0.61	0.78	0.48	0.90	0.54	0.69	0.71	0.69	0.66	0.70	0.65	0.67	0.63	0.57	0.63	0.74	0.64	0.59	0.82	0.70	0.73	0.51	0.67	0.72	0.96	0.64	0.55	0.82	0.70	0.73	0.51	0.67	0.78	0.71	0.66	0.30	0.44	0.42	0.37	0.73
monto entretenimiento	0.47	0.69	0.56	0.60	0.64	0.58	0.36	0.40	0.69	0.30	0.55	0.65	1.00	0.61	0.59	0.18	0.59	0.50	0.59	0.63	0.56	0.60	0.59	0.69	0.70	0.66	0.63	0.65	0.73	0.67	0.68	0.59	0.65	0.87	0.50	0.64	0.64	0.65	0.49	0.56	0.73	0.61	0.66	0.39	0.40	0.57	0.37	0.74					
monto estaciones	0.43	0.71	0.56	0.78	0.81	0.81	0.40	0.52	0.35	0.25	0.83	0.61	0.61	1.00	0.56	0.39	0.85	0.50	0.85	0.88	0.78	0.88	0.70	0.42	0.43	0.40	0.36	0.43	0.49	0.44	0.37	0.84	0.60	0.43	0.85	0.62	0.71	0.88	0.50	0.85	0.87	0.82	0.86	0.44	0.21	0.15	0.12	0.65					
monto gasolineros	0.49	0.72	0.73	0.52	0.65	0.60	0.27	0.34	0.65	0.43	0.61	0.78	0.59	0.56	1.00	0.38	0.57	0.54	0.59	0.62	0.70	0.60	0.63	0.69	0.70	0.67	0.62	0.67	0.75	0.68	0.64	0.67	0.86	0.58	0.58	0.96	0.74	0.64	0.56	0.65	0.72	0.72	0.67	0.19	0.50	0.57	0.46	0.77					
monto hospitales	0.05	0.22	0.27	0.28	0.33	0.36	0.22	0.29	-0.20	0.10	0.49	0.38	0.18	0.39	0.38	1.00	0.45	0.34	0.49	0.47	0.58	0.48	0.33	-0.11	-0.05	-0.09	-0.18	-0.09	0.08	-0.07	-0.32	0.46	0.37	0.11	0.42	0.38	0.66	0.44	0.29	0.48	0.42	0.53	0.46	0.27	0.27	0.04	-0.14	0.21					
monto hoteles	0.37	0.67	0.64	0.79	0.80	0.81	0.40	0.52	0.24	0.38	0.90	0.70	0.59	0.85	0.57	0.45	1.00	0.59	0.97	0.97	0.80	0.92	0.74	0.33	0.36	0.31	0.25	0.32	0.45	0.34	0.26	0.89	0.65	0.48	0.85	0.63	0.67	0.98	0.56	0.93	0.83	0.84	0.39	0.12	0.17	0.09	0.67						
monto peaje	0.46	0.51	0.61	0.52	0.71	0.67	0.36	0.45	0.50	0.37	0.55	0.54	0.50	0.50	0.54	0.34	0.59	1.00	0.60	0.58	0.55	0.55	0.54	0.54	0.56	0.51	0.46	0.52	0.64	0.55	0.44	0.61	0.54	0.46	0.49	0.53	0.54	0.60	0.91	0.58	0.62	0.56	0.57	0.20	0.42	0.44	0.27	0.59					
monto renta autos	0.37	0.67	0.65	0.79	0.80	0.81	0.40	0.53	0.24	0.35	0.90	0.69	0.59	0.85	0.59	0.49	0.97	1.00	0.96	0.81	0.92	0.73	0.33	0.35	0.31	0.26	0.34	0.44	0.36	0.26	0.89	0.65	0.47	0.86	0.64	0.69	0.97	0.55	0.96	0.93	0.83	0.86	0.41	0.22	0.18	0.12	0.68						
monto restaurantes	0.41	0.73	0.63	0.80	0.80	0.81	0.41	0.53	0.25	0.41	0.93	0.71	0.63	0.88	0.62	0.47	0.97	0.58	0.96	1.00	0.85	0.96	0.75	0.33	0.36	0.31	0.26	0.33	0.45	0.36	0.28	0.90	0.68	0.48	0.87	0.69	0.74	0.98	0.55	0.94	0.98	0.88	0.88	0.40	0.17	0.16	0.06	0.70					
monto salones belleza	0.41	0.68	0.60	0.60	0.65	0.29	0.39	0.28	0.33	0.85	0.69	0.56	0.78	0.70	0.58	0.80	0.55	0.81	0.85	1.00	0.86	0.64	0.36	0.37	0.35	0.30	0.37	0.45	0.39	0.27	0.83	0.71	0.44	0.72	0.73	0.80	0.84	0.54	0.83	0.85	0.99	0.81	0.33	0.25	0.14	0.14	0.64						
monto aéro	0.41	0.74	0.63	0.82	0.82	0.83	0.47	0.58	0.24	0.40	0.93	0.66	0.60	0.88	0.60	0.48	0.92	0.55	0.92	0.96	0.86	1.00	0.72	0.32	0.35	0.30	0.25	0.33	0.42	0.35	0.27	0.92	0.65	0.42	0.85	0.66	0.75	0.95	0.52	0.92	0.94	0.89	0.94	0.39	0.16	0.15	0.04	0.70					
monto terec	0.43	0.67	0.59	0.63	0.69	0.66	0.37	0.45	0.56	0.35	0.67	0.70	0.59	0.70	0.63	0.33	0.74	0.54	0.73	0.75	0.64	0.72	1.00	0.64	0.65	0.64	0.56	0.61	0.71	0.62	0.57	0.67	0.67	0.54	0.73	0.68	0.66	0.76	0.54	0.76	0.79	0.67	0.67	0.60	0.32	0.30	0.28	0.67					
OpenTable México	0.82	0.74	0.67	0.37	0.36	0.27	0.10	0.10	0.93	0.37	0.31	0.65	0.69	0.42	0.69	-0.11	0.33	0.54	0.33	0.33	0.36	0.32	0.64	1.00	0.94	0.98	0.97	0.96	0.93	0.95	0.95	0.39	0.71	0.80	0.31	0.70	0.58	0.38															

Dentro de las medidas adicionales que existen para determinar si los elementos de un conjunto se correlacionan lo suficiente está la prueba Kaiser-Meyer-Olkin (KMO). Esta técnica se ocupa con el propósito de analizar si las variables en el conjunto de datos pueden explicar las correlaciones ente variables, es decir, nos permite saber si se puede o no resumir la información proporcionada por las variables iniciales en pocos factores. Su fórmula es la siguiente:

$$KMO_j = \frac{\sum_{i \neq j} r_{ij}^2}{\sum_{i \neq j} r_{ij}^2 + \sum_{i \neq j} u_{ij}^2}$$

donde:

r_{ij}^2 es la matriz de correlación de Pearson al cuadrado

u_{ij}^2 es la matriz de covarianza parcial al cuadrado.

La prueba de KMO devuelve valores entre 0 y 1, una lectura entre 0.8 y 1 indica que el muestreo es adecuado. En cambio, los valores de KMO cercanos a cero significan que existen grandes correlaciones parciales en comparación con la suma de las correlaciones. En el presente análisis el KMO arroja un valor de 0.92, por lo que, de acuerdo con este indicador, la matriz de datos resulta apropiada para realizar nuestro análisis.

Una segunda forma de evaluar la correlación entre series es a través de la prueba de esfericidad de Bartlett. Este método contrasta la hipótesis que establece como matriz identidad a la matriz de correlaciones, lo que indicaría que las variables no están relacionadas y, por lo tanto, no son adecuadas para detectar una estructura o patrón general. Los valores menores al nivel de significancia (0.05) indican que un análisis factorial puede ser útil con los datos. En este caso, el estadístico de la prueba de Bartlett arroja un resultado de 0.001, de esta forma se comprueba que sí existe un grado de reiteración entre las variables que se puede

resumir con menos factores. No obstante, es importante mencionar que, aunque entre todas las variables existe una correlación relevante, aquellas que comparten un factor presentan una mayor relación.

Análisis Factorial Dinámico

Los modelos de factores dinámicos son una técnica de reducción de dimensionalidad que nos permite estimar un subconjunto de factores subyacentes comunes entre el conjunto original de series de tiempo. Su objetivo es explicar la variación afín dentro del conjunto de n series observadas utilizando combinaciones lineales de m caminatas aleatorias ocultas, donde $m \ll n$.

Los MFD tradicionalmente suponen que un conjunto de datos se puede caracterizar por uno o más componentes comunes e inobservables a las series que capturan los co-movimientos de las variables, así como un componente idiosincrásico específico a cada variable. Estos modelos implican que la actividad económica se puede describir por un grupo de fuerzas latentes y dinámicas comunes, capturadas por los factores dinámicos, que gracias al uso de un menor número de variables facilitan su representación.

La idea general es que el vector de series de tiempo observadas (y_t) es modelado como una combinación lineal de un número reducido de factores latentes o no observables (x_t) y un componente idiosincrásico de media cero v_t . Los factores x_t evolucionan a lo largo del tiempo siguiendo un proceso autorregresivo.

La estructura de los modelos factoriales es la siguiente:

$$y_t = Zx_t + a + v_t \text{ con } v_t \sim MVN(0, R)$$

$$x_t = x_{t-1} + w_t \text{ con } w_t \sim MVN(0, Q)$$

De acuerdo con esta estructura, los MFD son la suma de dos componentes: el primero se refiere a los factores comunes al conjunto de variables (x_t), y el segundo, al componente idiosincrático (v_t), el cual mantiene una distribución normal multivariante (MVN). El primero suele identificarse como componente común mientras que el segundo componente cubre los movimientos particulares de cada serie. Las cargas factoriales (Z) representan el peso de cada factor sobre la variable observable.

Los MFD han sido utilizados en diferentes campos de estudio, particularmente en economía, estadística y psicometría debido a su facilidad para sintetizar en un pequeño número de factores la mayor información de variables observadas. Recientemente, su uso se ha extendido al campo estadístico para realizar pronósticos por medio de una regresión simple considerando la información y dinámicas principales de todas las series.

Una de las ventajas que presenta el análisis factorial dinámico es que se puede conocer información sobre la estructura y dinámica del conjunto de datos. Lo anterior contrasta con los análisis individuales que, conforme aumenta el número de variables a considerar, dificulta el estudio general del estado general de la economía. Por ello, gracias a la aplicación de estas técnicas se puede representar la información condensada a partir de combinaciones lineales de las series que explican la mayor parte de la variabilidad de los datos.

