

Departamento de Economía

Tipo de documento: Tesis de maestría



Maestría en Econometría

Estimación de un indicador sintético de actividad económica mediante modelos factoriales dinámicos. Aplicación empírica al caso del Municipio de General Pueyrredon, Buenos Aires

Autoría: Fernández, Mailén

Fecha: 2025

¿Cómo citar este trabajo?

Fernández, M. (2025). "Estimación de un indicador sintético de actividad económica mediante modelos factoriales dinámicos. Aplicación empírica al caso del Municipio de General Pueyrredon, Buenos Aires". [Tesis de maestría. Universidad Torcuato Di Tella].

Repositorio Digital Universidad Torcuato Di Tella

<https://repositorio.utdt.edu/handle/20.500.13098/13558>

El presente documento se encuentra alojado en el Repositorio Digital de la **Universidad Torcuato Di Tella** bajo una licencia Creative Commons Atribución-No Comercial-Compartir Igual 4.0 Internacional
Dirección: <https://repositorio.utdt.edu>



**UNIVERSIDAD
TORCUATO DI TELLA**

UNIVERSIDAD TORCUATO DI TELLA
DEPARTAMENTO DE ECONOMÍA
MAESTRÍA EN ECONOMETRÍA

**Estimación de un indicador sintético de actividad económica mediante
modelos factoriales dinámicos. Aplicación empírica al caso del
Municipio de General Pueyrredon, Buenos Aires**

Alumna: Lic. Fernandez Mailen

Legajo: 23F1980

Tutora: Dra. Lacaze, M. Victoria

Fecha: 06/2025

Estimación de un indicador sintético de actividad económica mediante modelos factoriales dinámicos. Aplicación empírica al caso del Municipio de General Pueyrredon, Buenos Aires

Resumen

Este trabajo presenta una estimación del Indicador Sintético de Actividad Económica para el Partido de General Pueyrredon ($ISAE - GP$) a partir de la aplicación de un modelo factorial dinámico. Utilizando un conjunto de series representativas del entramado productivo local, se implementa un enfoque multivariado que identifica un componente común latente y modela su evolución temporal mediante un sistema en espacio de estados, estimado con el filtro de Kalman. El objetivo central es evaluar el desempeño de esta versión del indicador ($ISAE - GP_{MFD}$) en comparación con una variante previamente construida bajo la metodología de *Conference Board* ($ISAE - GP_{TCB}$). Se examina la trayectoria del nuevo indicador, destacando su capacidad para captar con mayor sensibilidad los principales eventos del ciclo económico local y contrastando su comportamiento con el de la versión TCB.

Palabras clave

Indicadores compuestos; Ciclos económicos regionales; Filtro de Kalman; Análisis multivariado; Espacio de estados.

Abstract

This study presents an estimate of the Synthetic Economic Activity Indicator for the Municipality of General Pueyrredon ($ISAE - GP$), based on the application of a dynamic factor model. Using a set of series representative of the local productive structure, a multivariate approach is implemented to identify a latent common component and model its temporal evolution through a state-space system estimated via the Kalman filter. The main objective is to assess the performance of this version of the indicator ($ISAE - GP_{MFD}$) in comparison with a previously developed variant based on The Conference Board methodology ($ISAE - GP_{TCB}$). The trajectory of the new indicator is analyzed, highlighting its capacity to capture the main events of the local economic cycle with greater sensitivity and contrasting its behavior with that of the TCB version.

Key words

Composite indicators; Regional economic cycles; Kalman filter; Multivariate analysis; State-space

Índice

1.	Introducción.....	4
2.	Marco conceptual	7
2.1	Construcción de indicadores sintéticos de actividad económica.....	7
2.1.1	Metodología de TCB.....	8
2.1.2	Metodología de Factores Dinámicos.....	12
2.2	<i>ISAE – GP</i> : síntesis metodológica y principales conclusiones	16
3.	Estructura productiva local y datos	19
3.1	Perfil productivo del Municipio de General Pueyrredon	19
3.2	Definición y operacionalización de variables	20
4.	Metodología de Factores Dinámicos	23
5.	Resultados	28
5.1	Estimación del componente estático	29
5.2	Estimación del componente dinámico	31
6.	Conclusiones	38
7.	Referencias bibliográficas	41

1. Introducción

El análisis de la evolución económica de un país o región requiere de mediciones que cuantifiquen la riqueza generada y describan el comportamiento de la actividad, para ser insumos relevantes en el diseño de políticas públicas. Entre las principales macromagnitudes económicas se encuentra el Producto, entendido como el valor monetario de los bienes y servicios finales generados en una jurisdicción durante un período determinado.

En Argentina, el Instituto Nacional de Estadística y Censos (INDEC) publica trimestralmente el Producto Bruto Interno (PBI), con un rezago de aproximadamente noventa días. Para responder a una demanda de información más oportuna, el organismo también difunde el Estimador Mensual de Actividad Económica (EMAE), en forma más contemporánea.

Cuando la medición del Producto se realiza a nivel subnacional, como en provincias o municipios, se la denomina Producto Bruto Geográfico (PBG) un indicador que se calcula con frecuencia anual. En nuestro país, su elaboración fue delegada en 1993 a los institutos provinciales de estadística, generando fuertes disparidades en la cobertura y actualización de las mediciones provinciales. En algunos casos puntuales existen estimaciones a escala municipal o departamental que emplean información de fuentes primarias locales. Tal es el caso de la región Gran Rosario en Santa Fe (Castagna et al., 2001) o del Partido de General Pueyrredon en Buenos Aires, donde se han desarrollado estimaciones del PBG para los períodos 1993-1999 y 2004-2012 (Atucha et al., 1999; Wierny, 2012; Lacaze et al., 2014).

En un país extenso y heterogéneo como Argentina, la producción de información estadística subnacional resulta clave para captar las particularidades territoriales. La existencia de ciclos económicos regionales, muchas veces desfasados o divergentes respecto de las tendencias nacionales, justifica el desarrollo de herramientas analíticas que permitan monitorear la coyuntura a menor escala geográfica (Trujillo Aranda et al., 2000). En este contexto, distintas iniciativas promovidas por organismos estadísticos provinciales y universidades han desarrollado la construcción de indicadores sintéticos de actividad económica a fin de dar cuenta de la dinámica productiva y, a la vez, disponer de información relevante con una frecuencia superior a la del PBG. Así, estos indicadores, al combinar información de múltiples fuentes, permiten monitorear

la economía local en tiempo más cercano al presente, convirtiéndolos en instrumentos clave para la formulación de políticas públicas.

Estos indicadores adquieren mayor relevancia en el contexto de ciudades o regiones con marcada estacionalidad económica, como Mar del Plata, cabecera del Municipio de General Pueyrredon, al reflejar el impacto de variaciones ligadas al turismo y otras dinámicas locales específicas sobre el empleo, los consumos energético e hídrico y el uso de infraestructura, entre otros aspectos. A partir de un conjunto de series representativas de la dinámica productiva local y mediante la aplicación de diversos procedimientos estadísticos, se ha estimado el Indicador Sintético de Actividad Económica de General Pueyrredon (*ISAE – GP*), con base enero 2004=100 y hasta el año 2023 inclusive (Lacaze et al 2021, 2025) empleando la metodología propuesta por *The Conference Board* (TCB). Este enfoque, ampliamente utilizado a nivel internacional, se basa en el cálculo de un promedio ponderado de tasas de variación simétricas de las variables o series representativas de distintos sectores económicos que se eligen para integrar el indicador (TCB, 2001). La metodología ofrece una solución operativamente simple y robusta cuyo enfoque es esencialmente estático.

Las series que componen el *ISAE – GP* son heterogéneas y no están correlacionadas entre sí, pero, a través de un componente común inobservable, reflejan de manera conjunta la evolución de la actividad económica local. Esto plantea dos interrogantes centrales que motivan esta investigación: ¿ese componente común presenta una dinámica temporal relevante? Y, de ser así, una metodología alternativa, como la de factores dinámicos ¿permitiría construir un indicador más preciso y representativo del ciclo económico del Partido de General Pueyrredon?

Hasta el momento, no se registran antecedentes en Argentina del uso de modelos factoriales dinámicos para estimar indicadores sintéticos de actividad económica en jurisdicciones sub provinciales y su aplicación, a nivel provincial, ha sido poco difundida. En este marco, el presente trabajo propone realizar una estimación del *ISAE – GP*, empleando la metodología de factores dinámicos. Este enfoque multivariado permite identificar un componente común latente entre las series seleccionadas y modelar su evolución temporal a través de un sistema en el espacio de estados, estimado con el filtro de Kalman (Kalman, 1960).

El objetivo general del trabajo es evaluar si el indicador -que será llamado *ISAE – GP_{MFD}*- estimado mediante esta metodología, permite captar con mayor

precisión la tendencia subyacente de la economía local, mejorar la identificación de puntos de giro y representar de forma más realista la duración de las fases expansivas y contractivas del ciclo económico local, respecto de los que brinda el indicador ya disponible. Para ello, se emplea un conjunto ya seleccionado de series representativas del entramado productivo local, se aplican los tratamientos estadísticos necesarios y se estima el modelo factorial dinámico para la construcción del nuevo indicador. Finalmente, se analiza el comportamiento cíclico del $ISAE - GP_{MFD}$ y se lo contrasta con la versión previamente desarrollada bajo la metodología TCB, que a los fines de este trabajo será llamado $ISAE - GP_{TCB}$, con el propósito de comparar su desempeño y capacidad de seguimiento de la coyuntura económica local.

2. Marco conceptual

2.1 Construcción de indicadores sintéticos de actividad económica

Un indicador económico es un parámetro que ofrece información básica, clasificada y sistematizada, construido a partir de una o varias variables estadísticas, cuyo propósito es describir, sintetizar o anticipar el comportamiento de un fenómeno económico determinado (Cabrera et al., 2005). En el caso de los indicadores sintéticos se integran múltiples series en una sola medida agregada, permitiendo representar de forma resumida la evolución de procesos económicos complejos como la actividad económica. Estos indicadores reúnen movimientos de series heterogéneas que avanzan en sincronía y, al ser agregadas, dan lugar a un comportamiento homogéneo respecto del ciclo económico general (Moore, 1960).

Según su relación temporal con el ciclo económico, los indicadores sintéticos pueden clasificarse en coincidentes, líderes o rezagados. Los indicadores coincidentes se mueven en simultáneo con el ciclo y permiten identificar la fase actual de la economía. Los indicadores líderes se anticipan a los puntos de giro, lo que los convierte en herramientas útiles para prever cambios en la dinámica económica. Por su parte, los indicadores rezagados reaccionan con posterioridad a las fluctuaciones del ciclo, siendo valiosos para confirmar *ex post* la magnitud de una expansión o recesión.

Este tipo de indicadores permite hacer un seguimiento más contemporáneo (normalmente, de tipo mensual o trimestral) de la evolución económica lo cual resulta particularmente valioso en contextos subnacionales donde los agregados oficiales, como el Producto Bruto Geográfico, se presentan con frecuencia anual y, a menudo, se publican con rezagos significativos.

En Argentina y desde la década del 2000, se han desarrollado proyectos destinados a estimar indicadores sintéticos de actividad económica regional elaborados sobre la base de un reducido número de series estadísticas disponibles y correlacionadas con el ciclo económico. El programa pionero fue el de Ciclos Económicos y de Crecimiento de la Universidad Nacional de Tucumán del Dr. Juan Mario Jorrat (Jorrat y Salvatierra, 1999; Jorrat, 2003; 2005). Sus aportes estimularon la elaboración de trabajos que se replicaron para casi la totalidad de las provincias, como también para jurisdicciones sub provinciales.

Existen diversas metodologías para la construcción de indicadores sintéticos de actividad económica. Tradicionalmente, estos pueden ser elaborados siguiendo el enfoque desarrollado por el *National Bureau of Economic Research* (NBER), o bien, mediante modelos de factores dinámicos o, incluso utilizando enfoques basados en series temporales tales como modelos autorregresivos univariados, vectores autorregresivos (VAR) o modelos de indicadores líderes.

2.1.1 Metodología de TCB

La primera de las opciones enunciadas es una de las metodologías más difundidas para este propósito. Comúnmente denominada como “método de diferencias simétricas”, fue desarrollada por el NBER y transferida, desde 1995, a *The Conference Board*, institución que ha difundido su uso a escala internacional.

La aplicación de esta estrategia implica asignar a las series intervinientes pesos relativos inversamente relacionados con su grado de volatilidad, resultando idénticos una vez que la volatilidad ha sido estandarizada (TCB, 2001). Se emplean los cambios porcentuales simétricos y el promedio ponderado de las series de actividad que componen el indicador para la construcción del mismo.