Análisis de Componentes principales (PCA)

El Análisis de Componentes Principales es un método estadístico que permite reagrupar las series en un número menor de variables, llamadas componentes. Su objetivo es encontrar una combinación lineal de las variables originales con la máxima varianza. Así, es posible explicar, a través de un menor número de componentes, la mayor variabilidad del conjunto de variables.

Lo anterior se logra transformando en un conjunto nuevo los componentes principales no correlacionados y ordenados de forma que los primeros componentes tengan la mayor variación (es decir, el primer componente principal captura la máxima varianza). Luego, el segundo componente principal tiene la máxima varianza entre todas las combinaciones lineales que no están correlacionadas con el primer componente principal y así sucesivamente. De forma que el último componente principal tiene la menor varianza entre todas las combinaciones lineales de las variables. Si bien, todos los componentes principales contienen información de las variables originales, la información relevante se reparte de manera que los primeros componentes contienen más información que los últimos.

El marco teórico original fue desarrollado por Pearson (1901) y Hotelling (1933). Esta visión fue retomada años después por Chamberlain y Rothschild (1983), quienes sugirieron utilizar el análisis de componentes principales (PCA) para estimar un modelo de factor estático aproximado, aunque fueron Stock y Watson (2002a, b) y Bai y Ng (2002) quienes popularizaron este enfoque y su aplicación en la macroeconomía. Recientemente, su principal uso se centra en construir modelos predictivos y de análisis para estudiar la estructura subyacente de un conjunto de variables.

Seguendo la representación de Joliffe (2002), el modelo PCA se puede expresar de la siguiente forma:

$$Y_{ij} = P'_i X_j + e_{ij},$$

$$i = 1, \dots, n$$

$$j = 1, \dots, p$$

donde Y_{ij} representa la matriz de las variables observadas, P'_i es un vector de constantes que representan las cargas o coeficientes de importancia relativa, X_j son los componentes principales o variables latentes y e_{ij} es la matriz de errores homocedásticos e independientes. Específicamente, siguiendo a Bai y Ng (2008) y a Armendáriz y Ramírez (2017), se utiliza un modelo con restricciones para encontrar una solución única. Los componentes principales se estiman a partir de las siguientes expresiones:

Primer componente principal:

$$PC_1 = P'_1 X = P_{11}X_1 + P_{12}X_2 + \dots + P_{1n}X_n$$

Con una combinación lineal $P'_1 X$ que maximiza $\text{Var}(P'_1 X)$, sujeto a $P'_1 P_1 = 1$

Segundo componente principal:

$$PC_2 = P'_2 X = P_{21}X_1 + P_{22}X_2 + \dots + P_{2n}X_n$$

Con una combinación $P'_2 X$ que maximiza $\text{Var}(P'_2 X)$, sujeto a $P'_2 P_2 = 1$ y a $\text{Cov}(P'_1 X, P'_2 X) = 0$.

Con el i -ésimo componente principal:

$$PC_i = P'_i X = P_{i1}X_1 + P_{i2}X_2 + \dots + P_{in}X_n$$

Con una combinación $P'_i X$ que maximiza $\text{Var}(P'_i X)$, sujeto a $P'_i P_i = 1$ y $\text{Cov}(P'_i X, P'_k X) = 0$ para $k < i$,

donde X es la matriz de variables, P es la matriz de vectores propios y PC es el componente principal.

La primera restricción supone que los componentes principales son ortogonales (perpendiculares) entre ellos. La segunda restricción supone la diagonalidad de la matriz de covarianzas de las cargas.

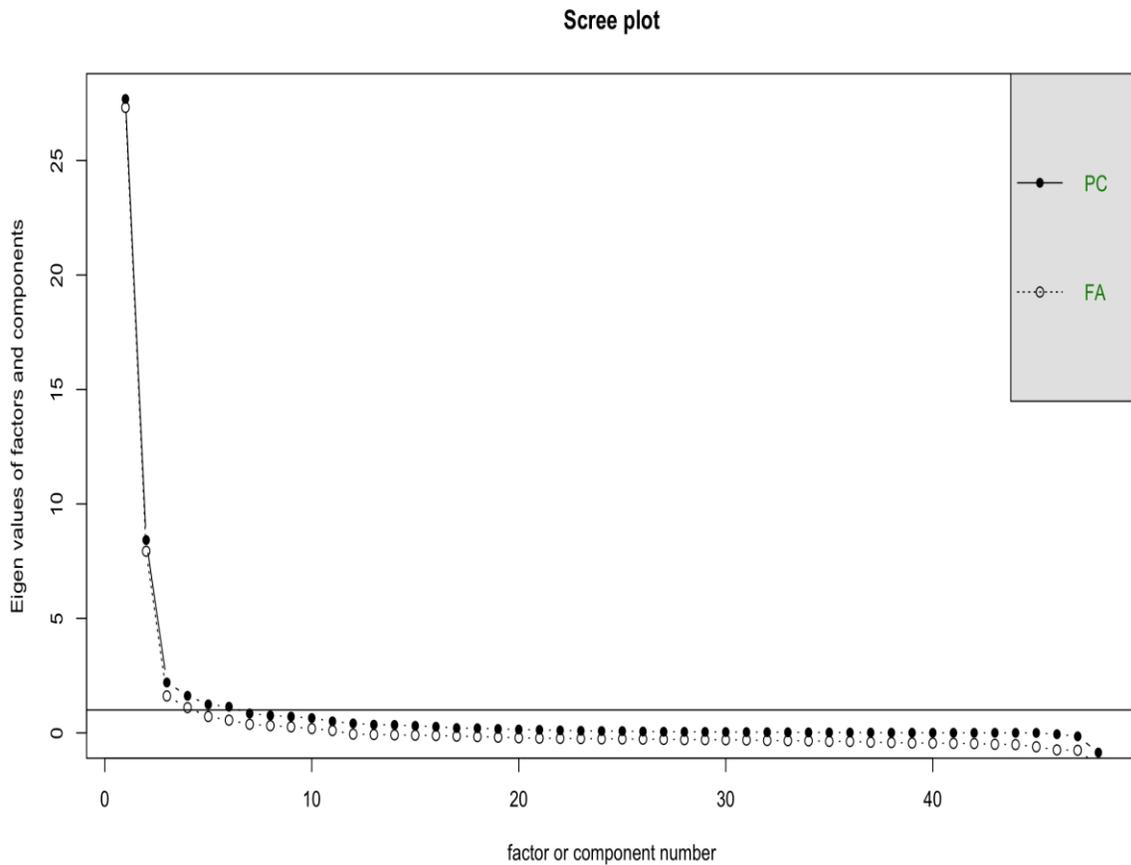
Como se subrayó anteriormente, el análisis PCA permite transformar la matriz original de variables en otro conjunto de variables nuevas no correlacionadas entre sí. La ventaja de la estimación del indicador de actividad económica a través de este enfoque es la facilidad de su implementación en la práctica debido a su incorporación en diferentes paquetes o softwares estadísticos. En cambio, una de las principales limitaciones está en la necesidad de un conjunto elevado de variables que permita garantizar la consistencia del indicador.

Una vez introducidas las principales formas del análisis factorial, en esta sección se describe la implementación del MFD para la economía mexicana. Para ello se seleccionó un conjunto de datos compuesto por 48 variables que fueron transformadas antes de ser introducidas al modelo, después se procedió a la determinación y extracción del número de factores. Una vez identificado esto último, se dio paso a la estimación de cargas y factores a través de la función MARSS en el lenguaje de programación R. Después, se interpretaron los resultados obtenidos y se realizó una regresión lineal para realizar un pronóstico del Indicador Global de la Actividad Económica (IGAE). Finalmente, para evaluar qué tan bien reproducen los datos los factores se presenta el coeficiente de determinación R^2 como medida de bondad de ajuste.

Estimación del número de factores

Para la estimación del número de factores latentes se ocupó el método gráfico *scree plot* formulado por Cattell (1966), el cual busca seleccionar el menor número de factores que explique el mayor porcentaje de variación. Para lograr lo anterior, considera los valores propios como medida de la cantidad de varianza explicada por cada factor. En el siguiente diagrama se aprecian los valores propios (eje y) para todos los factores potenciales de las variables (eje x).

Figura 3: Gráfico de sedimentación (scree plot)

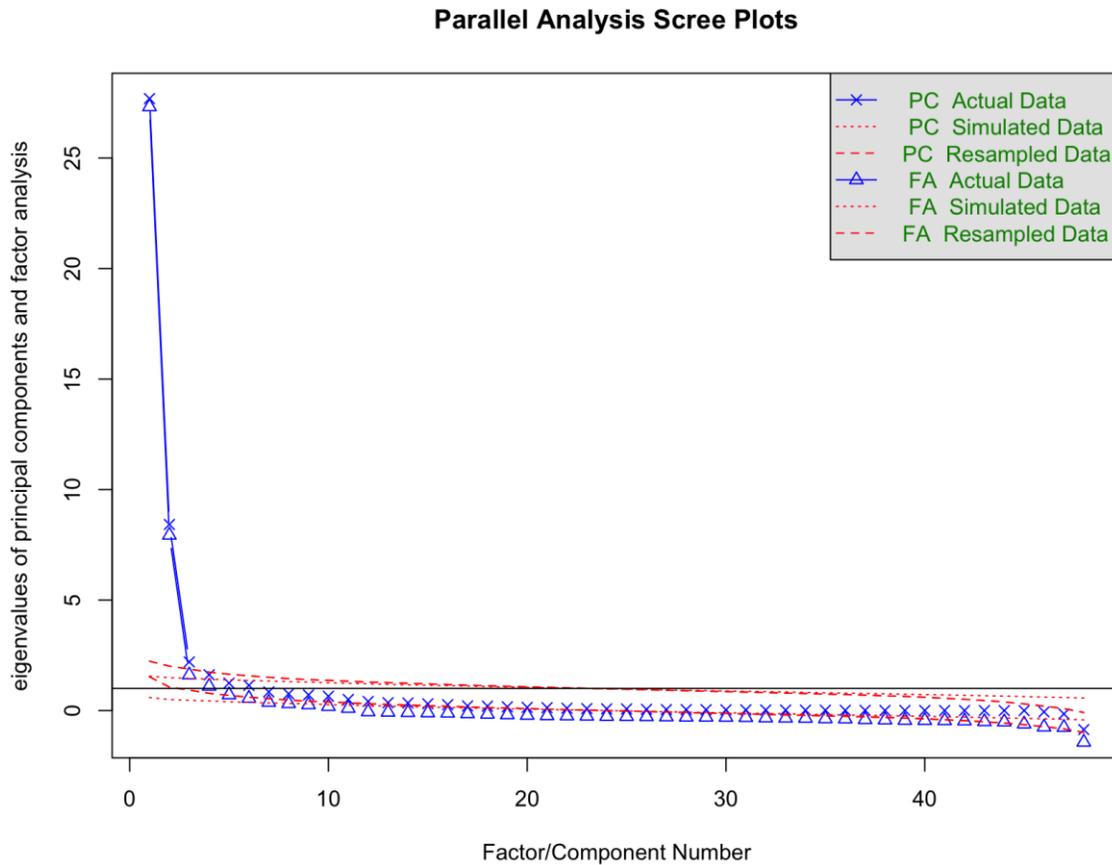


Fuente: Elaboración propia con datos de diversas fuentes.

En la gráfica anterior se aprecia una línea horizontal que marca el límite del factor que extrae la mayor cantidad de varianza. Después de ésta, la cantidad de variación adicional no es significativa. Considerando lo anterior, hay cuatro factores en el conjunto de datos que explican la mayor varianza. Un mejor método gráfico para determinar el número óptimo de factores es el *parallel analysis scree plot*, el cual, además de trazar los valores propios del análisis factorial, genera matrices de correlación aleatorias y, después de analizarlas por factores, compara los valores propios estimados respecto a los valores propios de los datos observados. La idea detrás de este método es que los valores propios observados que son más

altos que sus correspondientes valores propios aleatorios tienen más probabilidades de ser factores significativos que los valores que están por debajo de su valor aleatorio correspondiente.

Figura 4: Análisis paralelo del gráfico de sedimentación



Fuente: Elaboración propia con información de diversas fuentes.

En la gráfica anterior, las líneas azules muestran los valores propios observados y las líneas punteadas rojas representan los valores propios simulados. Cada punto de la línea azul que se encuentra por encima de la línea roja es un factor o componente que se recomienda extraer.

En este caso, de acuerdo con lo observado en la gráfica basada en el *parallel analysis* se considera el uso de 5 factores.

El modelo de factores

Una vez estimado el número de factores, a continuación se presentan las ecuaciones matriciales, considerando 5 factores ocultos ($m = 5$) y 48 series observadas (y):

$$\begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_{48} \end{bmatrix} = \begin{bmatrix} Z_{1,1} & Z_{1,2} & \dots & Z_{1,5} \\ Z_{2,1} & Z_{2,2} & \dots & Z_{2,5} \\ \vdots & \vdots & & \vdots \\ Z_{48,1} & Z_{48,2} & \dots & Z_{48,5} \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_5 \end{bmatrix}_t + \begin{bmatrix} a_1 \\ a_2 \\ \vdots \\ a_{48} \end{bmatrix} + \begin{bmatrix} v_1 \\ v_2 \\ \vdots \\ v_{48} \end{bmatrix}_t$$

Siendo \mathbf{Y} una matriz estacionaria y estandarizada con media cero que representa el vector de datos observables. La matriz \mathbf{Z} denota las cargas factoriales o ponderadas calculadas a partir de los factores latentes \mathbf{X} . Las posibles compensaciones son reproducidas con la matriz \mathbf{a} y los errores con la matriz \mathbf{v} .

Los factores ocultos y sus errores se representan de la siguiente forma:

$$\begin{bmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \\ x_5 \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \\ x_5 \end{bmatrix}_{t-1} + \begin{bmatrix} w_1 \\ w_2 \\ w_3 \\ w_4 \\ w_5 \end{bmatrix}_t$$

$$\begin{bmatrix} w_1 \\ w_2 \\ w_3 \\ w_4 \\ w_5 \end{bmatrix}_t \sim MVN \left(\begin{bmatrix} 0 \\ 0 \\ 0 \\ 0 \\ 0 \end{bmatrix}, \begin{bmatrix} q_{1,1} & q_{1,2} & q_{1,3} & q_{1,4} & q_{1,5} \\ q_{2,1} & q_{2,2} & q_{2,3} & q_{2,4} & q_{2,5} \\ q_{3,1} & q_{3,2} & q_{3,3} & q_{3,4} & q_{3,5} \\ q_{4,1} & q_{4,2} & q_{4,3} & q_{4,4} & q_{4,5} \\ q_{5,1} & q_{5,2} & q_{5,3} & q_{5,4} & q_{5,5} \end{bmatrix} \right)$$

Y los errores de los datos observados son:

$$\begin{bmatrix} v_1 \\ v_2 \\ \vdots \\ v_{48} \end{bmatrix}_t \sim MVN \left(\begin{bmatrix} 0 \\ 0 \\ \vdots \\ 0 \end{bmatrix}_{48 \times 1}, \begin{bmatrix} r_{1,1} & r_{1,2} & \dots & r_{1,48} \\ r_{2,1} & r_{2,2} & \dots & r_{2,48} \\ \vdots & \vdots & \vdots & \vdots \\ r_{48,1} & r_{48,2} & \dots & r_{48,48} \end{bmatrix} \right)$$

Como se mencionó anteriormente, la matriz \mathbf{Z} permite construir una estructura de cargas. Sin embargo, al no tener ninguna restricción hay un número infinito de combinaciones de \mathbf{Z} y \mathbf{X} que igualan a \mathbf{Y} . Por ello y con el propósito de facilitar la solución del modelo, las restricciones requeridas para el modelo son las siguientes:

- 1) \mathbf{a} está restringida de modo que los valores m se establecen en cero;
- 2) En la fila $m - 1$ de \mathbf{Z} , los valores z en la j -ésima columna y la i -ésima fila es igual a cero si $j > i$
- 3) \mathbf{Q} se iguala a la matriz \mathbf{I}

La primera restricción señala que el vector \mathbf{a} , el cual incluye los niveles de las series que intersectan en cada estado, es igual a cero para cada componente. Esta restricción evita problemas con el algoritmo esperanza-maximización (algoritmo EM) que se describirá más adelante. La segunda establece que el triángulo superior de la matriz de cargas \mathbf{Z} es igual a

cero y finalmente, la tercera restricción determina que la varianza Q de los residuos es igual a la matriz identidad. Con estas restricciones el modelo se simplifica y da una mayor flexibilidad al análisis.

Tomando en cuenta las restricciones anteriores, el sistema de ecuaciones del modelo queda de la siguiente forma:

$$\begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_{48} \end{bmatrix} = \begin{bmatrix} z_{1,1} & 0 & 0 \\ z_{2,1} & z_{2,2} & 0 \\ \vdots & \vdots & \vdots \\ z_{48,1} & z_{48,2} & z_{48,3} \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_5 \end{bmatrix}_t + \begin{bmatrix} 0 \\ 0 \\ \vdots \\ 0 \end{bmatrix} + \begin{bmatrix} v_1 \\ v_2 \\ \vdots \\ v_{48} \end{bmatrix}_t$$

$$\begin{bmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \\ x_5 \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \\ x_5 \end{bmatrix}_{t-1} + \begin{bmatrix} w_1 \\ w_2 \\ w_3 \\ w_4 \\ w_5 \end{bmatrix}_t$$

$$\begin{bmatrix} w_1 \\ w_2 \\ w_3 \\ w_4 \\ w_5 \end{bmatrix}_t \sim MVN \left(\begin{bmatrix} 0 \\ 0 \\ 0 \\ 0 \\ 0 \end{bmatrix}, \begin{bmatrix} 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix} \right)$$

$$\begin{bmatrix} v_1 \\ v_2 \\ \vdots \\ v_{48} \end{bmatrix}_t \sim MVN \left(\begin{bmatrix} 0 \\ 0 \\ \vdots \\ 0 \end{bmatrix}_{48 \times 1}, \begin{bmatrix} r_{1,1} & r_{1,2} & \dots & r_{1,48} \\ r_{2,1} & r_{2,2} & \dots & r_{2,48} \\ \vdots & \vdots & \vdots & \vdots \\ r_{48,1} & r_{48,2} & \dots & r_{48,48} \end{bmatrix} \right)$$

Una vez definido y especificado el modelo, se realizó la adaptación del modelo con el paquete MARSS (Holmes et al., 2014). Este paquete está diseñado para trabajar con la forma matricial del modelo de espacio de estado multivariado descrito previamente.

La notación de la estimación de los factores se calcula a través de la siguiente expresión:

$$y_t = Zx_t + a + v_t \text{ con } v_t \sim MVN(0, R)$$
$$x_t = \beta x_t + w_t \text{ con } w_t \sim MVN(0, Q)$$

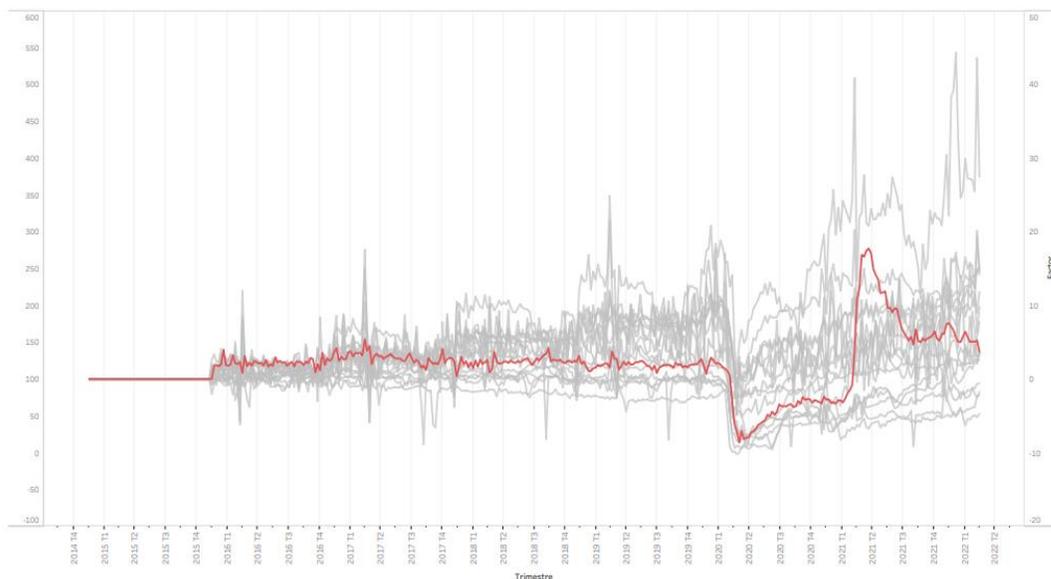
Para ajustar el modelo en MARSS es necesario crear i) una lista de especificaciones para los vectores y matrices del modelo; ii) una lista con los valores iniciales y iii) una lista de parámetros de control. Una vez especificado lo anterior, es posible ajustar el modelo.