Bajo este enfoque, la elaboración del indicador se organiza en cinco etapas (Malvicino et al., 2021). En primer lugar, se calculan los cambios porcentuales simétricos mensuales para cada serie obteniendo, de esta manera, una medida estandarizada de la variación relativa para cada componente. En segundo lugar, dichas variaciones se ajustan aplicando un factor de estandarización w_i , definido como el inverso del desvío estándar de cada serie. Este ajuste busca homogeneizar la contribución de cada variable de modo que las series más volátiles no dominen la evolución del índice. Así, se obtienen las contribuciones mensuales ajustadas. En la tercera etapa, se agregan las contribuciones ajustadas de todas las series para cada período, generando un valor compuesto que resume el comportamiento conjunto de las variables seleccionadas. En el cuarto paso, a partir de estas variaciones agregadas, se reconstruyen de forma recursiva los niveles preliminares del índice, utilizando la fórmula simétrica de cambio porcentual. Finalmente, en el quinto paso, se re-escalan los niveles del índice tomando como referencia un año base al que se le asigna el valor inicial, obteniendo así una serie final interpretable y comparable a lo largo del tiempo.

En nuestro país, esta estrategia fue aplicada en distintas provincias y regiones subnacionales. Entre los antecedentes más destacados se encuentran los trabajos de Jorrat (2003) para Tucumán; Michel Rivero (2007) para Córdoba; Arredondo et al. (2009) para Santa Fe; Martínez et al. (2017) para Salta y Pizzi et al. (2019) para Mendoza. A nivel sub provincial también fue implementada por Lapelle (2015) para el Gran Rosario (provincia de Santa Fe); Delbianco (2017) para Bahía Blanca (provincia de Buenos Aires); Malvicino et al. (2021) para Bariloche (provincia de Río Negro) y Lacaze et al. (2021; 2025) para General Pueyrredon (provincia de Buenos Aires).

Los trabajos que aplican la metodología TCB a nivel subnacional en Argentina han demostrado su utilidad para monitorear la trayectoria de la actividad económica regional, aunque también revelan ciertas limitaciones comunes, principalmente asociadas a la disponibilidad de datos y su cobertura temporal. En la provincia de Tucumán, Jorrat (2003) construye el Índice Mensual de Actividad Económica de Tucumán (IMAT) a partir de siete series seleccionadas y valida su comportamiento mediante el Índice Compuesto Coincidente de Argentina (ICCO), indicador que refleja la evolución de la actividad económica general en el país y usa la información de ocho series, incluido el PBI (Jorrat, 2005). Encuentra que el IMAT refleja adecuadamente la dinámica provincial y que la metodología resulta apropiada. En Córdoba, Michel Rivero (2007) desarrolla un indicador basado en diez series, contrastado con el ICCO nacional y el PBI. El estudio destaca la robustez del indicador para el seguimiento mensual de la actividad económica provincial. De forma similar, Arredondo et al. (2009) aplican la metodología en Santa Fe utilizando catorce series y validan el Índice Compuesto Coincidente de Actividad Económica de Santa Fe (ICASFe), diseñado para monitorear mensualmente la evolución de la actividad económica de la provincia, mediante su correlación con el PBI, el PBG y el ICCO, alcanzando un coeficiente de 0.76 con el Producto nacional.

Martínez et al. (2017) proponen una versión optimizada del indicador para la provincia de Salta, seleccionando once series representativas entre las cuales se incluye a la actividad turística. Emplean el EMAE como macromagnitud de referencia. En Mendoza, Pizzi et al. (2019) estiman una primera aproximación de su indicador para el cual contemplan la utilización de 23 series componentes de actividad económica provincial, aunque advierten sobre la falta de longitud

temporal y disponibilidad de algunas de ellas. A pesar de ello, logran validar la evolución del indicador mediante comparaciones con el EMAE y el PBI nacional.

A nivel sub provincial, Lapelle (2015) construye el Indicador Sintético de Actividad de la Región Rosario (ISARR) para el Gran Rosario a partir de once series y lo valida frente al PBG local, el EMAE y el ICASFe, mostrando una buena capacidad de seguimiento respecto de los indicadores de referencia. Por su parte, Delbianco (2017) elabora un indicador para Bahía Blanca utilizando ocho series, con resultados que muestran una alineación consistente con las tendencias observadas a nivel nacional y provincial.

En el caso de Bariloche, Malvicino et al. (2021) construyen un indicador sintético a partir de solo seis series locales, reflejo de las restricciones en la disponibilidad de información estadística para esa jurisdicción. A pesar de estas limitaciones el índice logra captar con precisión los principales *shocks* que impactaron en la economía local. Aunque no existen series oficiales que permitan establecer una referencia directa para validar el indicador, recurren a estimaciones anuales de empleo registrado y empresas activas para la ciudad. Por su parte, Lacaze et al. (2021; 2025) desarrollan un indicador sintético para el Partido de General Pueyrredon, compuesto por catorce series y validado frente al EMAE y al Indicador Trimestral de Actividad Económica de la provincia de Buenos Aires (ITAE-PBA), indicador compuesto que resume, de forma trimestral, la evolución de la actividad económica bonaerense. El estudio concluye que el ciclo económico local se caracteriza por expansiones más breves y recesiones más prolongadas en comparación con la dinámica nacional.

En conjunto, todos estos trabajos no solo consolidan la aplicación de la metodología de TCB en distintas jurisdicciones del país, sino que ofrecen evidencia empírica de su capacidad para construir indicadores sintéticos que reflejan con precisión la evolución de la actividad económica regional, incluso en contextos marcados por limitaciones estadísticas. Un aspecto metodológico central en estos estudios es la definición de los ponderadores asignados a cada serie componente del indicador. Estos pesos permiten otorgar a cada variable una importancia relativa, en función de criterios como su estabilidad, representatividad sectorial o grado de asociación con el ciclo económico. Así, el índice resultante deja de ser un simple promedio aritmético para convertirse en una combinación ponderada que busca captar con mayor precisión la dinámica subyacente del entramado económico analizado.

Los criterios metodológicos propuestos por *The Conference Board* (TCB) para la selección de series que integran un indicador sintético pueden resumirse en los siguientes aspectos fundamentales:

1. Significancia económica (“*economic significance*”): las series deben ser representativas de la actividad económica del área a estudiar. Esto implica que los movimientos cíclicos de las series elegidas deben ser económicamente consistentes respecto del nivel general de actividad.

2. Adecuación estadística (“*statistical adequacy*”): la información debe ser recogida y procesada de una manera estadísticamente apropiada.

3. *Timing* (“*timing at revivals and recessions*”): los puntos de giro de las series deben exhibir un patrón de tiempo coincidente, adelantado o rezagado respecto del ciclo económico. En el caso del *ISAE – GP* la intención fue utilizar series coincidentes con respecto a la trayectoria del nivel general de actividad.

4. Conformidad (“*conformity to historical business cycles*”): una serie procíclica debe crecer en las expansiones y disminuir en las recesiones; lo contrario debe suceder con una serie contracíclica. La evaluación de este criterio, y del *timing* se lleva a cabo a partir de análisis de correlaciones desfasadas de cada serie (Lapelle, 2015).

5. Suavidad (“*smoothness*”): las series no deben mostrar un comportamiento errático. Esto significa que debe buscarse que el componente irregular sea mínimo (Lapelle, 2015).

6. Disponibilidad o demora de la información (“*currency or timeliness*”): deben ser publicadas en un tiempo razonable para la actualización del indicador.

Estos criterios garantizan la fiabilidad de la información utilizada. Finalmente, deben aplicarse distintos tratamientos estadísticos como la deflactación, la desagregación temporal y la desestacionalización según corresponda (TCB, 2001; Jorrat, 2003).

Al tiempo que los antecedentes mencionados demuestran la pertinencia de la metodología de TCB en contextos regionales, también evidencian los principales desafíos de esta metodología: la necesidad de establecer criterios rigurosos para la selección de series, mitigar los sesgos asociados a la estacionalidad y la irregularidad y afrontar la fuerte dependencia de las magnitudes construidas respecto de la calidad de la información disponible.

2.1.2 Metodología de Factores Dinámicos

Desarrollada originalmente por Geweke (1977) y Sargent y Sims (1977), esta metodología ha evolucionado significativamente a lo largo del tiempo, refinando y ampliando los modelos formulados y mejorando, en consecuencia, su precisión y aplicabilidad en distintos contextos. Por ejemplo, ha sido ampliamente utilizada en el análisis del ciclo económico, en la elaboración de proyecciones, en la construcción de indicadores sintéticos de actividad económica y en la estimación temprana o *nowcasting* del PBI (Camacho et al., 2015; D'Amato et al., 2016).

El principal desafío que abordan los modelos factoriales dinámicos (MFD) es la alta dimensionalidad, entendida como la situación en la que el número de variables es grande en relación con el número de observaciones disponibles o, incluso, lo supera. Este fenómeno, común en el análisis de datos económicos de alta frecuencia, dificulta la aplicación de técnicas econométricas tradicionales por lo que propicia la aplicación de otras metodologías que permiten extraer y emplear un acotado pero relevante número de factores comunes. Así, se asume que los co-movimientos observados en diversas series de actividad pueden resumirse mediante una única variable no observada que representa el estado latente de la economía. El enfoque de MFD, que se basa en modelos de espacio de estados, permite una estimación óptima a través del cálculo de los pesos que mejor identifican un factor subyacente común.

Particularmente, el *nowcasting*, abreviatura de *now* (ahora) y *forecasting* (pronóstico), se refiere a la predicción del presente, del pasado muy reciente y del futuro inmediato (Giannone et al., 2008) en contextos donde la información estadística se publica con rezagos. Esta técnica busca producir estimaciones en tiempo real de variables clave antes de que estén oficialmente disponibles. Para ello aprovecha información parcial pero actualizada, proveniente de un gran número de fuentes de datos (indicadores, variables, series) de alta frecuencia (mensuales, semanales o, incluso, diarios) que están correlacionados con la variable objetivo usualmente de menor frecuencia de observación.

Ante el contexto de alta dimensionalidad, en el que las técnicas tradicionales de estimación pueden volverse ineficientes o inestables, el *nowcasting* reduce la dimensionalidad sin perder información relevante, como mediante la aplicación de la técnica de las ecuaciones puente (*bridge equations*). En particular, el enfoque conocido como *two-stage*, propuesto por Giannone et al. (2008) y ampliamente utilizado en aplicaciones empíricas recientes, constituye una de las

metodologías de estimación del modelo de factores dinámicos. Este enfoque combina, en una primera etapa, la estimación de componentes principales para extraer los factores comunes y, en una segunda etapa, una representación en espacio de estados para modelar su dinámica (Blanco et al., 2021). El procedimiento se basa en el modelo de factores dinámicos exacto (*Exact DFM*) y permite estimar de manera eficiente los parámetros de las matrices de carga y los factores comunes de manera eficiente. Esta metodología es especialmente adecuada para procesar grandes volúmenes de datos y proporciona una estimación parsimoniosa y eficaz de la evolución de la variable objetivo.

Stock y Watson (2011) distinguen tres generaciones de modelos de factores dinámicos. La primera se basa en la estimación paramétrica mediante Máxima Verosimilitud (MLE) y el filtro de Kalman¹, proporcionando estimaciones óptimas bajo los supuestos del modelo. Sin embargo, la necesidad de optimización no lineal restringía la cantidad de parámetros y series manejables. La segunda generación introdujo métodos no paramétricos para trabajar con un gran número de series y utilizando técnicas como componentes principales. Un resultado clave es que, si el número de series es suficientemente grande, los factores pueden estimarse con precisión y tratarse como datos en regresiones posteriores. La tercera generación combina estos estimadores no paramétricos con el modelo de espacio de estados de la primera generación, resolviendo así el problema de dimensionalidad.

Como alternativa, algunos estudios han explorado métodos bayesianos, que integran una distribución a priori en lugar de maximizar la verosimilitud. Su uso ha sido más limitado (Stock y Watson, 2011). Más recientemente, se desarrollaron trabajos de estimación que emplean técnicas de *machine learning* para la modelación de indicadores sintéticos de actividad económica. Por ejemplo, Carrera (2024) aplica los modelos *Lasso*, *Ridge* y *Elastic Net*. Estos modelos se concentran en la capacidad predictiva del indicador estimado y la posibilidad de realizar *nowcasting* a partir del mismo.