Una vez resuelto, los resultados que arroja el modelo incluyen las 48 estimaciones de los parámetros con las cargas de cada serie de tiempo Z considerando 5 estados latentes; las varianzas de los errores de observación R y las 5 estimaciones de los estados iniciales.

Las funciones del paquete MARSS estiman los parámetros del modelo (Z y R) por máxima verosimilitud utilizando el filtro de Kalman y el algoritmo EM. El uso del mismo fue popularizado por Dempster et al. (1977) y Watson & Engle (1983) debido a que su aplicación facilita la consideración de factores no observables. Una simplificación del algoritmo EM es que, si es posible observar algunas variables latentes, entonces calcular las funciones de probabilidad es más simple. En este sentido, el algoritmo alterna la estimación de las variables ocultas asumiendo que son conocidas y, a partir de ello, realiza estimaciones simples con las variables ocultas observadas. Después, estima las variables ocultas nuevamente e itera este proceso hasta que los valores convergen.

Aunque inicialmente no conocemos los factores latentes, suponemos que estos existen y que caracterizan a la economía. El análisis factorial brinda una forma de estimar estos factores subyacentes y nos permite definirlos en términos de los mismos datos. Es importante recordar que el objetivo de este análisis es explicar las variaciones en el comportamiento de la economía mexicana a partir de los factores o estados latentes estimados. En la Figura 5 puede apreciarse la dinámica entre el conjunto de series seleccionadas y el primer factor latente estimado (de color rojo) a partir del panel de las series observadas representadas con el color gris.

Figura 5: Gráfica del primer factor y su relación con las variables seleccionadas.



Fuente: Elaboración propia

Para dar una mejor interpretación a las cargas factoriales es posible encontrar una solución equivalente mediante una matriz de rotación. Este paso permite flexibilizar las restricciones del modelo.

Para ello, es necesario definir una matriz H que diagonalice los factores. Específicamente, el modelo equivalente está representado por el siguiente sistema de ecuaciones:

$$y_t = Zx_t + a + v_t x_t = x_{t-1} + w_t$$

$$y_t = ZH^{-1}x_t + a + v_t Hx_t = Hx_{t-1} + Hw_t,$$

donde H representa una matriz no singular de $m \times m$.

Dentro de la literatura existen diferentes formas de hacer rotaciones de factores. Un método estándar es mediante la rotación varimax (Harvey, 1989). Este enfoque busca una matriz de rotación H que genere la mayor diferencia entre cargas. Por ejemplo, en el modelo de este estudio con 5 factores, una i fila de la matriz Z puede representarse por (0.2, 0.2, 0.2, 0.2, 0.2), es decir, la fila i está descrita en la misma proporción por los 5 factores. En cambio, si esta fila se definiera por (0.6, 0.2, 0.1, 0.05, 0.05) facilitaría la interpretación al distribuir el peso de los factores. Las cargas factoriales rotadas para el modelo se presentan en la siguiente figura:

La Figura anterior muestra la relación que tienen los 5 factores subyacentes con cada una de las variables seleccionadas. Específicamente, del lado izquierdo se presentan las series de los 5 factores dinámicos. Por su parte, las cargas o contribuciones de cada variable asociadas a cada uno de los factores se presentan dentro del cuadro incluido del lado derecho. Estas cargas pueden interpretarse como la contribución o peso de las variables sobre el factor.

V. Resultados Empíricos

Debido a que se calcularon 5 factores latentes, para estimar un solo factor que describa el comportamiento de la actividad económica mexicana se utilizó el método de componentes principales. Los resultados obtenidos se presentan a continuación:

	PA1	PA2	PA3	PA5	PA4
SS loadings	15.94	14.38	4.93	2.79	2.23
Proportion Var	0.33	0.30	0.10	0.06	0.05
Cumulative Var	0.33	0.63	0.73	0.79	0.84
Proportion Explained	0.40	0.36	0.12	0.07	0.06
Cumulative Proportion	0.40	0.75	0.88	0.94	1.00

Los valores propios se muestran en la fila denominada *SS loadings*, estos representan la varianza explicada por cada componente. Es decir, el primer componente explica 15.94 unidades de la varianza del conjunto total de datos, como proporción esto representa el 33 por ciento. En suma, con los 5 componentes estimados se explica el 84% de la varianza.

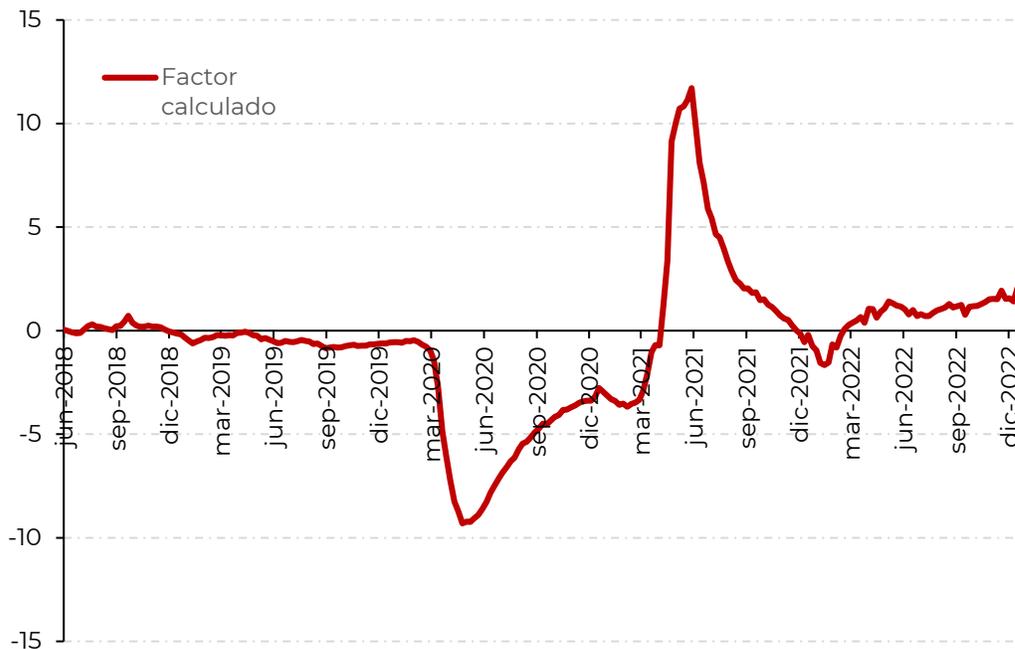
Para la estimación de un solo factor latente, se calculó la media ponderada de los 5 factores extraídos del MFD, considerando la proporción de varianza explicada por cada factor como el peso (w_i). La media ponderada se calculó con la siguiente ecuación:

$$\bar{f}_t = \frac{\sum_{i=1}^n w_i x_i}{\sum_{i=1}^n w_i}$$

La Figura 7 muestra el factor estimado para la actividad económica en México. Se observa que la fuerte caída en la actividad económica mexicana de 2020, así como su trayectoria de recuperación, son capturadas por el factor propuesto. Así, se puede concluir que el indicador semanal propuesto muestra el potencial, tanto de las variables seleccionadas, como de la

metodología implementada para construir un indicador oportuno y sólido que describa el comportamiento general de la actividad económica agregada en México.

Figura 7: Factor estimado ponderado por la proporción de sus componentes



Fuente: Elaboración propia.

Una vez estimado el factor único, es necesario transformarlo a una frecuencia mensual para estimar el modelo de nowcasting mensual que integra las 48 variables. Esta se obtiene con el promedio de las observaciones semanales correspondientes a cada mes:

$$f_t^m = \frac{1}{n} (f_1^w + f_2^w + \dots + f_n^w)$$

Con base en los resultados anteriores, se pronostica el comportamiento del indicador de actividad económica en México. Para estimar el crecimiento de la actividad económica mensual a través de la técnica de nowcasting se emplea la tasa de crecimiento anual del IGAE ajustado por estacionalidad como variable dependiente y el factor único que integra a las 48

series seleccionadas como variable independiente. El procedimiento de estimación de esta regresión lineal de la ecuación emplea el método de Cochrane-Orcutt.

La ecuación que estima el crecimiento del indicador mensual a partir del factor con frecuencia semanal es la siguiente:

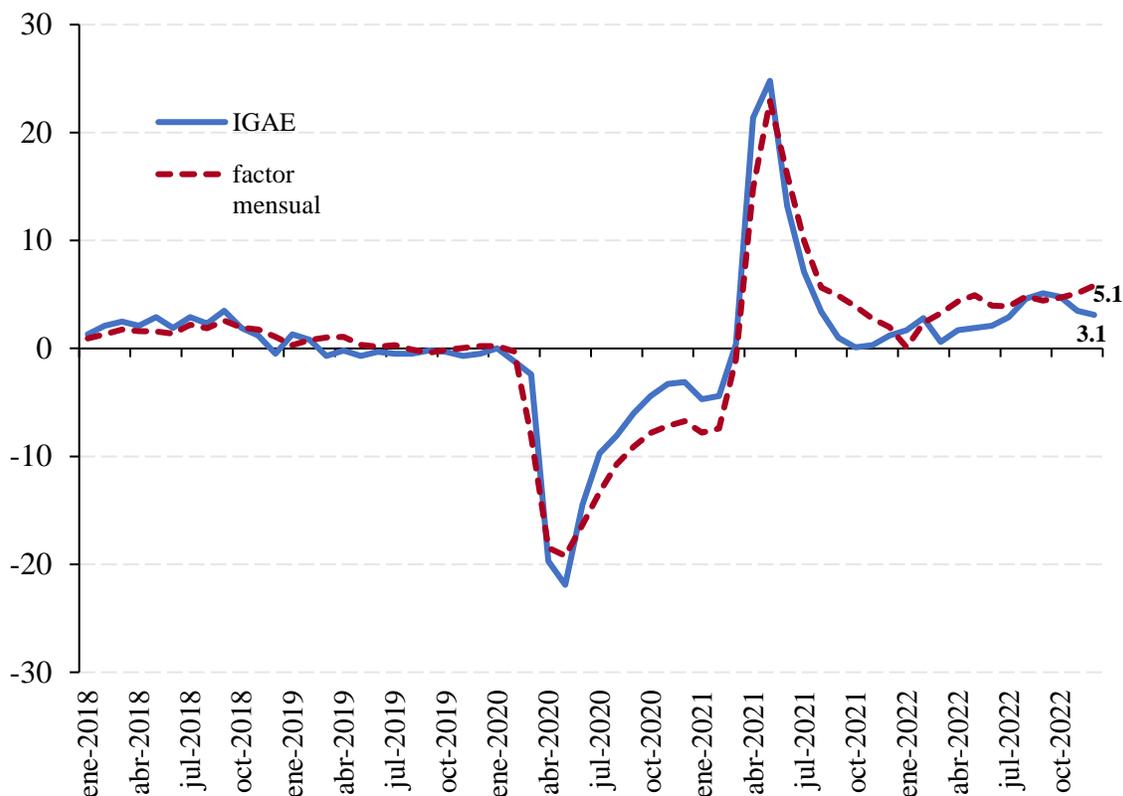
$$Y_t^m = \alpha + \beta f_t^q + e_{ij}$$

Al sustituir los valores obtenidos en la ecuación anterior se obtiene la siguiente expresión:

$$Y_t^q = 1.15 + 2.37 f_t^m + e_{ij}$$

Para ilustrar el desempeño general del modelo, se comparan las cifras del crecimiento del IGAE ya publicadas con el factor único estimado en este análisis. La siguiente gráfica muestra las estimaciones para el indicador oportuno mensual, por medio del factor oportuno mensualizado, en comparación con el IGAE publicado por INEGI.

Figura 8: Comparación entre el factor mensual estimado y el IGAE



Elaboración propia con información de INEGI

Si bien de forma general, como se puede apreciar en la Figura 8, el factor propuesto logra capturar el comportamiento de la actividad económica agregada, en algunos periodos tiende a sobrestimar el mismo. Por ejemplo, se puede observar que a partir del último trimestre de 2021 el factor estimado se ubica por encima del IGAE (excepto en el primer trimestre de 2022). Por ello, es importante mencionar que el indicador no busca reemplazar los indicadores oficiales publicados. En cambio, busca ofrecer una alternativa para conocer con antelación y de manera confiable el estado de la actividad económica en México. Este indicador también contribuye a la discusión sobre la coyuntura de aquellos factores que determinan el comportamiento agregado económico.

Por último, para evaluar la bondad de ajuste del modelo, se calculó el coeficiente de determinación R^2 ajustado, el cual indica la proporción de la variación de la variable dependiente explicada por el factor estimado. En nuestro análisis este último fue de 0.82, de esta forma, se comprueba el potencial de las variables seleccionadas para construir un indicador oportuno que describa el comportamiento general de la actividad económica agregada en México.

Finalmente, gracias a este ejercicio fue posible demostrar mediante la aplicación de herramientas multivariantes, que sintetizan el comportamiento de covariables de alta frecuencia, es posible conocer la tendencia de la actividad económica y, en consecuencia, es posible adelantar las señales económicas que faciliten la toma de decisiones y, al mismo tiempo, nos permitan evaluar el desempeño de la actividad económica en el muy corto plazo.

VI Conclusiones

Una preocupación central en la formulación de políticas es identificar los signos de expansión y recesión en la actividad económica. Sin embargo, debido a la gran cantidad de información y a la complejidad para calcular la actividad económica agregada, las etapas del ciclo económico suelen identificarse con cierto rezago y pierden utilidad en la toma de decisiones de muy corto plazo. En respuesta a lo anterior, las metodologías que permiten simplificar la información y, a su vez, predecir el comportamiento de las variables de interés han mostrado un crecimiento en su aplicación y estudio. Dentro de este tipo de modelos destacan por su uso generalizado el análisis de Componentes Principales y los Modelos de Factores Dinámicos.

El objetivo de este análisis es demostrar la utilidad del uso de indicadores de alta frecuencia, como proxies de la actividad económica, para predecir de forma oportuna el comportamiento económico agregado en México. Para ello, se seleccionaron más de 40 series con frecuencias diarias, semanales y mensuales y, a partir de estas, se estimaron 5 factores comunes e inobservables ocupando la metodología de MFD. De esta manera, fue posible construir una tendencia del estado general de la economía en el corto plazo a través de estos 5 factores latentes manteniendo la máxima variación del conjunto original de variables. Finalmente, partiendo de estas estimaciones, se construyó un indicador oportuno a través de la aplicación del método de Componentes Principales. Los resultados obtenidos muestran que el indicador estimado se mueve en línea con el indicador oportuno publicado por el INEGI.

Durante el periodo analizado ocurrieron diferentes choques que afectaron el estado de la actividad económica global. Ante este contexto, contar con indicadores de alta frecuencia

que logren capturar de forma oportuna y confiable las señales económicas resulta de gran utilidad para la toma de decisiones de corto plazo. Aunque, es importante mencionar que el indicador no busca reemplazar los indicadores oficiales publicados.

Referencias:

- Anderson, T. (1984). *An Introduction to Multivariate Statistical Analysis (2nd ed.)*. New York: Wiley.
- Armendáriz, T., & Ramírez, C. (2017). Estimación de un índice de condiciones financieras para México. *El Trimestre Económico*, 84(336), 899–946. <https://doi.org/10.20430/ete.v84i336.610>
- Arouba et al. (2007)] Aruoba, S. B., Diebold, F. X., y Scotti, C. (2007). *Real-time measurement of business conditions*. FRB International Finance Discussion Paper, 901, 07-028
- Bai y Ng (2002)] Bai, J., y Ng, S. (2002). *Determining the number of factors in approximate factor models*. *Econometrica*, 70(1), 191-221.
- Bartholomew, D. J. (1987). *Latent Variable Models and Factors Analysis*. Oxford: Oxford University Press.
- Banbura, M., Giannone, D., Modugno, M., & Reichlin, L. (2013). Now-Casting and the Real-time Data Flow. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.2284274>
- Bessec, M. (2012). *Short-term forecasts of French GDP: a dynamic factor model with targeted predictors*. <https://EconPapers.repec.org/RePEc:bfr:banfra:409>
- Bernanke et al. (2005) Bernanke, B. S., Boivin, J., y Eliasziw, P. (2005). *Measuring the effects of monetary policy: a factor-augmented vector autoregressive (FAVAR) approach*. *The Quarterly journal of economics*, 120(1), 387-422.
- Burns, A. F., & Mitchell, W. C. (1946). *Measuring business cycles*. New York: NBER.
- Camacho y Pérez-Quiros (2009)] Camacho, M., y Pérez-Quiros, G. (2009). *Ñ-Sting: España short term indicator of growth*. Cuadernos de Trabajo, Banco de España, No 0912.
- Camacho y Doménech (2012)] Camacho, M., y Doménech, R. (2012). *MICA-BBVA: A factor model of economic and financial indicators for short-term GDP forecasting*. *SERIEs*, 3(4), 475-497.
- Casares, F. (2017). Nowcasting: Modelos de Factores Dinámicos y Ecuaciones Puente para la Proyección del PIB del Ecuador. *Compendium: Cuadernos de Economía y Administración*, 4(8), 25–46. <http://www.revistas.espol.edu.ec/index.php/compendium/article/view/210>
- Chamberlain, G., & Rothschild, M. (1983). *Arbitrage, factor structure, and mean-variance analysis on large asset markets*. *Econometrica*, 51(5), 1281–1304.
- Corona, F., González-Farías, G., & López-Pérez, J. (2021). A nowcasting approach to generate timely estimates of Mexican economic activity: An application to the period of COVID-19. *arXiv preprint arXiv:2101.10383*.

- Corona, F., González-Farías, G., & Orraca, P. (2017). A dynamic factor model for the Mexican economy: are common trends useful when predicting economic activity? *Latin American Economic Review*, 26(1), 7. <https://doi.org/10.1007/s40503-017-0044-7>
- D'Amato, L., Garegnani, L., & Blanco, E. (2015). Nowcasting de PIB: Evaluando las condiciones cíclicas de la economía argentina. *Working Paper*, 2015/69. <http://hdl.handle.net/10419/126246>
- Doz et al. (2011)] Doz, C., Giannone, D., y Reichlin, L. (2011). *A two-step estimator for large approximate dynamic factor models based on Kalman filtering*. *Journal of Econometrics*, 164(1), 188-205.
- Eraslan, S., & Götz, T. (2021). An unconventional weekly economic activity index for Germany. *Economics Letters*, 204, 109881. <https://doi.org/10.1016/j.econlet.2021.109881>
- Favero, C. A., Marcellino, M., & Neglia, F. (2005). *Principal components at work: The empirical analysis of monetary policy with large data sets*. *Journal of Applied Econometrics*, 20(5), 603–620.
- Forni et al. (2005)] Forni, M., Hallin, M., Lippi, M., y Reichlin, L. (2005). *The generalized dynamic factor model: one-sided estimation and forecasting*. *Journal of the American Statistical Association*, 100(471), 830-840.
- Forni et al. (2007)] Forni, M., Giannone, D., Lippi, M., y Reichlin, L. (2009). *Opening the black box: Structural factor models with large cross sections*. *Econometric Theory*, 1319-1347.
- Fuleky, P. (Ed.). (2020). *Macroeconomic Forecasting in the Era of Big Data* (Vol. 52). Springer International Publishing. <https://doi.org/10.1007/978-3-030-31150-6>
- Geweke, J. (1977). The dynamic factor analysis of economic time series. In D. J. Aigner & A. S. Goldberger (Eds.), *Latent variables in socio-economic models*. Amsterdam: North Holland.
- Giannone et al. (2008)] Giannone, D., Reichlin, L., y Small, D. (2008). *Nowcasting: The real-time informational content of macroeconomic data*. *Journal of Monetary Economics*, 55(4), 665-676
- Gálvez-Soriano, O. D. J. (2020). Nowcasting del PIB de México usando modelos de factores y ecuaciones puente. *Estudios Económicos de El Colegio de México*, 213–265. <https://doi.org/10.24201/ee.v35i2.402>
- Hotelling, H. (1933). Analysis of a complex of statistical variables into principal components. *Journal of Educational Psychology*, 24(6), 417–441. <https://doi.org/10.1037/h0071325>
- INEGI. (s/f). *Indicador Oportuno de la Actividad Económica. Síntesis metodológica*. Instituto Nacional de Estadística y Geografía.
- Jolliffe, I. T. (2002). *Principal component analysis* (2nd ed). Berlin: Springer Series in Statistics.
- Lewis, D., Mertens, K., & Stock, J. (2020). *U.S. Economic Activity During the Early Weeks of the SARS-Cov-2 Outbreak*. <https://doi.org/10.3386/w26954>