La utilización de MFD a nivel internacional para el *nowcasting* del PBI y otras variables macroeconómicas ha mostrado un notable desarrollo en las últimas

¹ Algoritmo recursivo, desarrollado por R. Kalman (Kalman, 1960), que permite estimar sistemas dinámicos representados en la forma de estado-espacio. Se utiliza en diversas aplicaciones en diferentes disciplinas científicas.

dos décadas. En América Latina, Bragoli et al. (2014) aplican esta metodología al caso de Brasil y concluyen que los pronósticos generados mediante MFD alcanzan una precisión comparable a la de las proyecciones institucionales elaboradas por el Banco Central de Brasil, basadas en el relevamiento de expectativas de mercado. Para México, Caruso (2015) implementa un modelo basado en el enfoque de Giannone et al. (2008) y encuentra que el rendimiento del MFD es comparable al de las proyecciones realizadas por organismos internacionales como el FMI y la OCDE, con la ventaja adicional de que el modelo permite actualizar los pronósticos en tiempo real ante la publicación de nueva información macroeconómica. Liu et al. (2012) amplían este análisis a diez países latinoamericanos (Argentina, Brasil, Chile, Colombia, Ecuador, República Dominicana, México, Perú, Uruguay y Venezuela), comparando cinco especificaciones distintas y concluyendo que los MFD generan estimaciones más precisas para el PBI comparado con otras especificaciones como los modelos autorregresivos, ecuaciones puente, de Vectores Autoregresivos (VAR) bivariados y VAR bayesianos.

En Ecuador, Casares (2018) y Moreno Brito (2020) emplean modelos basados en componentes principales y la utilización del filtro de Kalman para proyectar el PBI, logrando estimaciones consistentes y anticipadas respecto de las publicaciones oficiales y superando marginalmente el desempeño de un modelo *Autoregressive Moving Average* (ARMA) utilizado como *benchmark*. Por su parte, Dahlhaus et al. (2017) emplean un MFD para estimar el crecimiento del PBI en cinco economías emergentes (Brasil, Rusia, India, China y México) destacando su capacidad para procesar información con diferentes frecuencias, rezagos y estructuras estadísticas.

En Europa, los modelos de factores dinámicos también han sido aplicados con éxito. Liedo (2014) propone un modelo conjunto para Bélgica y la zona euro, mientras que Barhoumi et al. (2010) analizan el desempeño predictivo del crecimiento del PBI en Francia utilizando 140 variables. Su estudio concluye que la inclusión de un mayor número de factores comunes mejora significativamente la precisión del modelo. D'Agostino et al. (2008) aplican un modelo similar para Irlanda empleando un conjunto de 41 variables y Arnostova et al. (2011) realizan una comparación entre seis modelos distintos para el caso de la República Checa, encontrando que el basado en componentes principales presenta el mejor rendimiento. En India, Prakash (2022) evalúa tres especificaciones

alternativas del modelo con 10, 14 y 25 indicadores y encuentra que la opción con mayor número de series ofrece el mejor desempeño en términos de pronóstico. En Turquía, Modugno et al. (2016) implementan el enfoque de Giannone et al. (2008) para estimar el PBI en tiempo real. En Asia, Yiu y Chow (2011) también aplican esta metodología al caso de China, utilizando 188 indicadores para medir el impacto de *shocks* específicos sobre el crecimiento económico, mientras que Luciani et al. (2015) desarrollan un indicador sintético de actividad económica para Indonesia, a partir de 11 variables.

En Argentina, la aplicación de MFD para la construcción de indicadores sintéticos de actividad económica se ha desarrollado tanto a nivel nacional como subnacional. A nivel provincial, Berardi et al. (2010) construyen un indicador para Santa Fe a partir de cinco series de tiempo clave. El índice resultante muestra una evolución similar a la del ICASFe aunque, en este último caso, las fases recesivas se presentan con mayor intensidad. Con el objetivo de medir la actividad de varias provincias, Ibáñez Martín et al. (2014) proponen la estimación de índices coincidentes regionales para el período 1997–2011. Por su parte, Camacho et al. (2015) implementan esta metodología para proporcionar medidas alternativas de los datos de producción y contrastar con las estadísticas oficiales. De manera complementaria, D'Amato et al. (2016) comparan ecuaciones puente y MDF para realizar *nowcasting* del PBI, concluyendo que el desempeño de los MDF resulta superior. Asimismo, otros trabajos relevantes son los de Ontivero y Rodríguez (2018) para Tierra del Fuego y Haberkorn y Orsini (2018) para Entre Ríos. En ambos casos, los indicadores estimados demostraron ser robustos y reflejar, de manera consistente, la evolución de la actividad económica en cada provincia.

En esta misma línea y más recientemente, Malvicino et al. (2020) proponen una serie de indicadores provinciales con el objetivo de facilitar comparaciones entre las 24 jurisdicciones sub nacionales de primer orden. Comparan las tasas de crecimiento anual de los índices resultantes con las de los respectivos PBG disponibles, encontrando un ajuste razonable. Además, Malvicino (2022) desarrolla un indicador mensual de actividad económica específico para la provincia de Río Negro (ISAE-RN) que permitió dar cuenta de la dinámica provincial durante la pandemia COVID-19. Los resultados mostraron diferencias frente a estimaciones realizadas con otras metodologías, especialmente en cuanto al impacto económico de las medidas de aislamiento implementadas a

partir de marzo de 2020. Hasta el momento no se han identificado aplicaciones de esta metodología para el desarrollo de indicadores sintéticos de actividad a nivel sub provincial, lo que pone de manifiesto una oportunidad concreta de investigación en ese ámbito.

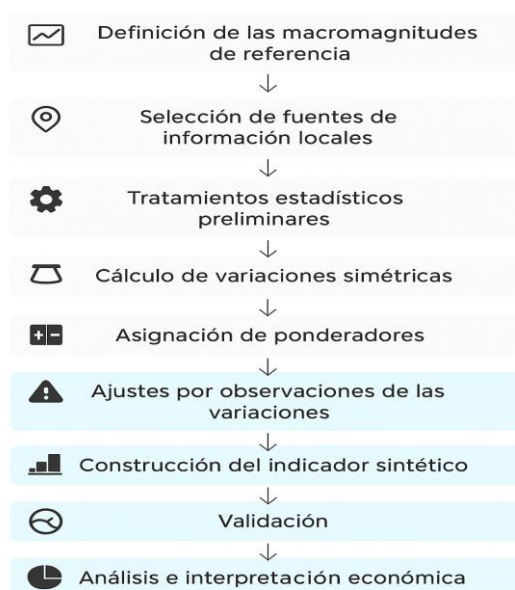
Por último, es importante destacar que el marco metodológico de los MDF ha sido extendido a la estimación de otras variables económicas distintas del PBI. Por ejemplo, D'Agostino et al. (2015) efectúan un *nowcasting* del comercio en la zona euro para analizar su versatilidad en distintas coyunturas macroeconómicas. En Argentina, González Rozada (2025) implementa un modelo de *nowcasting* para estimar la incidencia de la pobreza, a partir de proyecciones mensuales basadas en la evolución del mercado laboral y de los ingresos familiares según la Encuesta Permanente de Hogares (EPH), lo que permite generar estimaciones actualizadas para los semestres de referencia. En Estados Unidos, los trabajos de Bábura et al. (2013) y Modugno (2013) amplían el alcance de los MFD al incorporar variables financieras de alta frecuencia (diaria y semanal) y aplicarlos también al *nowcasting* de la inflación. De esta manera, los modelos de factores dinámicos se han consolidado como una herramienta robusta y flexible para estimar en tiempo real el comportamiento de variables económicas agregadas. Su capacidad para sintetizar grandes volúmenes de datos con diferentes frecuencias y estructuras los posiciona como una sólida alternativa metodológica frente a enfoques más tradicionales.

2.2 ISAE – GP: síntesis metodológica y principales conclusiones

Para el municipio de General Pueyrredon se ha estimado una primera versión del Indicador Sintético de Actividad Económica de General Pueyrredon (*ISAE – GP*) de tipo coincidente y para el período 2004-2023 (Lacaze et al., 2021; 2025). Para dicha labor se consideró la metodología de diferencias simétricas (TCB, 2001; Jorrat, 2003), que establece la siguiente secuencia de acciones, representadas en la *Figura 1*.

Para establecer una base de comparación y evaluar el desempeño del *ISAE – GP* se utilizaron tres macromagnitudes de referencia: (i) el Producto Bruto Geográfico del Partido de General Pueyrredon (PBG-GP), de frecuencia anual y disponible para el período 2004–2012 (Wierny, 2012); (ii) el Estimador Mensual de Actividad Económica (EMAE), disponible para todo el período considerado; y (iii) el Indicador Trimestral de Actividad Económica de la provincia de Buenos Aires (ITAE-PBA), disponible desde 2012.

Figura 1 – secuencia de pasos metodología TCB



Fuente: elaboración propia.

A partir de un conjunto inicial de 25 series se aplicaron los criterios estadísticos y económicos que establece la metodología TCB con el propósito de realizar una primera depuración. A continuación, se mantuvieron únicamente aquellas series cuyos puntos de giro coincidían, de forma aproximada, con los del PBG y el EMAE. Todas las series nominales fueron deflactadas y sometidas a desestacionalización para eliminar las oscilaciones regulares intraanuales. Luego se calcularon las variaciones porcentuales simétricas mensuales de las series seleccionadas. Las mismas fueron promediadas empleando ponderadores inversamente proporcionales a su volatilidad, de modo de equilibrar la influencia de cada componente. Para evitar la sobredimensión de ciertos sectores o aspectos particulares de la dinámica económica local se descartaron series altamente correlacionadas entre sí.

Finalmente, el indicador compuesto resultante se obtuvo acumulando simétricamente el promedio de las variaciones ponderadas. Su desempeño se validó mediante comparaciones gráficas y el cálculo de coeficientes de correlación —tanto a niveles como de variaciones— con las macromagnitudes antes referidas. Los componentes del *ISAE – GP* son las series referidas a *Agua; Desembarques; Electricidad; Transporte; Gas residencial; Arribos; Depósitos; Construcción; Agricultura; Vehículos; Tasa ISH; Combustible; Recursos y Gas industrial.*

Algunas de las series² componentes son representativas de aspectos vertebrales de toda estructura productiva, como los consumos de energía eléctrica y de gas, el uso del transporte público y los recursos fiscales municipales. En tanto que otras están vinculadas a aspectos singulares de la economía local estudiada, como el turismo receptivo, la dinámica del mercado automotor y los volúmenes de desembarques pesqueros (Lacaze et al., 2021; 2025).

Cierta información disponible y vinculada significativamente a la actividad económica del municipio no cuenta con la periodicidad requerida para integrar un indicador sintético mensual. Por lo tanto, fue necesario realizar procedimientos de transformación de frecuencias para luego evaluar su potencial inclusión en el *ISAE – GP*. A tal fin, se aplicaron procedimientos estadísticos de desagregación temporal que permitieron distribuir la información, originalmente disponible en base anual, semestral o trimestral, en los meses componentes del año (Fernandez 2023; Fernandez et al., 2024).

El *ISAE – GP_{TCB}* presenta una buena consistencia temporal con el EMAE y el ITAE-PBA (Lacaze et al., 2025). Exhibe mayores correlaciones en niveles -como es de esperar- con las macromagnitudes de referencia, que los valores obtenidos al analizar correlaciones en variaciones. Sin embargo, en ambos casos los resultados son satisfactorios. También lo son al realizar las comparaciones con el PBG-GP en el intervalo temporal en que éste está disponible.

² Indistintamente se utiliza en el documento las denominaciones “series”, “variables” y “datos-fuente”.

3. Estructura productiva local y datos

3.1 Perfil productivo del Municipio de General Pueyrredon

Mar del Plata, la segunda ciudad más poblada de la provincia de Buenos Aires y la sexta a nivel nacional (INDEC, 2023), se consolida en el sur de la provincia como el principal polo naval del país. Su industria pesada naval alberga dos de los astilleros más importantes para la construcción de embarcaciones pesqueras (Mauro et al., 2020), actividad que, como principal puerto pesquero de la Argentina, actúa como motor histórico de su desarrollo naval (Mauro et al., 2022).

Aunque, como ya se ha mencionado, no se dispone de estimaciones recientes del Producto Bruto Geográfico (PBG) del Partido de General Pueyrredon -la última serie disponible cubre el intervalo 2004–2012-, aquellos datos muestran que los sectores extractivos aportaban el 8% del valor agregado, con especial relevancia de la pesca y la producción frutihortícola (Wierny, 2012). En efecto, la importancia que presenta el cinturón verde que rodea la ciudad en cuanto a variedad y volumen de especies producidas explica su capacidad de abastecer, durante buena parte del año, a los principales centros de consumo nacionales (Lacaze et al., 2017).