- Mooi Erik and Sarstedt, M. and M.-R. I. (2018). Principal Component and Factor Analysis. En *Market Research: The Process, Data, and Methods Using Stata* (pp. 265–311). Springer Singapore. https://doi.org/10.1007/978-981-10-5218-7_8
- Motta, G., Hafner, C., & Von Sachs, R. (2011). *Locally stationary factor models: identification and nonparametric estimation*. *Econometric Theory*, 27(6), 1279-1319. doi:10.1017/S0266466611000053
- Pearson Karl, Lee Alice, Warren Ernest, Fry Agnes and Fawcett Cicely D. 1901VIII. Mathematical contributions to the theory evolution. —IX. On principle of homotyposis and its relation, the variability of the individual, and to that of the race. Part I. —Homotyposis in the vegetable Kingdom *Philosophical Transactions of the Royal Society of London. Series A, Containing Papers of a Mathematical or Physical Character* 197285–379
- Perez, J., & Brens, P. (2018). Modelo de Factores Dinámicos para Pronósticos de la Actividad Económica en Tiempo Real. *Santo Domingo, República Dominicana. Ministerio de Hacienda. Serie de documentos de investigación*.
- Rella, J. C. (2020). *Modelo Factorial Dinámico para la Economía Gallega*. Universidad de Santiago de Compostela.
- Santos, J. C. C. (2019). Pronósticos del PIB mediante modelos de factores dinámicos. *Revista de Análisis del BCB*, 30(1), 125–174. <https://ideas.repec.org/a/blv/journal/v30y2019i1p125-174.html>
- Sargent y Sims (1977)] Sargent, T. J., y Sims, C. A. (1977). *Business cycle modeling without pretending to have too much a priori economic theory*. *New methods in business cycle research*, 1,145-168.
- Shumway, R. H., & Stoffer, D. S. (1982). *An approach to time series smoothing and forecasting using the EM algorithm*. *Journal of Time Series Analysis*, 3(4), 253–264.
- Sierra Suárez, L. P., Collazos-Rodríguez, J. A., Sanabria-Domínguez, J., & Vidal-Alejandro, P. (2017a). La construcción de indicadores de la actividad económica: una revisión bibliográfica. *Apuntes del Cenes*, 36(64), 79–107. <https://doi.org/10.19053/01203053.v36.n64.2017.5132>
- Sierra Suárez, L. P., Collazos-Rodríguez, J. A., Sanabria-Domínguez, J., & Vidal-Alejandro, P. (2017b). La construcción de indicadores de la actividad económica: una revisión bibliográfica. *Apuntes del Cenes*, 36(64), 79–107. <https://doi.org/10.19053/01203053.v36.n64.2017.5132>
- Stock y Watson (1998a) Stock, J. H., y Watson, M. W. (1998). *Diffusion indexes*. NBER working paper, (w6702)
- Stock y Watson (1998)] Stock, J. H., y Watson, M. W. (1988). *A probability model of the coincident economic indicators* (No. w2772). National Bureau of Economic Research.

- Stock y Watson (2002)] Stock, J. H., y Watson, M. W. (2002). *Macroeconomic forecasting using diffusion indexes*. *Journal of Business & Economic Statistics*, 20(2), 147-162.
- Stock y Watson (2002a)] Stock, J. H., y Watson, M. W. (2002). *Forecasting using principal components from a large number of predictors*. *Journal of the American Statistical Association*, 97(460), 1167-1179.
- Stock, J. H., & Watson, M. W. (2016). *Dynamic Factor Models, Factor-Augmented Vector Autoregressions, and Structural Vector Autoregressions in Macroeconomics* (pp. 415–525). <https://doi.org/10.1016/bs.hesmac.2016.04.002>
- Stock, J., & Watson, M. (2010). Dynamic Factor Models. En M. P. Clements & D. F. Henry (Eds.), *Oxford Handbook of Economic Forecasting*. Oxford University Press. http://www.economics.harvard.edu/faculty/stock/files/dfm_oup_4.pdf
- Spearman C. *The proof and measurement of association between two things*, *Am J Psychol*, 1904, vol. 15 (pg. 72-101) Reprinted *Int J Epidemiol* 2010;39:1137–50
- Valk, S. de, Mattos, D. de, & Ferreira, P. (2019). Nowcasting: An R Package for Predicting Economic Variables Using Dynamic Factor Models. *The R Journal*, 11(1), 230. <https://doi.org/10.32614/RJ-2019-020>
- Watson, M. W., & Engle, R. F. (1983). Alternative algorithms for the estimation of dynamic factor, mimic and varying coefficient regression models. *Journal of Econometrics*, 23(3), 385–400.

ANEXO A: Revisión de Literatura

Trabajo de investigación y autores	Objetivo general	Datos e información	Estrategia Empírica	Principales Resultados
<p>A dynamic factor model for the Mexican economy: are common trends useful when predicting economic activity? (Corona, González-Farías & Orraca, 2020)</p>	<p>Implementar un modelo DFM no estacionario afín de estimar factores comunes que puedan ser usados en un modelo de autoregresión vectorial amplificado por factores (FAVAR) para estimar la actividad económica mexicana 1 y 2 pasos adelante.</p>	<ul style="list-style-type: none"> Originalmente se consideraron 511 variables, las cuales después de ser tratadas con la prueba de Dickey-Fuller, fueron filtradas hasta llegar a 211 (consideradas variables tradicionales). Las variables se agregaron en 13 bloques dependiendo de la categoría mostrada de INEGI (precios, actividad económica, misceláneo, desempleo, etc.) 	<ul style="list-style-type: none"> Se utiliza un modelo DFM no estacionario con variables para obtener tendencias comunes de la economía mexicana. Se busca la no estacionalidad con el análisis PANIC para los errores idiosincráticos, esto ayuda a comprobar que los bloques estén cointegrados. Estas tendencias comunes son usadas en una representación FAVAR para evaluar el error pronosticado a 1 y 2 pasos (1 and 2 steps ahead). La estimación es realizada con mínimos cuadrados ordinarios restrictivos. 	<ul style="list-style-type: none"> Las variables que mayor componen al factor son las del grupo misceláneo, la actividad económica y el comercio, mientras que precios, empleo y confianza del consumidor, son las menos relevantes. Cada tendencia común reduce el error de pronóstico. Este mismo error es menor respecto al ARIMA u otras regresiones de factor-aumentado.
<p>A nowcasting approach to generate timely estimates of Mexican economic</p>	<p>Realizar una estimación flexible y entrenada (DFM) con el objetivo de garantizar la consistencia del</p>	<ul style="list-style-type: none"> Se utiliza un método de selección de variables usando un criterio de oportunidad (oportuno) y correlación contemporánea respecto al IGAE. 	<ul style="list-style-type: none"> Construir una base de datos correlacionada y oportuna haciendo uso del método LASSO de regresión. Estimar los factores comunes usando una metodología de 2 pasos siguiendo a Doz et al (2011). 	<ul style="list-style-type: none"> Utilizar el “training” de los datos con una regresión lineal con errores ARMA permite seleccionar el modelo que mejor se ajuste para la generación del pronóstico inmediato.

Trabajo de investigación y autores	Objetivo general	Datos e información	Estrategia Empírica	Principales Resultados
activity: An application to the period of COVID-19 (Corona, González-Farías & Lopez-Perez, 2020)	componente de estimación desde un punto de vista estadístico. Se presenta un modelo de pronóstico inmediato para el IGAE que resulta competitivo e incorpora variables no tradicionales como <i>Google trends</i> .	<ul style="list-style-type: none"> Se ocuparon 68 series divididas en información tradicional (mensual), información tradicional de alta frecuencia (promedios mensuales) e información no tradicional de alta frecuencia (promedio mensual). 	<ul style="list-style-type: none"> Entrenar modelos de series de tiempo univariados con los factores comunes del DFM para seleccionar el mejor pronóstico inmediato. Determinar los intervalos de confianza para la carga de factores y el factor por sí mismo, para analizar la importancia de cada variable y la incertidumbre atribuida a la estimación. Combinar los pronósticos inmediatos que son estadísticamente iguales para generar los estimadores actuales. 	<ul style="list-style-type: none"> En los pesos de cada factor, las variables de alta frecuencia no tradicionales como Google trends resultaron relevantes para el modelo. La correlación del factor respecto al IGAE es menor en años anteriores como 2008, el rango de correlación es de: (0.75 a 0.97). El incorporar datos no tradicionales mejora la media absoluta de los errores. Los estimadores y pesos de los factores resultan estadísticamente significantes.
An unconventional weekly economic activity index for Germany (Eraslan & Götz, 2020)	La implementación de un índice semanal de la actividad económica (WEI) para Alemania inspirada en Lewis, Mertens y Stock (2020).	<ul style="list-style-type: none"> Construcción con datos de alta frecuencia haciendo uso de información relevante de distintos sectores, para la estimación macroeconómica a corto plazo. Cuenta con datos semanales, mensuales y trimestrales, entre ellos 	<ul style="list-style-type: none"> Para calcular el factor común de los indicadores disponibles en diferentes periodicidades, se transforman los indicadores para representar tasas de crecimiento comparables y se estiman los valores faltantes en caso de ser necesario. Se genera una tasa de crecimiento trimestral para todos los indicadores, los cuales representan el cambio en la 	<ul style="list-style-type: none"> El índice WAI es capaz de seguir el crecimiento trimestral del PIB, con una correlación de 0.9. Puesto que no está basado en un modelo econométrico, sus valores no pueden ser comparados directamente con las predicciones de corto plazo del crecimiento del PIB.

Trabajo de investigación y autores	Objetivo general	Datos e información	Estrategia Empírica	Principales Resultados
		<p>destacan el consumo de electricidad, índice de peaje de camiones, búsquedas en Google relacionadas con desempleo, PIB, entre otros.</p>	<p>tasa logarítmica de las últimas 13 semanas, lo que permite hacerlas comparables.</p> <ul style="list-style-type: none"> • El método de extractor de factor debe ser adaptado para contener datos faltantes, esto se consigue usando el algoritmo de maximización de expectativas (EM). 	
<p>Dynamic Factor Models, Factor-Augmented Vector Autoregressions, and Structural Vector Autoregressions in Macroeconomics (Stock & Watson, 2016)</p>	<p>Se busca replicar un modelo DFM similar al de literaturas anteriores, para comparar los resultados mediante modelos de auto regresión de vectores pequeños (SVAR).</p>	<ul style="list-style-type: none"> • Se ocuparon 207 variables utilizando datos trimestrales para la economía de Estados Unidos, tomando como referencia el periodo de 1959 al cuarto trimestre de 2014. Cabe señalar que solo 145 variables cubren este periodo en su totalidad. Al final, para la estimación de factores se usaron 139 variables, ya que algunas son 	<ul style="list-style-type: none"> • Se realizó una transformación de los datos para eliminar tendencias, esto mediante la integración aproximada de orden cero, para posteriormente estimar cada serie de forma no paramétrica, usando un filtro de paso bajo de 2 pesos, con bandas de 100 cuartos. • Modelo de índice único: se determina el número de factores estáticos, utilizando diversos métodos como el de Bai y Ng (2002) que sugiere 3 factores. • Modelo de múltiples factores: se calcula el número de factores a través 	<ul style="list-style-type: none"> • En el modelo de índice único, se concluye que el primer factor estimado (del método componentes principales) resulta ser un buen candidato para la creación de un índice trimestral de la actividad económica. • En la comparación del modelo DFM con VARs, se concluye que los VARs capturan aspectos importantes de la variación de los factores, aunque no logran cubrir el espacio de los factores y su innovación no permite cubrir el espacio de las innovaciones del factor

Trabajo de investigación y autores	Objetivo general	Datos e información	Estrategia Empírica	Principales Resultados
		<p>subconjuntos de variables agregadas</p> <ul style="list-style-type: none"> En este documento se pre procesó la información, removiendo las oscilaciones de baja frecuencia, sustrayendo tendencias estimadas y usando un filtro de bajo pase diseñado para capturar cambios en la media de las tasas de crecimiento en periodos de más de una década; esto es poco común en la literatura, pero se considera importante para trabajar con datos de Estados Unidos porque los conductores de tendencias de largo plazo en los datos cofundan los términos de modelaje de corto y largo plazo del DFM. 	<p>de diferentes métodos por lo que dependiendo de su aplicación se recomienda seleccionar el mejor resultado.</p> <ul style="list-style-type: none"> Se aplican diversas medidas estadísticas para comprobar la estabilidad de la muestra en 4 y 8 factores, encontrándose una inestabilidad elevada e identificándose 1 break en 1984. Se pone a prueba la viabilidad de aproximar el modelo DFM de 8 factores a través de un VAR de dimensionalidad baja. La identificación de los shocks se realiza por 3 métodos a los diferentes modelos: <ul style="list-style-type: none"> a. A través de la imposición de restricciones de tiempo para incluir ceros en la matriz H, considerando que las innovaciones en la cantidad de petróleo no respondan a shocks de demanda en un periodo corto. 	<ul style="list-style-type: none"> Se encontró también que el modelo DFM al lograr resumir una gran cantidad la información, y también reducir el error de medida y variación idiosincrático, captura innovaciones de factor con más información que con VARs pequeñas. <p>Resultados específicos:</p> <ul style="list-style-type: none"> La identificación de “precio del crudo exógeno” demuestra que para los 3 modelos el SIRF es muy similar, especialmente en periodos de 8 trimestres, esto debido a 2 razones: una fracción importante de la varianza del cambio de los precios está explicada por su componente común, haciendo que la innovación en el componente común del factor no observado del DFM sea similar al del factor FAVAR y los errores de pronóstico de los cambios en el precio del crudo 1 trimestre adelante son similares en ambos modelos (VAR de 8 variables o factores).

Trabajo de investigación y autores	Objetivo general	Datos e información	Estrategia Empírica	Principales Resultados
			<p>b. Restricciones inequitativas, suponiendo que un shock positivo de oferta empuja hacia abajo los precios e incrementa el consumo, mientras que un shock positivo de demanda empujaría precios y consumo.</p> <p>c. Identificando la respuesta de shocks de oferta usando disrupciones de la oferta exógenas (como la invasión de Iraq a Kuwait).</p> <ul style="list-style-type: none"> • Se utiliza un modelo SDFM con 8 factores, un FAVAR en donde 1 o más de los factores se maneja como observable y un modelo de 8 variables SVAR. • El método paramétrico de formular y estimar el DFM en estado-espacio tiene ventajas, produce MLE y es ameno con métodos de análisis bayesiano, además de que permite manipular la información con datos 	<ul style="list-style-type: none"> • El shock de crudo en SDFM tiende a ser más prolongado. • Se encuentra que, en el horizonte de 6 trimestres, los shocks identificados explican no más del 10% de la variación en el PIB de Estados Unidos, entre otras variables. <p>Resultados generales:</p> <ul style="list-style-type: none"> • No hay diferencia en ocupar un factor no observado en SDFM o uno observado en FAVAR. • En el segundo método de identificación los resultados dependen de que modelo es usado para el factor manejado como no observable en el SDFM. • Shocks de demanda agregada son una fuerza importante en los movimientos del precio. • Si el ajuste (R^2) es elevado, se puede afirmar que un número pequeño de factores describe co-movimientos de variables económicas.

Trabajo de investigación y autores	Objetivo general	Datos e información	Estrategia Empírica	Principales Resultados
			faltantes y datos de distinta frecuencia.	<ul style="list-style-type: none"> Los modelos DFM resultan ser de gran utilidad en la aplicación macroeconómica como herramienta para realizar forecast y nowcast.
Dynamic Factor Models (Watson, 2010)	Describir el modelo DFM a través de resultados teóricos y aplicaciones.	No aplica	<ul style="list-style-type: none"> La premisa de los DFM es que existen factores latentes dinámicos subyacentes a series de tiempo (con media 0). Estimación de factor: La estimación dominio-tiempo puede ser dividido en 3 etapas: <ul style="list-style-type: none"> i) La primera consiste en un modelo estimado de baja dimensión en el dominio del tiempo, usando la máxima probabilidad Gaussiana y el filtro de Kalman. Este método provee estimadores óptimos bajo los supuestos del modelo y sus parámetros. Aunque al ser desarrollados por optimización no lineal, se restringe el número de parámetros y, por ende, el número de series. 	<ul style="list-style-type: none"> Al comparar estimadores cuando el número de series es pequeño, el método de componentes generales principales genera buenos pronósticos de variables. Los parámetros y factores de DFM también pueden ser estimados por métodos bayesianos. Los pronósticos se calculan de 2 formas: pasos múltiples directos e iteraciones de pasos múltiples. En teoría, cualquiera de estas 2 formas puede ser mejor que la otra, la primera ignora errores de especificación en el VAR mientras la segunda resulta más eficiente cuando el modelo VAR está correctamente especificado.

Trabajo de investigación y autores	Objetivo general	Datos e información	Estrategia Empírica	Principales Resultados
			<p>ii) La segunda se centra en una estimación no paramétrica con un mayor número de series utilizando métodos de promedio transversales (método de componentes principales, entre otros). El estimador de los componentes principales es consistente.</p> <p>iii) La tercera generación usa estimadores consistentes no paramétricos para estimar los parámetros del modelo espacio-estado. Se sugiere el uso de modelos Bayesianos.</p>	<ul style="list-style-type: none"> • El uso de factores como variables instrumentales resulta útil para condensar información. • La aplicación de FAVAR permite superar 2 problemas estructurales del modelo VAR: el primero es que un modelo VAR no restringido no es viable cuando las series son grandes. Por otro lado, al utilizar un VAR de baja dimensión genera problemas al invertir el “VAR innovations” (problema de la no fundamentabilidad de los SVARS). • Por último, existen 3 líneas de investigación que extienden el uso de modelos de factores dinámicos: <ol style="list-style-type: none"> 1. DFM con breaks y parámetros “time-varying”. 2. Incorporación de cointegración y corrección de errores. 3. DFM jerárquicos.
Modelo Factorial Dinámico para la Economía	En este documento se define el modelo factorial dinámico	<ul style="list-style-type: none"> • El conjunto de datos considera 17 variables relevantes (de 24 variables 	<ul style="list-style-type: none"> • Considerar las variables como logarítmicas y transformarlas en series estacionarias. 	<ul style="list-style-type: none"> • El MFD resulta útil para condensar información relevante sobre una amplia cantidad de variables y,

Trabajo de investigación y autores	Objetivo general	Datos e información	Estrategia Empírica	Principales Resultados
Gallega (Rella, 2019-2020)	(MFD), conceptos clave, la motivación en econometría del modelo, características básicas por tipos de modelos. El modelo se aplica en la economía gallega, a través de la variable macroeconómica PIB, haciendo uso de un MFD.	originales) y cubre un periodo de 1995 a 2019. <ul style="list-style-type: none"> El criterio de selección de variables es a través de las correlaciones de las covariables con el PIB. Posteriormente, las series se estandarizan y estacionalizan. 	<ul style="list-style-type: none"> Después de contar con el panel, se estima el número de factores. Por último, se realiza el ajuste del PIB sobre el factor, por medio de una regresión con corrección del error mediante un modelo ARIMA; los parámetros de la regresión se estiman con todos los datos disponibles del PIB. Con el factor estimado se realiza el backtest, del cual se tiene información. Para el nowcast y forecast se ocupa el MFD, al no contar con datos del PIB. Se concluye con un ejercicio de simulación repitiendo el punto anterior, bajo el supuesto de contar con un panel hasta un periodo anterior (primer trimestre de 2020). 	también, ofrece una simplificación de problemas de alta dimensión. <ul style="list-style-type: none"> Aun cuando este trabajo tiene como objeto de estudio la economía de Galicia, la profundidad de la literatura alrededor del MFD y la justificación que da para su uso en economía, le da una mayor relevancia.
Indicador Oportuno de la Actividad Económica (INEGI)	En 2019 se implementó un modelo de nowcasting para la actividad económica de México; esto con el	Se consideran variables relacionadas con la actividad económica, tales como: ventas totales, confianza (comercio, construcción, manufacturas,	<ul style="list-style-type: none"> Se utiliza la regresión LASSO como método de selección de variables. Estimación de un modelo de factores dinámicos haciendo uso de la metodología de Doz (2011), con el 	<ul style="list-style-type: none"> Se estiman los intervalos de confianza de los factores y las cargas según Bai (2003).