El municipio concentra el 90% de las PyMEs de la zona atlántica, lo que lo posiciona como el núcleo industrial más relevante de la región (Elicabe et al., 2020). La industria manufacturera contribuía con cerca del 30% del valor agregado según los últimos datos disponibles de PBG, destacándose la rama alimenticia y el procesamiento de productos pesqueros (Lacaze et al., 2014). Gran parte de estas empresas, en su mayoría familiares y de planta única, opera en el Parque Industrial Mar del Plata-Batán (Liseras et al., 2024).

Por otra parte, la ciudad recibe cada año alrededor de 8.5 millones de visitantes, lo que exige una infraestructura robusta en términos de energía, agua y transporte y provoca una marcada estacionalidad en el empleo. De esta manera, las tasas de ocupación suben en temporada alta y la subocupación alcanza su pico en el segundo trimestre del año (Actis, 2022). El sector servicios, impulsado por el turismo, llega a representar casi dos tercios del PBG (Lacaze et al., 2014), integrando el comercio, el transporte, la gastronomía, la hotelería, los servicios inmobiliarios, financieros, de salud y de comunicaciones (Varisco, 2018; Atucha et al., 2012).

Este perfil productivo concentrado en pesca, agroindustria y turismo revela un bajo grado de diversificación que aumenta la vulnerabilidad ante *shocks* externo (Lacaze et al, 2025). Por ello es que resulta crucial disponer de estadísticas locales oportunas y de alta frecuencia, útiles para monitorear la actividad en tiempo real y diseñar respuestas más ágiles a los fenómenos coyunturales.

Este diagnóstico de la estructura productiva justifica la inclusión de las siguientes series, para integrar nuestro indicador sintético:

- **Desembarques y actividad agrícola**, por la relevancia de la pesca y la agricultura.
- **Electricidad, agua y combustibles**, como insumos vertebrales de la industria y los servicios.
- **Tasa de Inspección, Seguridad e Higiene (ISH)**, para reflejar la actividad comercial, industrial y de servicios vía recaudación fiscal.
- **Arribos de visitantes, actividad vehicular y transporte público**, que capturan la dinámica estacional del turismo, pero, también, los requerimientos logísticos de las actividades extractivas y de manufactura.
- **Construcción, depósitos bancarios y recursos tributarios**, para representar la inversión local, la actividad comercial y los ingresos fiscales.

3.2 Definición y operacionalización de variables

Para llevar a cabo la estimación del modelo factorial dinámico se seleccionaron 12 de las 14 variables que integran el $ISAE - GP_{TCB}$. En efecto, para la presente investigación se excluyeron las series referidas a la distribución de gas natural para consumo industrial y residencial debido a su menor cobertura temporal (la disponibilidad de datos inicia en 2013). Dado que la metodología propuesta emplea un Análisis de Componentes Principales (ACP)³ se requiere contar con series completas para todo el período en que se efectuará la estimación. Esto representa una diferencia importante respecto de la metodología TCB, que resulta flexible a la presencia o ausencia de datos, permitiendo entonces la utilización de series con datos faltantes en algunos tramos. De esta manera, el período de análisis, entre enero de 2006 y diciembre de 2022, queda determinado por la disponibilidad conjunta de las 12 series seleccionadas. Las variables utilizadas se detallan en la *Tabla 1*.

³ El ACP es una técnica estadística que transforma un conjunto de variables correlacionadas en un nuevo conjunto de variables no correlacionadas, los componentes principales. Estas nuevas variables son combinaciones lineales de las originales y están ordenadas según su contribución a la varianza total de los datos (Hansen, 2022).

**Tabla 1 – Variables seleccionadas para la estimación factorial dinámica del
ISAE – GP**

VARIABLE	FRECUENCIA	DESCRIPCIÓN	FUENTE
AGUA	Mensual	Producción de agua potable en el PGP.	OSSE-MGP
DESEMBARQUES	Mensual	Disposición en tierra de las capturas pesqueras realizadas por la flota argentina con matrícula en puerto Mar del Plata.	SAGYP
TRANSPORTE	Mensual	Boletos cancelados en el transporte público urbano del PGP.	MGP
ELECTRICIDAD	Mensual	Demanda total de energía eléctrica en el MGP.	CAMMESA
VEHÍCULOS	Mensual	Operaciones de inscripciones iniciales y transferencias de titularidad de automotores en GP.	MGP
ARRIBOS	Mensual	Turistas ingresados a Mar del Plata por avión, ómnibus, tren y automóvil.	EMTUR-MGP
DEPÓSITOS	Trimestral	Monto de los depósitos a la vista, en cajas de ahorro y a plazo fijo radicados en entidades financieras privadas y públicas que operan en el MGP.	BCRA
CONSTRUCCIÓN	Anual	Superficie total autorizada para construcción privada en el MGP.	CIEM-MGP
AGRICULTURA	Anual	Producción total de soja en el partido de General Pueyrredon.	SIIA-SAGYP
RECURSOS	Mensual	Monto de los recursos tributarios percibidos por la MGP, excepto los recaudados en concepto de Tasa ISH.	MGP
TISH	Mensual	Monto total tributado por la tasa de inspección de seguridad e higiene en comercios, industrias y servicios en el MGP.	MGP
COMBUSTIBLE	Mensual	Despachos mayoristas de combustible en el partido de General Pueyrredon.	SEN

OSSE: Obras Sanitarias Sociedad de Estado. MGP: Municipalidad de General Pueyrredon. SAGYP: Secretaría de Agricultura, Ganadería y Pesca de la Nación. CAMMESA: Compañía Administradora del Mercado Mayorista Eléctrico Sociedad Anónima. EMTUR: Ente Municipal de Turismo. BCRA: Banco Central de la República Argentina. CIEM: Centro de Información Estratégica Municipal. SIIA: Sistema Integrado de Información Agropecuaria. SEN: Secretaría de Energía de la Nación PGP: Partido de General Pueyrredon.

Elaboración propia.

La implementación de ACP requiere la normalización y estandarización de las variables para asegurar que todas contribuyan equitativamente al análisis y evitar sesgos derivados de diferencias en escalas y unidades de medida. Además, aquellas series originalmente de baja frecuencia fueron transformadas mediante técnicas de desagregación temporal (Fernandez, 2023).

Para el tratamiento particular de la serie referida a los arribos de turistas entre los meses de abril y noviembre de 2020, dado que la metodología de ACP no admite datos faltantes, se realizó un ajuste siguiendo el criterio propuesto por Giannone et al. (2008). En primer lugar, se imputaron ceros en los datos faltantes interpretando que éstos reflejan la ausencia de movilidad en el contexto de la medida de aislamiento preventivo obligatorio impuesto por el Poder Ejecutivo Nacional. Posteriormente, los valores faltantes fueron imputados utilizando la mediana de la serie, excluyendo los valores nulos. A fin de reducir la volatilidad de corto plazo y mejorar la calidad de la señal, se aplicó un suavizado mediante un promedio móvil centrado de tres períodos. Finalmente, los valores imputados y suavizados reemplazaron a los ceros originales, conservando los valores válidos observados en el resto de la serie.

El conjunto de variables seleccionadas ofrece una visión integral de la actividad económica en el Partido de General Pueyrredon. La diversidad de frecuencias que presentan los datos (mensuales, trimestrales y anuales) responde a las características propias de cada variable y su disponibilidad en las fuentes oficiales.

4. Metodología de Factores Dinámicos

La metodología de factores dinámicos, originalmente propuesta por Geweke (1977) y Sargent y Sims (1977), parte del supuesto de la existencia de un factor común no observable que subyace a un conjunto de series representativas de la actividad económica. Esta técnica permite reducir la dimensionalidad del sistema al condensar la información en un único factor que captura la variabilidad compartida entre las series. Cada variable observable se descompone en dos componentes independientes e inobservables, pero estimables. Por un lado, un factor común, que explica la mayor parte del comportamiento conjunto de las series y, por otro, un componente idiosincrático, que recoge las fluctuaciones individuales no explicadas por el factor común. De este modo, el factor extraído resume de manera parsimoniosa las interacciones dinámicas entre las distintas variables (Cuevas y Quilis, 2010; 2012; Stock y Watson, 1989).

Un enfoque ampliamente utilizado para la estimación de modelos de factores dinámicos en el espacio de estados es el método en dos etapas (*two-stage*), descrito en Giannone et al. (2008) tal como se comentó previamente. El modelo que da forma a la estimación y que permite la obtención del índice sintético y coincidente de actividad económica, puede escribirse como:

$$x_t = \Lambda f_t + \varepsilon_t \quad (1)$$

$$f_t = \sum_{i=1}^p A_i f_{t-1} + u_t, \quad u_t \sim i. i. d. N(0, I_q) \quad (2)$$

Donde, en la ecuación (1) $x_t = (x_{1t}, x_{2t}, \dots, x_{Nt})$ es el vector que recoge las observaciones de cada serie incluida como insumo del indicador sintético. Λ es la matriz de cargas factoriales de dimensión $k \times 1$ que relaciona el factor común con las series observadas. Dicha matriz cuantifica la sensibilidad de la señal de crecimiento de cada serie respecto a cambios en el factor. Por su parte, f_t es el factor común inobservable de la dinámica conjunta de los indicadores que componen el $ISAE - GP_{MFD}$, en tanto que ε_t es el vector que recoge la variabilidad de la señal del crecimiento no explicada por el factor común, también conocido como componente idiosincrático.

La ecuación (2) impone la estructura de un proceso $VAR(p)$ en los factores f_t y especifica cómo evoluciona el factor en el tiempo. Tanto ε_t como u_t siguen distribuciones normales lo que permite la aplicación del filtro de Kalman. Además, el vector de componentes idiosincráticos ε_t es ortogonal a u_t en todos los rezagos, es decir, $E[\varepsilon_t u'_{t-k}] = 0$ para cualquier k . Siguiendo a Banbura et al. (2011) el término de error puede ser modelado como un proceso $AR(p)$:

$$\varepsilon_{i,t} = \sum_{j=1}^p \alpha_{i,j} \varepsilon_{i,t-j} + \epsilon_{i,t}, \quad \epsilon_{i,t} \sim i. i. d. N(0, \sigma_i^2) \quad (3)$$

Donde $E[\epsilon_{i,t} \epsilon_{j,s}] = 0$ para $i \neq j$.

El indicador f_t en (1) y (2) es una estimación del valor de una variable inobservable, el estado de la economía, tal como lo denominaron Stock y Watson (1989). Esta variable se define empleando el supuesto de que los movimientos de las series coincidentes observadas, en todos los períodos de tiempo, provienen de los movimientos en f_t . Por supuesto, cualquier serie coincidente en particular podría tener movimientos diferentes con esta variable inobservable. Por lo tanto, se considera que cada serie coincidente tiene un componente que se le debe atribuir a la variable f_t más otro componente idiosincrático incorrelacionado con la variable inobservable y con los otros componentes idiosincráticos de las restantes variables, en todos los períodos de tiempo. Concretamente, se asume que la covarianza entre un número N de series de tiempo con sus adelantos y sus rezagos puede ser representada mediante un número reducido de q factores no observados, con $N > q$ (Blanco et al., 2021).

En una primera etapa se debe estimar el factor común mediante ACP utilizando un panel balanceado y estandarizado x_t , es decir, un conjunto de datos sin valores faltantes ni valores atípicos. Desde un punto de vista matemático (Hansen, 2022) los componentes principales de un conjunto de variables X se obtienen como combinaciones lineales $h'_j X$ donde los vectores de pesos h_j son los autovectores de la matriz de covarianza $\Sigma = var[X]$. La descomposición espectral de Σ nos permite escribirla como:

$$\Sigma = HDH'$$

Donde $H = [h_1, \dots, h_k]$ es la matriz de autovectores y $D = \text{diag}(d_1, \dots, d_k)$ es la matriz diagonal de autovalores. Como Σ es semidefinida positiva, sus autovalores son reales, no negativos y están ordenados de mayor a menor:

$$d_1 \geq d_2 \geq \dots \geq d_k.$$

Los componentes principales $U = (U_1, \dots, U_k)$ se calculan como $U = H'X$ y su matriz de covarianzas es diagonal $\text{var}[U] = H' \Sigma H = D$. Esto implica que cada componente principal U_j tiene una varianza igual a su respectivo autovalor d_j y que los componentes principales son mutuamente no correlacionados. La proporción de la varianza total explicada por el j -ésimo componente principal está dada por $\frac{d_j}{\text{tr}(\Sigma)}$.

La metodología de ACP permite identificar el (los) factor(es) comunes. Para ello, la estandarización de las series es un paso fundamental dado que el ACP no es invariante a la escala de las variables. Los estimadores de $\hat{\Lambda}$ y \hat{f}_t se obtienen a partir de resolver el siguiente problema de optimización:

$$\min_{f_1, \dots, f_2, \Lambda} \frac{1}{NT} \sum_{t=1}^T (\bar{X}_t - \hat{\Lambda} \hat{f}_t)' (\bar{X}_t - \Lambda f_t) \quad \text{s. t. } N^{-1} \Lambda' \Lambda = I_r \quad (4)$$

Se sigue el enfoque propuesto por Bai y Ng (2002; 2007) para definir, por un lado, el número r^* de factores en la ecuación (1) y, por otro, el número de *shocks* q que afectan a los factores en la ecuación (2). Sea $V(r, \hat{F}^r)$ la suma de los residuos al cuadrado cuando los r factores son estimados mediante componentes principales. Los criterios de información pueden expresarse de la siguiente manera:

$$IC_{r1}(r) = \ln(V(r, \hat{F}^r)) + r \left(\frac{N+T}{NT} \right) \ln \left(\frac{NT}{N+T} \right) \quad (5)$$

$$IC_{r2}(r) = \ln(V(r, \hat{F}^r)) + r \left(\frac{N+T}{NT} \right) \ln(\min\{N, T\}) \quad (6)$$

$$IC_{r3}(r) = \ln(V(r, \hat{F}^r)) + r \left(\frac{\ln(\min\{N, T\})}{(\min\{N, T\})} \right) \quad (7)$$

El número óptimo de factores r^* será aquel que minimice $IC_{ri}(r)$, es decir,

$$r^* = \text{argmin}_r IC_{ri}(r)$$

Para $i \in \{1,2,3\}$. Si bien las ecuaciones (5), (6) y (7) son asintóticamente equivalentes, en muestras finitas pueden arrojar resultados significativamente diferentes. En particular, la penalización en la ecuación (6) es la más restrictiva cuando se trabaja con muestras finitas.

El número de *shocks* q puede ser menor que el número de factores r . Una vez determinado r utilizamos el criterio de información basado en Bai y Ng (2007) para estimar el número de *shocks* q en la ecuación (2).

En una segunda etapa se emplea el filtro de Kalman para reestimar los factores utilizando los parámetros obtenidos en la primera etapa. Finalmente, la dinámica del factor común puede representarse mediante un modelo de vectores autorregresivos (VAR) de orden p (Banbura et al. 2011).

Este modelo se puede escribir como:

$$f_t = \sum_{i=1}^p A_i f_{t-i} + u_t \quad (8)$$

Donde A_1 es una matriz de dimensión 5×5 que contiene los coeficientes correspondientes al primer rezago del modelo, indicando cómo cada uno de los factores depende de los valores de todos los factores en el período anterior. Del mismo modo, A_2 es otra matriz de dimensión 5×5 que representa los coeficientes del segundo rezago, capturando la influencia de los valores de los factores con dos rezagos sobre la dinámica actual del sistema.

La estimación completa del modelo se lleva a cabo formulándolo en el espacio de estados y aplicando el filtro de Kalman, el cual emplea un procedimiento recursivo para estimar los parámetros desconocidos en presencia de variables no observables.⁴

La formulación en el espacio de estados es una metodología ampliamente utilizada para representar modelos dinámicos en econometría de series temporales. Su principal ventaja radica en la capacidad de modelar sistemas

⁴La estimación fue realizada utilizando el software estadístico R-Studio. Se emplearon las siguientes librerías: *stats* para el análisis de componentes principales (ACP); *factoextra* para la visualización de la varianza explicada por los componentes principales; *vars* para la estimación de modelos de vectores autorregresivos (VAR); *FKF* para la implementación del filtro de Kalman.

donde existen variables no observables, tal como factores latentes. Un modelo en el espacio de estados se compone de dos ecuaciones fundamentales:


1. Ecuación de medición: define cómo se vinculan las variables observables con el estado no observado del sistema. En este caso, describe la relación entre las series de datos económicos que integran el *ISAE – GP* y los factores comunes no observables que capturan la dinámica subyacente compartida entre ellas.
2. Ecuación de estado o transición: describe la evolución temporal del vector de estado, el cual contiene las variables clave del sistema.

La representación de modelos econométricos dinámicos mediante esta formulación permite estructurar de manera clara y precisa los distintos componentes del sistema, separando los aspectos de medida -es decir, qué variables generan las series temporales observadas y de qué forma- de los aspectos dinámicos, que describen la evolución temporal de los factores determinantes del sistema (Cuevas Galindo, 2017).

5. Resultados

La *Figura 2* presenta la evolución temporal suavizada y estandarizada de las 12 variables económicas utilizadas como insumos para la construcción del Indicador Sintético de Actividad Económica de General Pueyrredon con la metodología de Factores Dinámicos ($ISAE - GP_{MFD}$).

Figura 2 - Evolución suavizada de variables estandarizadas



Elaboración propia en software R-Studio.

El análisis visual revela tanto patrones compartidos como comportamientos diferenciados entre las series. La caída generalizada observada en 2020, vinculada al impacto económico de la pandemia, constituye un claro ejemplo de sincronización sectorial. No obstante, si bien todas las series se vieron afectadas en alguna medida, la magnitud y duración del impacto son disímiles. Esto evidencia el carácter diferenciado de la crisis y pone de manifiesto respuestas dispares de los indicadores frente a distintos *shocks*, lo que sugiere que la dinámica entre las variables es heterogénea. Esta coexistencia de movimientos comunes y particulares respalda la elección de un modelo de factores comunes dinámicos que permite extraer una componente agregada (indicativa de la actividad económica local) y aislar los comportamientos específicos de cada sector.

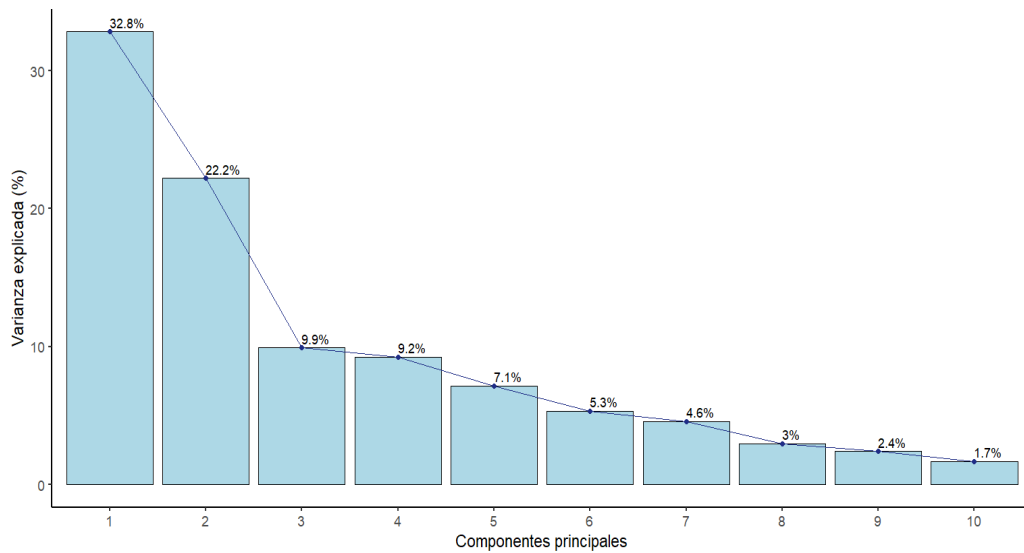
Adicionalmente, la *Figura 2* permite apreciar diferencias en la volatilidad relativa de las series. Sectores como *agricultura* y *combustible* presentan mayores oscilaciones en contraste con ramas más estables como *electricidad* o *agua*.

Este comportamiento ya había sido identificado en la construcción del $ISAE - GP_{TCB}$ (Lacaze et al., 2025) al verificar que, tras aplicar la metodología de TCB, las series más volátiles recibían ponderadores más bajos.

5.1 Estimación del componente estático

En la primera etapa del proceso se estiman, utilizando ACP, los factores estáticos que representan el co-movimiento conjunto de las series. La *Figura 3* presenta el gráfico de sedimentación (*scree plot*), el cual muestra la proporción de varianza explicada por cada uno de los primeros 10 componentes principales estimados.

Figura 3 - Scree Plot, ACP



Elaboración propia en software R-Studio.

Por su parte, la *Tabla 2* resume las cargas factoriales de cada una de las variables incluidas en el análisis en los primeros 5 componentes estimados (PC1 a PC5), que resumen poco más del del 81% de la variabilidad conjunta de los datos. Cada fila muestra el peso o contribución de cada variable original en los distintos componentes. Las cargas positivas o negativas indican la dirección de la relación entre la variable y el componente, ayudando a entender la estructura subyacente de los datos. Estos valores permiten identificar las variables que tienen mayor influencia en cada componente: por ejemplo, *agua* y *electricidad* tienen altas cargas en el PC1, mientras que *desembarques* destaca en el PC5.

Tabla 2 – Cargas factoriales de los primeros 5 componentes estimados por ACP.

	PC1	PC2	PC3	PC4	PC5
Agua	0.45	-0.04	0.001	-0.27	0.02
vehículos	0.25	0.39	0.29	-0.03	-0.09
desembarques	-0.18	0.14	-0.04	-0.35	0.84
electricidad	0.43	-0.11	-0.23	-0.20	0.007
transportes	-0.08	0.46	-0.07	0.49	0.03
arribos	0.11	0.33	-0.42	0.32	0.22
depósitos	0.24	-0.23	0.16	0.55	0.18
construcción	0.34	-0.27	-0.18	0.14	0.14
agricultura	0.18	0.29	0.59	-0.0002	0.21
combustible	0.14	0.36	-0.48	-0.15	-0.11
recursos	0.14	0.36	0.10	-0.21	-0.29
tasa SH	0.47	-0.02	0.06	0.05	0.13

Elaboración propia en software R-Studio.

Al analizar el primer componente principal (PC1), que concentra la mayor proporción de varianza explicada del conjunto de datos (32.8%), se observa que todas las cargas factoriales son positivas⁵ excepto en los casos de desembarques y transportes. Las variables con mayor peso en este componente son agua, electricidad, construcción y tasa ISH lo cual sugiere que el PC1 está estrechamente vinculado con el suministro y la gestión de recursos básicos y la infraestructura.

El segundo componente (PC2) capta información asociada a dinámicas de movilidad y producción agrícola, con altas cargas en vehículos, transportes,

⁵ La carga positiva (negativa) de una variable, en un componente principal, da cuenta de la asociación positiva (negativa) entre dicha variable y el componente. La magnitud de la asociación se desprende de la magnitud de la misma carga.

arribos, combustible, recursos y agricultura. Este patrón permite interpretar que el PC2 representa factores asociados al flujo de bienes y personas y, posiblemente, a la actividad agrícola y logística.

En cuanto al tercer componente (PC3), se destacan particularmente las altas cargas en agricultura y vehículos, mientras que otras variables como arribos y combustible presentan cargas negativas. El cuarto componente (PC4) muestra fuertes cargas positivas en transportes, arribos y depósitos y negativas en desembarques y recursos. Este patrón puede estar reflejando una dimensión vinculada al movimiento logístico interno y la distribución local que resulta diferenciada de la actividad extractiva pesquera. Finalmente, el quinto componente (PC5) tiene una alta carga en desembarques y contribuciones moderadas en agricultura, arribos y depósitos.

De acuerdo con el enfoque propuesto por Bai y Ng (2002, 2007), se selecciona como número óptimo de factores -a incluir en el modelo dinámico- un valor de $r^* = 5$. Tal como se observa en la Figura 3, los primeros cinco componentes principales explican conjuntamente el 81.32% de la varianza total del conjunto de datos disponibles lo que respalda empíricamente esta elección. A partir del sexto componente, la varianza explicada por cada factor adicional se reduce considerablemente lo que sugiere rendimientos decrecientes en términos de capacidad explicativa. Esta clara inflexión refuerza la selección de 5 factores como umbral adecuado para capturar la estructura latente común de las series observadas.

5.2 Estimación del componente dinámico

En la segunda etapa del proceso se estimó el número de rezagos óptimo para estructurar la dinámica de los factores mediante un modelo $VAR(p)$ que luego es incorporado dentro del sistema en el espacio de estados para su estimación con el filtro de Kalman. Siguiendo el mismo enfoque metodológico se determina que la cantidad de *shocks* estructurales óptimos que afectan a los factores en la ecuación (2) es $q^* = 2$. Este valor q^* también minimiza el criterio BIC y AIC en una comparación de modelos $VAR(p)$ con $p = 1, 2, 3, 4, 5$ y 6.

Esta selección permite modelar de manera parsimoniosa las dinámicas comunes subyacentes garantizando, a la vez, un buen ajuste en la representación estocástica del sistema. Una vez definido el modelo en espacio de estados y

aplicado el filtro de Kalman, se obtienen los factores filtrados que representan el componente común dinámico de los datos.