Trabajo de investigación y autores	Objetivo general	Datos e información	Estrategia Empírica	Principales Resultados
	fin de estimar de manera oportuna el trimestre en curso del Producto Interno Bruto. En 2020 se hizo uso de lo anterior e inició la publicación oficial del Indicador Oportuno de la Actividad Económica (IOAE).	servicios), demanda de combustibles, cotizaciones de mercado mexicano, asegurados del IMSS, producción industrial de USA, agregado monetario M4, importaciones, ventas al por menor, pedidos manufactureros, ocupación hotelera y variables de interés en Google trends, entre otras.	<p>objetivo de utilizar los factores significativos que minimizaran el error de predicción.</p> <ul style="list-style-type: none"> • Por último, se modela la dinámica de los factores dinámicos ajustando un vector autorregresivo diagonal que requiere el filtro Kalman, para obtener la dinámica temporal del factor. • Obteniendo los factores, se incorpora el modelo nowcasting • El IOAE se obtiene mediante la combinación de nowcasting con errores de estimación de datos, considerando la mediana de estos y ponderando los pesos de acuerdo con el error de estimación. 	<ul style="list-style-type: none"> • Finalmente, el IOAE se obtiene mediante la combinación de nowcasts con errores de estimación en datos de prueba estadísticamente iguales según la prueba de DieboldMariano.
La construcción de indicadores de la actividad económica: una revisión bibliográfica (Sierra,	El objetivo es construir un indicador oportuno de la actividad económica para el Valle de Cauca, Colombia, utilizando el modelo de factores	<ul style="list-style-type: none"> • Para la construcción del IMAE de la región, se utilizan 12 variables relevantes de la economía regional como: consumo de energía del sector no residencial, venta de 	<ul style="list-style-type: none"> • Se aplica el método de 3 pasos: <ol style="list-style-type: none"> 1. Siguiendo a Stock y Watson (1991), acompañado del filtro de Kalman, estima un factor común a toda la serie, este depende de la estimación de los pesos o cargas. 	<ul style="list-style-type: none"> • Se analizó el modelo y se realizó un pronóstico fuera de muestra y se obtuvo un error absoluto medio de 0.25%. • Aun cuando la aplicación del modelo suele realizarse para economías a nivel nacional, en el documento se

Trabajo de investigación y autores	Objetivo general	Datos e información	Estrategia Empírica	Principales Resultados
Collazos, Sanabria & Vidal, 2017)	dinámicos. El documento incluye la descripción de algunas técnicas de estimación, como componentes principales y filtro de Kalman.	vehículos, exportaciones, confianza del consumidor, índice de condiciones económicas, entre otros.	<ol style="list-style-type: none"> 2. Se aplica el método de Litterman (1983) para mensualizar el PIB anual a partir del factor común estimado en el paso 1. 3. Se aplica la metodología de los modelos estructurales univariantes de Harvey (1989), dando como resultado una trayectoria cíclica del IMAE sobre una media cero. 	demuestra la viabilidad de aplicar los MFD a economías regionales.
Nowcasting del PIB de México usando Modelos de Factores y Ecuaciones Puente (Galvez-Soriano, 2018)	Se evalúan 5 modelos de nowcasting: un MFD, 2 modelos de ecuaciones puente y 2 modelos de componentes principales con datos de alta frecuencia para pronosticar el PIB trimestral.	<ul style="list-style-type: none"> • Se ocupan 3 conjuntos de datos para las variables explicativas. Los datos están divididos en variables duras y suaves. Las primeras incluyen una relación sólida con el PIB, mientras que las segundas proporcionan información más oportuna. • Para el caso de falta de información, se elaboraron modelos ARIMA para 	<ul style="list-style-type: none"> • El nowcasting se estima a través de mínimos cuadrados ordinarios en donde el PIB es una función de sus propios rezagos. • En ecuaciones puente se buscan las variables explicativas en los indicadores mensuales. • Para el modelo de factores dinámicos se utiliza la dinámica de los factores considerada por Giannone (2008) compuesta de 3 ecuaciones. • El modelo de análisis de componentes principales se utiliza para la reducción de datos. 	<ul style="list-style-type: none"> • El uso de ecuaciones puente con la prueba de Diebold-Mariano es la mejor técnica para estimar el comportamiento de la actividad económica en Mexico. • El análisis de pronóstico de BE sugiere que la varianza disminuye cuando se va incluyendo información disponible, • Se identificaron 2 componentes esenciales en el mejoramiento de la precisión de estimación: la publicación de la Balanza Comercial del segundo mes y el IGAE.

Trabajo de investigación y autores	Objetivo general	Datos e información	Estrategia Empírica	Principales Resultados
		<p>pronosticar observaciones faltantes.</p>	<ul style="list-style-type: none"> Para medir la robustez de los resultados, se aplicó el Error Absoluto Medio del Pronostico como criterio de pérdida y Bartlett Kernel para calcular la varianza de largo plazo de la serie de diferencias. 	<ul style="list-style-type: none"> El modelo de mayor precisión fue aquel que utilizó la mayor cantidad de datos.
<p>U.S. Economic Activity during the early weeks of The Sars-Cov-2 Outbreak (Lewis, Mertens & Stock, 2020)</p>	<p>Se describe el índice semanal económico (WEI) desarrollado para seguir los cambios económicos asociados a la pandemia en Estados Unidos.</p>	<ul style="list-style-type: none"> Los datos utilizados abarcan la actividad económica real. Se utilizan 10 series de tiempo del periodo de enero 2008 a febrero 2020: Ventas retail, Índice de consumidor Rasmussen, seguros de desempleo, producción de acero, venta de gasolina (y destilados) a clientes finales, tráfico ferroviario, etc. 	<ul style="list-style-type: none"> Estimar los factores a través de 2 métodos: componentes principales y el método de estado-espacio. Aplicar test de robustez para observar cambios en el modelo cuando se añaden o quitan variables. Para la producción de valores preliminares se usa un pronóstico de regresión del WEI con 2 lags, así como para las variables faltantes. Para medir el contenido predictivo de WEI, este se compara con indicadores de baja frecuencia con la finalidad de medir una aproximación de la señal arrojada por el índice después de su primera, segunda, tercera y cuarta semana del mes. 	<ul style="list-style-type: none"> Con el método de componentes principales se encontró que el Índice (WEI) explica más de la mitad de la varianza de las series. La prueba de robustez arroja que el quitar o añadir variables no tiene un impacto importante en el WEI. Para el crecimiento del PIB, el 85% de la variación es explicada por el WEI.

Trabajo de investigación y autores	Objetivo general	Datos e información	Estrategia Empírica	Principales Resultados
			<ul style="list-style-type: none"> Se aplica el nowcast para otras variables tales como producción industrial y empleo. 	
<p>Modelo de Factores Dinámicos para Pronósticos de la Actividad Económica en Tiempo Real (Perez y Brens, 2018)</p>	<ul style="list-style-type: none"> Realizar un pronóstico de corto plazo del crecimiento de la actividad económica utilizando un modelo de factores dinámicos aplicado a la economía de Republica Dominicana. 	<ul style="list-style-type: none"> Se seleccionan variables con criterios de selección de Quiroz y Camacho (2008) de 1991 a mediados de 2018. Se ocupan datos que capturan la actividad por el lado de la demanda, oferta, sector externo, fiscal y otros indicadores de ingreso. 	<ul style="list-style-type: none"> Se emplea el Filtro de Kalman para completar las series cortas con datos faltantes y se introducen series suaves. Se estiman 3 modelos con diferentes supuestos en la dinámica del componente común: <ol style="list-style-type: none"> El modelo 1 se asume un proceso autorregresivo de orden 2 (AR(2)) El modelo 2 se asume un proceso autorregresivo de orden 1 (AR(1)) El último modelo asume un proceso autorregresivo y de medias móviles de orden 1 (ARMA(1,1)) 	<ul style="list-style-type: none"> Las variables de mayor carga son aquellas de indicadores duros respecto a las suaves. El factor explica la mayor parte de la varianza de crecimiento del IMAE. El promedio resulta el mejor modelo para las proyecciones, pero realizando pruebas como Diebold-Mariano, se llega a la conclusión que todos los modelos poseen el mismo nivel de precisión predictiva.
<p>Nowcasting de PIB: evaluando las condiciones cíclicas de la</p>	<p>Realizar un nowcasting para el PIB de Argentina utilizando 2 enfoques:</p>	<ul style="list-style-type: none"> El conjunto de datos inicial incluye 37 indicadores del ciclo económico incluyendo datos 	<ul style="list-style-type: none"> Se divide el conjunto de indicadores en 2 grupos: aquellos disponibles al menos 10 días después de finalizado cada mes y aquellos que se publican 	<ul style="list-style-type: none"> Al comparar los dos modelos con uno AR(1) se observa que los modelos nowcast tienen mejor capacidad predictiva.

Trabajo de investigación y autores	Objetivo general	Datos e información	Estrategia Empírica	Principales Resultados
economía argentina (D'Amato, Garegnani & Blanco, 2018)	ecuaciones puente y modelo de factores.	financieros, fiscales, encuestas de confianza del consumidor y ventas de automóviles de 1997 a 2013.	<p>con un retraso superior a 10 días, pero menor a 30 días.</p> <ul style="list-style-type: none"> Modelo de Factores: Se calcula el coeficiente de correlación de los indicadores respecto al PIB. Basándose en el screeplot, se seleccionan 4 factores a estimar. <p>Ecuaciones puente: Se estiman modelos bivariados autorregresivos de rezagos distribuidos para cada uno de los indicadores ciclo y finalmente, se aplican evaluaciones en la capacidad predictiva con el test Giacomini y White (2004).</p>	<ul style="list-style-type: none"> Se encontró que el modelo de factores dinámicos tiene mayor capacidad predictiva que el modelo de ecuaciones puente. Con el test de Giacomini y White, se encontró que estos modelos nuevamente superan al modelo AR(1), mientras que el modelo de factores dinámicos supera el de ecuaciones puente.

ANEXO B: Contrucción de un indicador semanal que mida la evolución de los precios.

En esta nota se describe el cálculo de un indicador de precios con frecuencia semanal con el fin de dar seguimiento a la evolución de los precios en el muy corto plazo. Para ello se emplea el Índice de Precios al Consumidor quincenal publicado por INEGI.

La estimación de este indicador se realiza mediante los siguientes pasos:

1. Se calcula la variación quincenal del Índice de Precios al Consumidor.
2. La variación obtenida en el punto anterior se divide a la mitad. Lo anterior bajo el supuesto de que cada quincena se compone de dos semanas. Así, la variación estimada puede expresarse como:

$$\Pi_w = \frac{1}{2} * \left(\left(\frac{INPC_t}{INPC_{t-1}} \right) - 1 \right) * 100$$

3. Posteriormente, para calcular el Índice de Precios semanal se aplica la siguiente fórmula:

$$INPC_w = INPC_{t-1} * \left(1 + \left(\frac{\Pi_w}{100} \right) \right)$$

4. Finalmente, las variables expresadas en términos nominales son deflactadas con el Índice semanal obtenido en el punto anterior.