Dado que el modelo está estimado con 5 factores, se obtienen 5 factores filtrados en cada momento del tiempo que explican la mayor proporción de la varianza común entre las series. La combinación lineal de los 5 componente filtrados del vector de estados constituye la estimación del Indicador Sintético de Actividad Económica para el Partido de General Pueyrredon ($ISAE - GP_{MFD}$), obtenido a partir de un modelo factorial dinámico.

La escala del factor no tiene una interpretación inmediata en términos económicos concretos ya que se trata de una combinación lineal de las variables observadas ajustada a través del modelo de espacio de estados. Las estimaciones del estado común que provienen del filtro de Kalman deben ser recalibradas para adquirir una interpretación útil (Crone y Clayton-Matthews, 2005), dado que esta variable carece de tendencia y su amplitud está determinada por la covarianza de las series originales. Por ello, resulta necesario ajustarla utilizando una serie de referencia que refleje el comportamiento esperado del indicador en niveles consistentes con la realidad económica. Como señala Malvicino (2022), un aspecto clave en la construcción de indicadores sintéticos mediante el uso de MFD radica en la adecuada elección de esa serie de referencia. Esta selección permite conferir a la serie latente la tendencia y la amplitud necesarias para capturar adecuadamente su trayectoria temporal.

En esta estimación se emplea, como serie de referencia, el $ISAE - GP_{TCB}$ ya que el objetivo es analizar el desempeño comparativo de ambas metodologías en la construcción de un índice sintético de actividad⁶. Su evolución refleja de manera adecuada el desempeño de la economía local y representa la fuente de información más completa disponible para este propósito. Además, comparte la misma periodicidad que el indicador que se pretende estimar y ofrece una cobertura temporal completa para el período de análisis. Esto contrasta con la serie del Producto Bruto Geográfico local, que solo está disponible hasta el año 2012.

6 Adicionalmente, si bien no se incluyen en esta tesis, se realizaron pruebas de re-escalamiento utilizando, por un lado, la serie del EMAE y, por otro, una proyección de la serie del PBG extendida hasta 2022. Esta proyección fue elaborada mediante la misma metodología de factores dinámicos, empleando el paquete de *nowcasting* (de Valk, et al., 2019).

Para ello, primero se identifican los parámetros de la serie de referencia (Malvicino, 2022) y luego se proyecta el conjunto de factores dinámicos estimados sobre dicha serie mediante una regresión lineal simple. A partir de esta regresión, se obtiene el valor filtrado del factor⁷, VE_t . Posteriormente, se aplica una transformación para re-escalar el factor en la misma unidad de medida que la serie de referencia (Guezta, 2015):

$$ISAE - GP_{MFD} = \alpha + \beta * VE_t$$

Siendo α la media y β el desvío estándar del $ISAE - GP_{TCB}$. De esta manera, no se modifica la estimación del factor latente; sin embargo, se obtiene la transformación lineal de los factores estimados que se ajusta al nivel del $ISAE - GP_{TCB}$.

Con el objetivo de analizar la volatilidad de las series $ISAE - GP_{MFD}$ e $ISAE - GP_{TCB}$, se calcularon sus respectivas variaciones mensuales porcentuales, a partir de sus valores en niveles. Sobre estas series se estimó la volatilidad, expresada a través del desvío estándar. Este enfoque permite captar cambios en la dispersión relativa de las tasas de crecimiento de ambas series a lo largo del tiempo, facilitando la comparación de sus comportamientos dinámicos ante distintas coyunturas macroeconómicas.

Los resultados muestran que la volatilidad promedio fue levemente superior en el caso del $ISAE - GP_{MFD}$ (2.64%) en comparación con el $ISAE - GP_{TCB}$ (2.54%). Esta diferencia, aunque acotada, sugiere que el indicador basado en el modelo factorial dinámico presenta una mayor sensibilidad a las fluctuaciones de corto plazo. Por el contrario, el indicador derivado del enfoque de *The Conference Board* muestra un comportamiento ligeramente más estable.

La *Figura 4* presenta la evolución de ambos indicadores sintéticos de actividad económica, $ISAE - GP_{MFD}$ e $ISAE - GP_{TCB}$, junto con los puntos de giro identificados a partir del algoritmo de Bry-Boschan⁸. Se observa una elevada correspondencia entre ambos índices en términos de tendencia general y

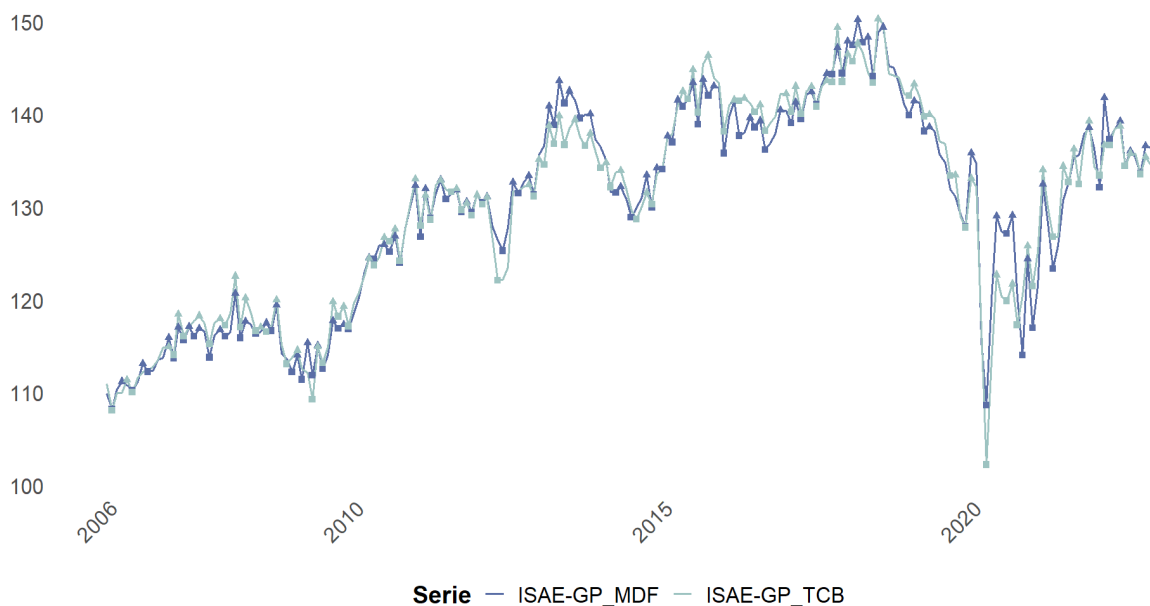
7 Es el valor del factor común estimado en el período t, transformado a la escala y dinámica de la serie de referencia ($ISAE - GP_{TCB}$), para que pueda interpretarse como un indicador económico real.

8 El algoritmo de datado de ciclos utilizado corresponde al método de Bry y Boschan (1971), implementado en R mediante el paquete *BCDating* (versión 0.9.8), desarrollado por Majid Einian en el *Monetary and Banking Research Institute, Central Bank of Islamic Republic of Iran*.

localización de fases cíclicas, lo que sugiere que ambos capturan adecuadamente los ciclos de la economía local.

No obstante, pueden identificarse algunas diferencias relevantes. En primer lugar, el $ISAE - GP_{MFD}$ muestra una mayor sensibilidad en ciertos tramos, con mayor frecuencia de picos y valles, lo que indicaría una respuesta más reactiva ante cambios coyunturales de corto plazo. Esta característica puede estar asociada a la capacidad del modelo factorial dinámico para incorporar estructuras de dependencia temporal y captar variaciones transitorias. Por el contrario, el $ISAE - GP_{TCB}$ presenta una trayectoria levemente más suavizada, con menor número de puntos de giro, lo que podría reflejar su enfoque metodológico más conservador.

Figura 4 - Puntos de giro del ciclo económico según $ISAE - GP$: modelo factorial dinámico vs. enfoque TCB (Bry-Boschan).



Fuente: Lacaze et al. (2025) y elaboración propia en software R-Studio.

En términos generales, el $ISAE - GP_{TCB}$ exhibe fases más prolongadas, tanto en expansión como en contracción mientras que, el $ISAE - GP_{MFD}$ tiende a identificar ciclos de menor duración, especialmente en las fases de contracción.

Esta diferencia sugiere que, si bien ambos indicadores captan adecuadamente los momentos de giro de la economía local, lo hacen con ritmos distintos. Mientras que la versión del indicador elaborada con TCB prioriza la estabilidad

del ciclo, la versión que surge de aplicar MFD es más sensible a cambios, aunque a costa de generar fases más breves y, posiblemente, más volátiles.

En términos temporales, los puntos de giro principales (crisis de 2008-2009, desaceleraciones de 2012 y 2018, y el impacto de la pandemia en 2020) son captados por ambos indicadores con diferencias mínimas. La *Tabla 3* muestra una comparación de los principales indicadores de ciclo económico estimados a partir de los dos enfoques metodológicos aplicados al ISAE-GP.

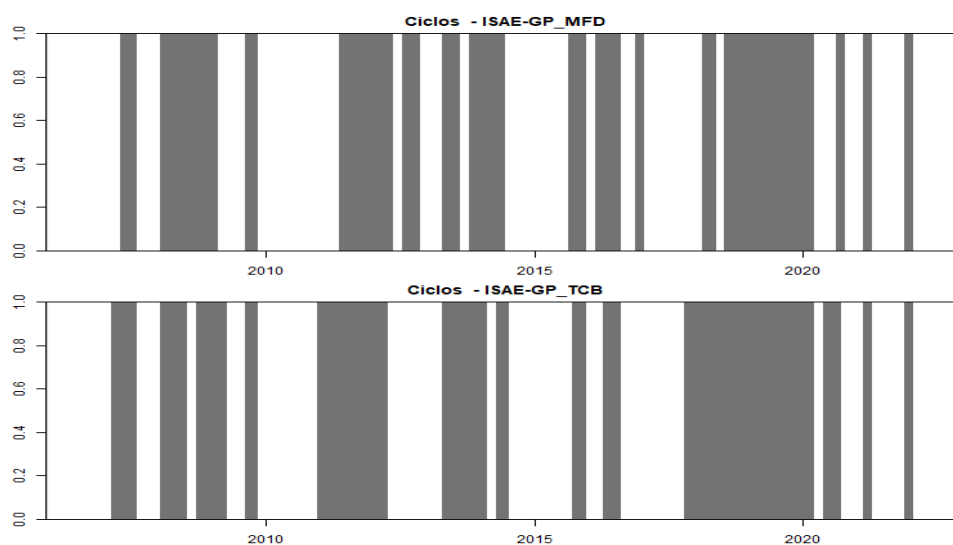
Tabla 3 - Resumen comparativo de los ciclos económicos estimados por el *ISAE – GP_{TCB}* y el *ISAE – GP_{MFD}*

	<i>ISAE – GP_{TCB}</i>	<i>ISAE – GP_{MFD}</i>
CANTIDAD DE PUNTOS DE GIRO	28	30
AMPLITUD PROMEDIO	10.3	9.5
DURACIÓN PROMEDIO	7.05	6.1

Fuente: elaboración propia en software R-Studio.

Ambos detectan una cantidad similar de puntos de giro (28 en el caso del TCB y 30 en el del MFD), lo que sugiere una coincidencia general en la identificación de fases del ciclo económico local. No obstante, se observan algunas diferencias relevantes en los atributos de esos ciclos. En promedio, las fluctuaciones captadas por el *ISAE – GP_{TCB}* son de mayor duración (7.05 meses frente a 6.1 meses) y de mayor amplitud (10.3 frente a 9.5), lo que indica que este enfoque tiende a reflejar movimientos más persistentes e intensos en la actividad económica. Por el contrario, el *ISAE – GP_{MFD}* capta ciclos algo más breves y moderados, posiblemente como resultado de su mayor sensibilidad a cambios de corto plazo en las variables subyacentes.

Figura 5 - Fases recesivas identificadas por el $ISAE - GP_{TCB}$ y el $ISAE - GP_{MFD}$ (2006-2022)

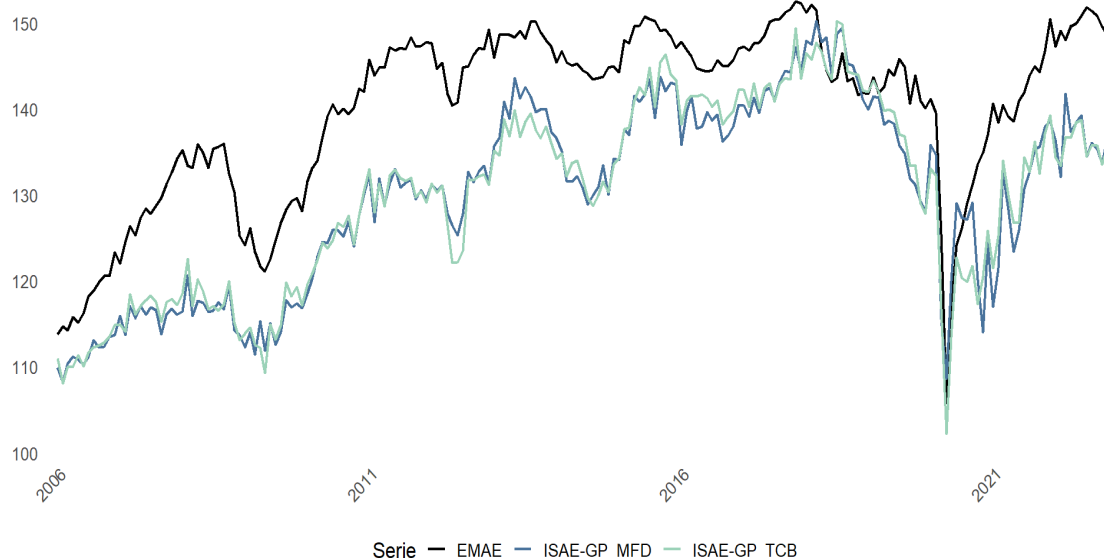


Fuente: elaboración propia en software R-Studio.

Por su parte, la *Figura 5* refuerza estas diferencias al mostrar la secuencia temporal de fases recesivas (en gris) identificadas por cada enfoque. Se observa que el $ISAE - GP_{TCB}$ tiende a agrupar recesiones más prolongadas y menos frecuentes, mientras que el $ISAE - GP_{MFD}$ identifica un mayor número de episodios recesivos que, en términos generales, presentan una menor duración.

La *Figura 6*, a continuación, permite analizar la evolución comparada del Indicador Sintético de Actividad Económica para el partido de General Pueyrredon ($ISAE - GP$) estimado a partir de las dos metodologías alternativas - el modelo de factores dinámicos (MFD) y la metodología propuesta por *The Conference Board* (TCB)-, en relación con el Estimador Mensual de Actividad Económica (EMAE) a nivel nacional.

Figura 6 - Indicador Sintético de Actividad Económica de General Pueyrredon (*ISAE – GP*) estimado con modelo factorial dinámico y por la metodología de *The Conference Board*, en comparación con el EMAE. Período 2006–2022.



Fuente: INDEC, Lacaze et al. (2025) y elaboración propia en software R-Studio.

Ambas versiones del *ISAE – GP* presentan un patrón de evolución muy similar entre sí y, en general, un movimiento coherente con el EMAE. Esto sugiere que las dos metodologías logran captar adecuadamente los principales ciclos de actividad, aunque con algunas diferencias en la magnitud y el *timing* de las fluctuaciones.

Las correlaciones de ambos *ISAE – GP* para el período de análisis, se reportan a continuación en la *Tabla 4*:

Tabla 4 – Correlaciones simples entre el *ISAE – GP* (TCB y MFD) y las series de referencia (EMAE y PBG) (2006-2022)

CORRELACIÓN	PERÍODO	<i>ISAE – GP_{TCB}</i>		<i>ISAE – GP_{MFD}</i>	
		Niveles	Variaciones	Niveles	Variaciones
EMAE (INDEC)	2006-2022	0.88	0.61	0.87	0.45
IPBG	2006-2012	0.84	0.33	0.86	0.10
ITAE-PBA	2012-2022	0.61	0.77	0.57	0.56

Fuente: elaboración propia con base en Lacaze et al. (2025).

La correlación del $ISAE - GP_{TCB}$ con el EMAE es de 0.88 en niveles y 0.61 en variaciones. En comparación, el $ISAE - GP_{MFD}$ presenta una correlación levemente inferior en niveles (0.87), pero muestra una diferencia sustancial en términos de variaciones, alcanzando una correlación del 0.45 con el EMAE.

Mientras que la correlación en niveles puede capturar tendencias comunes a largo plazo, la correlación en tasas de variación es más exigente pues refleja la sensibilidad del indicador ante fluctuaciones coyunturales. En este sentido, una mayor correlación en variaciones sugiere que el $ISAE - GP_{TCB}$ puede estar captando mejor la dinámica mensual de la economía local.

En el período 2006–2012, la comparación entre el $ISAE - GP_{MFD}$ y el PBG expresado en número índice (base 100=2006) muestra un coeficiente de correlación en niveles de 0.86, levemente superior al 0.84 obtenido con el $ISAE - GP_{TCB}$. Sin embargo, al considerar las variaciones anuales, el $ISAE - GP_{MFD}$ presenta una correlación de 0.10 con el PBG, mientras que el $ISAE - GP_{TCB}$ alcanza un valor de 0.34. Al considerar el ITAE-PBA, para el período 2012-2022, se observa que el $ISAE - GP_{MFD}$ correlaciona en niveles con este indicador en 0.57, mientras que en variaciones trimestrales la correlación es de 0.56. Por su parte, el $ISAE - GP_{TCB}$ exhibe un coeficiente de correlación superior en ambos casos, siendo de 0.61 en niveles y 0.77 en variaciones.

6. Conclusiones

El presente trabajo aplicó la metodología de factores dinámicos para estimar el Indicador Sintético de Actividad Económica para el Partido de General Pueyrredon ($ISAE - GP$). Para ello se empleó un conjunto amplio y heterogéneo de variables económicas locales, en una estrategia de estimación en dos etapas. Una primera fase estática permitió la extracción de factores comunes y una segunda fase dinámica modeló su evolución temporal. Este enfoque permitió captar patrones subyacentes compartidos entre las series e identificar una trayectoria compatible con la dinámica general de la actividad económica local. Uno de los objetivos centrales del estudio fue comparar el indicador estimado ($ISAE - GP_{MFD}$) con una versión previa del mismo (Lacaze et al., 2021; 2025), basada en la metodología de *The Conference Board* ($ISAE - GP_{TCB}$).

Ambas variantes mostraron trayectorias coherentes entre sí y un grado razonable de correspondencia con la dinámica del Estimador Mensual de Actividad Económica (EMAE) nacional, lo que resalta el buen desempeño de MFD especialmente considerando que, a diferencia del $ISAE - GP_{TCB}$, no incluye en su estimación las series de consumo de gas, ni industrial (fundamental para la actividad manufacturera y la producción de energía eléctrica) ni residencial. Esta exclusión se debió a la menor cobertura temporal de dichas series, pese a su relevancia. En particular, el $ISAE - GP_{TCB}$ presenta, al menos para el período analizado, una mayor correlación con el EMAE tanto en niveles como en tasas de variación. El $ISAE - GP_{MFD}$, por su parte, mostró un buen desempeño en niveles y una adecuada correspondencia con el Producto Bruto Geográfico local. Ambos indicadores captan adecuadamente los principales eventos económicos del período con diferencias temporales mínimas.

Desde una perspectiva comparativa, ambos enfoques presentan fortalezas distintas. El $ISAE - GP_{MFD}$ muestra mayor sensibilidad ante cambios de corto plazo, identificación de más puntos de giro (especialmente en fases contractivas) y capacidad para captar variaciones coyunturales gracias al modelado dinámico. Por su parte, el $ISAE - GP_{TCB}$ exhibe una trayectoria más suavizada, menor número de puntos de giro y fases cíclicas más prolongadas, lo que favorece una lectura más estable de la dinámica agregada.

En términos de implementación, el enfoque TCB se destaca por su simplicidad operativa y su capacidad de ofrecer estimaciones contemporáneas de forma

robusta. En contraste, el modelo factorial dinámico, pese a su mayor complejidad computacional y metodológica, habilita aplicaciones más sofisticadas especialmente en contextos donde resulta necesario incorporar dinámicas temporales y actualizar los indicadores de forma continua, como en sistemas de monitoreo económico en tiempo real.

En suma, la elección entre ambas metodologías no debe fundarse únicamente en métricas de ajuste contemporáneo, sino en la adecuación de cada enfoque al objetivo analítico específico. El MFD representa una herramienta potente cuando se busca modelar la estructura subyacente del ciclo económico con fines de predicción o análisis dinámico. Por el contrario, si el propósito es obtener una estimación puntual, robusta y operativamente sencilla, el enfoque TCB constituye una alternativa eficaz.

Por último, en términos metodológicos, la especificación del modelo dinámico adoptado incluyó 5 factores principales y un rezago de orden dos, configuración que resultó adecuada para el caso analizado. Sin embargo, futuras investigaciones podrían explorar variantes en el número de factores, la inclusión de nuevas variables o el uso de técnicas alternativas de estimación para robustecer y ampliar los alcances del indicador.

7. Referencias bibliográficas

1. Actis Di Pasquale, E. (2022). El trabajo en Mar del Plata. Feminización, informalidad y segmentación en tiempos de cambio macroeconómico. EUDEM.
2. Antonio Liedo, D. (2014). Nowcasting Belgium. National Bank of Belgium. <https://www.nbb.be/doc/oc/research/wp/wp256en.pdf>
3. Arnoštová, K., Havriant, D., Růžička, L., & Tóth, P. (2011). Short-term forecasting of Czech quarterly GDP using monthly indicators. *Statistika*, 61(6), 566–583.
4. Arredondo, F. et al. (2009). Metodología y Proceso de Construcción del Índice Compuesto Coincidente de Actividad Económica de la Provincia de Santa Fe". Centro de Estudios y Servicios Bolsa de Comercio.
5. Atucha, A. J.; Errazti, E.; Lacaze, M. V.; Labrunée, M. E.; López, M. T. y Volpato, G. G. (2012). La estructura productiva del Partido de General Pueyrredon. *FACES*, 18(38-39), 57-81. ISSN 0328-4050.
6. Atucha, A.; López, M.; Volpato, G. (1999). Producto Bruto Geográfico del Partido de General Pueyrredon, 1993 - 1998. Mar del Plata: UNMDP, FCEyS.
7. Bai, J., & Ng, S. (2002). Determining the number of factors in approximate factor models. *Econometrica*, 70(1), 191–221. <https://doi.org/10.1111/1468-0262.00273>
8. Bai, J., & Ng, S. (2007). Determining the number of primitive shocks in factor models. *Journal of Business & Economic Statistics*, 25(1), 52–60. <https://doi.org/10.1198/073500106000000413>
9. Banbura, M., Giannone, D., & Reichlin, L. (2011). Nowcasting. En M. P. Clements & D. F. Hendry (Eds.), *The Oxford Handbook of Economic Forecasting* (pp. 193–224). Oxford University Press.
10. Bánbura, M., Giannone, D., Modugno, M., & Reichlin, L. (2013). Now-casting and the real-time data flow. En G. Elliott & A. Timmermann (Eds.), *Handbook of Economic Forecasting* (Vol. 2, pp. 195–237). Elsevier. <https://doi.org/10.1016/B978-0-444-62731-5.00004-0>
11. Barhoumi, K., Darné, O., & Ferrara, L. (2010). Are disaggregate data useful for factor analysis in forecasting French GDP? *Journal of Forecasting*, 29(1–2), 132–144. <https://doi.org/10.1002/for.1110>
12. Berardi, M.; Navarro, A. & Uría, M. (2010). An application of the Stock/Watson index methodology to the Santa Fe Economy. Available at SSRN: <https://ssrn.com/abstract=1685330>
13. Blanco, E., D'Amato, L., Dogliolo, F., & Garegnani, L. (2021). Nowcast de agregados macroeconómicos en Argentina: Comparando la capacidad predictiva de diferentes modelos (Documentos de Trabajo N° 90). Banco Central de la República Argentina. https://www.bcra.gob.ar/Pdfs/PublicacionesInvestigacion/DT_90.pdf
14. Bragoli, D., Metelli, L., & Modugno, M. (2014). The importance of updating: Evidence from a Brazilian nowcasting model. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.2529168>
15. Cabrera Adame, C. J., Gutiérrez Lara, A. A., & Miguel, R. A. (2005). Introducción a los indicadores económicos y sociales de México. Universidad Nacional Autónoma de México, Facultad de Economía.
16. Camacho, M.; Dal Bianco, M., & Martínez-Martín, J. (2015). Toward a more reliable picture of the economic activity: An application to Argentina. *Economics Letters*, 132, 129–132.
17. Carrera, G. (2024, marzo). Anticipar el EMAE para decidir mejor: Modelos de nowcasting para el pronóstico de la actividad económica mensual argentina [Trabajo final de maestría, Maestría en Economía Aplicada].
18. Caruso, A. (2015). Nowcasting Mexican GDP (ECARES Working Paper 2015-40). Université libre de Bruxelles, SBS-EM, ECARES.
19. Casares Conforme, F. F. (2018). Identificación de los estados de la economía ecuatoriana en dolarización: Una aproximación multivariante a través de los modelos MS-DFM en dos pasos. *Compendium: Cuadernos de Economía y Administración*, 5(10). Escuela Superior Politécnica del Litoral.
20. Castagna, A.; Romero, L.; Scagliotti, E.; Ghilardi, F.; Yoya, A.; Leone, G.; Woelflin, M. (2001). Producto Bruto Geográfico de Rosario y su Región. Evolución 1993-1998. Sextas Jornadas "Investigaciones en la Facultad" UNR.
21. Crone, T. M., & Clayton-Matthews, A. (2005). Consistent economic indexes for the 50 states. *Review of Economics and Statistics*, 87(4), 593–603. <https://doi.org/10.1162/003465305775098207>

22. Cuevas Galindo, A. (2017). Utilización de modelos factoriales en la predicción integrada a corto plazo de agregados macroeconómicos y sus componentes [Tesis doctoral, Universidad Nacional de Educación a Distancia]. UNED Repositorio.
23. Cuevas, Á., & Quilis, E. M. (2012). A factor analysis for the Spanish economy. *SERIEs*, 3(3), 311–338. <https://doi.org/10.1007/s13209-011-0060-9>
24. D'Agostino, A., McQuinn, K., & O'Brien, D. (2008). Now-casting Irish GDP (Research Technical Papers 9/RT/08). Central Bank of Ireland. <https://doi.org/10.1787/19952899>
25. D'Agostino, A., Modugno, M., & Osbat, C. (2016). A global trade model for the euro area (ECB Working Paper No. 1986). European Central Bank. <https://www.ecb.europa.eu/pub/pdf/scpwps/ecbwp1986.en.pdf>
26. D'Amato, L.; Garegnani, L. & Blanco, E. (2016). Nowcasting de PIB: evaluando las condiciones cíclicas de la economía argentina. *BCRA*, 74, 1–20.
27. Dahlhaus, T., Guénette, J.-D., & Vasishtha, G. (2017). Nowcasting BRIC+M in real time. *International Journal of Forecasting*, 33(4), 915–935. <https://doi.org/10.1016/j.ijforecast.2017.03.005>
28. Delbianco, F. (2017). Indicador Sintético de Actividad de Bahía Blanca. Recuperado de <http://www.ecodata.uns.edu.ar>
29. De Valk, S., De Mattos, D., & Ferreira, P. (2019). Nowcasting: An R package for predicting economic variables using dynamic factor models. Contributed Research Article. *The R Journal*.
30. Elicabe, N., Mauro, L., & Manzo, F. (2020). Análisis de la diversificación productiva a nivel firma, para el sector Químico, Caucho y Plástico del Partido de General Pueyrredon. *FACES*, 26(54), 65–83. Universidad Nacional de Mar del Plata, Facultad de Ciencias Económicas y Sociales.
31. Fernandez, M. (2023). Aportes a la estructura de agregación del Indicador Sintético de Actividad Económica para el Partido de General Pueyrredon (ISAE-GP) a partir de la desagregación temporal de series económicas. UNMDP.
32. Fernandez, M., Lacaze, M. V., & Errea, D. (2024). Avances en la aplicación de un modelo de factores dinámicos para estimar un indicador sintético de actividad económica. En B. Lupin (Comp.), Libro de ponencias de la II Jornada de Investigadores en Formación de la Facultad de Ciencias Económicas y Sociales de la Universidad Nacional de Mar del Plata. *Pensando la ciencia del futuro* (pp. 67–76). Universidad Nacional de Mar del Plata, Facultad de Ciencias Económicas y Sociales.
33. Geweke, J. (1977). The Dynamic Factor Analysis of Economic Time Series. *Latent Variables in Socio-Economic Models*, ed. by D.J. Aigner and A.S. Goldberger, Amsterdam: North-Holland.
34. Giannone, D., Reichlin, L., & Small, D. (2008). Nowcasting: The real-time informational content of macroeconomic data. *Journal of Monetary Economics*, 55(4), 665–676. <https://doi.org/10.1016/j.jmoneco.2008.05.010>
35. Gonzalez-Rozada, M. (2025). *Nowcast de pobreza* Universidad Torcuato Di Tella. <https://www.utdt.edu/>
36. Guerezta, B. (2015). Estimación de un indicador subyacente de actividad económica para Argentina: Modelo factorial dinámico [Tesis de maestría, Universidad Torcuato Di Tella]. Universidad Torcuato Di Tella.
37. Haberkorn, M. J., & Orsini, G. (2018). Indicador Sintético de Actividad Económica de la Provincia de Entre Ríos (Informe No. 3). Dirección General de Estadística y Censos de la Provincia de Entre Ríos. <https://www.entrerios.gov.ar/dgec/isaeer/>
38. Hansen, B. E. (2021). *Econometrics* (Capítulo 11). University of Wisconsin. <https://home.ustc.edu.cn/~matheming/Econometrics.pdf>
39. Ibáñez Martín, M., Trajtenberg, L., Pereira, M. (2014). Actividad económica provincial: Las dificultades para su monitoreo. Construcción de índices coincidentes abordando la metodología de Factores Dinámicos. I Jornadas de Econometría, UBA-FCE: Buenos Aires.
40. Instituto Nacional de Estadística y Censos (INDEC) (2023). Censo Nacional de Población, Hogares y Viviendas 2022. Resultados provisionarios.
41. Jorrat, J. (2003). Indicador económico regional: El Índice mensual de actividad económica de Tucumán (IMAT).
42. Jorrat, J. (2005) Construcción de Índices Compuestos Mensuales Coincidente y Líder de Argentina. En: Marchionni, M. (Ed.) *Avances en Econometría*, cap. 4. Temas Grupo Editorial. Buenos Aires.
43. Jorrat, J., Salvatierra, S. (1999). Ajuste estacional de series de tiempo económicas de Argentina. IV Congreso Latinoamericano de Sociedades de Estadística, Mendoza.

44. Kalman, R. E. (1960). A new approach to linear filtering and prediction problems. *Journal of Basic Engineering*, 82(1), 35–45. <https://doi.org/10.1115/1.3662552>
45. Lacaze, M. V.; Atucha, A.; Bertolotti, M.; Gualdoni, P.; Labrunée, M.; López, M. Pagani, A.; Volpato, G. (2014). *Producto Bruto Geográfico del Partido de General Pueyrredon, 2004-2012*. Mar del Plata: Universidad Nacional de Mar del Plata. ISBN 978-987-544-610-6.
46. Lacaze, Alegre, Errea y Fernandez (2025). *Avances metodológicos en la construcción del Indicador Sintético de Actividad Económica de General Pueyrredon*, Buenos Aires, Argentina. *Estudios Económicos*.
47. Lacaze, M.V.; Alegre, P.; Errea, D.; Atucha, A.; Volpato, G.; Blanco, G.; Fernández, M.; Bianchetti, L. (2021). *Indicador Sintético de Actividad Económica de General Pueyrredon: Avances en su construcción*. II Congreso Internacional de Desarrollo Territorial, UNTFR Rafaela, octubre.
48. Lacaze, M.V., Atucha, A., Adlercreutz, E. (2017). Valor agregado de los cultivos hortícolas tradicionales de General Pueyrredon, Argentina, en el período 1993-2010. *Agroalimentaria*, 23(44), 133-151.
49. Lapelle, H. C. (2015). Construyendo un indicador de actividad mensual para la Región Rosario. *SaberEs*,0(7).
50. Liseras, N., et al. (2024). *Mapa productivo del Partido de General Pueyrredon: Edición 2024 (1ª ed.)*. Universidad Nacional de Mar del Plata, Facultad de Ciencias Económicas y Sociales. <https://doi.org/ISBN978-987-811-184>
51. Liu, P., Matheson, T., & Romeu, R. (2012). Real-time forecasts of economic activity for Latin American economies. *Economic Modelling*, 29(4), 1090-1098. <https://doi.org/10.1016/j.econmod.2012.02.019>
52. Luciani, M., Pundit, M., Ramayandi, A., & Veronese, G. (2015). Nowcasting Indonesia. *Finance and Economics Discussion Series 2015-100*. Board of Governors of the Federal Reserve System (U.S.). <https://doi.org/10.17016/FEDS.2015.100>
53. Malvicino, F. (2022). *Indicador Mensual de Actividad Económica de Río Negro. Una aplicación para analizar el impacto económico del COVID19*. *Pilquen* 25(2): 98-133
54. Malvicino, F. E., Tedesco, L., Attaguile, M. A., & Ruiz, S. (2021). Impacto del COVID-19 sobre la actividad económica de San Carlos de Bariloche. Una aproximación a partir de indicadores sintéticos. *Cuyonomics. Investigaciones en Economía Regional*, 5(2021), 40-62.
55. Malvicino, F., Pereira, M. & Trajtenberg, L. A. (2020). Índice de actividad económica provincial en base a un modelo factorial dinámico. *Argentina 1997-2019. Cuadernos del CIMBAGE*, 2(22), 145-173.
56. Martínez, H. et al. (2017). Índice Compuesto de Actividad Económica para la Provincia de Salta (ICCASal).
57. Mauro, L.; Manzo, F.; Stubrin, L.; Yeyati Preiss, L.; y Arza, V. (2022). *La industria naval en Argentina: situación actual y lineamientos de política para su desarrollo*. Documentos de Trabajo del CCE N° 21. Consejo para el Cambio Estructural - Ministerio de Desarrollo Productivo de la Nación.
58. Michel Rivero, A. D. (2007). El Índice Compuesto Coincidente Mensual de la Actividad Económica de Córdoba (ICACOR) 1994-2006. *Revista de Economía y Estadística*, 45(1), 31–73.
59. Modugno, M. (2013). Now-casting inflation using high frequency data. *International Journal of Forecasting*, 29(4), 664–675. <https://doi.org/10.1016/j.ijforecast.2012.12.003>
60. Modugno, M., Soybilgen, B., & Yazgan, E. (2016). Nowcasting Turkish GDP and news decomposition. *International Journal of Forecasting*, 32(4), 1240–1253. <https://doi.org/10.1016/j.ijforecast.2016.07.001>
61. Moore, G. (1960). *Statistical indicators of cyclical revivals and recessions*. New York: National Bureau of Economic Research.
62. Moreno Brito, D. J. (2020). *Modelo nowcasting: Predicción del PIB de Ecuador (Tesis de maestría)*. Universidad Torcuato Di Tella. <https://repositorio.utdt.edu/handle/20.500.13098/12466>
63. Muñoz, F.; Trombetta, M. (2015). *Indicador Sintético de Actividad Provincial (ISAP): un Aporte al Análisis de las Economías Regionales Argentinas*. *Journal of Regional Research*, 33: 71-96.
64. Ontivero, J.; Rodriguez M. & Kataishi, R. (2018) *Indicador Sintético de Actividades de la Provincia de Tierra del Fuego. Aportes Metodológicos*. Universidad Nacional de Tierra del Fuego.
65. Pizzi, D., Maradona, G., Maradona, M. F., Perlbach, I., Mattar, M., & Piran, G. (2019). *Indicador compuesto de actividad económica para la provincia de Mendoza [Documento de conferencia]*. Universidad Nacional de Cuyo.
66. Prakash, A., Thakur, I., & Bhowmick, C. (2022, June). *Nowcasting of India's GDP using dynamic factor model: Optimising the results [Conference paper]*. Reserve Bank of India.

67. Quillis, E., & Cuevas, A. (2010). Predicción en tiempo real del Producto Interior Bruto de la economía española. *Boletín Económico de ICE*, (3000), 1–15 de noviembre.
68. Sargent, T. J. and C. A. Sims (1977). *Business Cycle Modeling Without Pretending to Have Too Much a Priori Economic Theory*. Working Papers No. 55, Federal Reserve Bank of Minneapolis.
69. Stock, J. H., & Watson, M. W. (1989). New indexes of coincident and leading economic indicators. *NBER Macroeconomics Annual*, 4, 351–394.
70. Stock, J. H., & Watson, M. W. (2011). Dynamic factor models. En M. P. Clements & D. F. Hendry (Eds.), *The Oxford handbook of economic forecasting*. Oxford University Press. <https://doi.org/10.1093/oxfordhb/9780195398649.013.0003>
71. The conference board (2001). *Business cycle indicators handbook*. Nueva York.
72. Trujillo Aranda, F.; Benítez Márquez, D.; López Delgado, P. (2000). Trimestralización de los valores añadidos sectoriales mediante indicadores. Aplicación al caso de Andalucía. *Revista de Estudios Regionales*, 57, 59-100.
73. Varisco, C. (2018). Caso en estudio: Mar del Plata: sol, playa y ciudad. En: Dieckow, L (Comp.) *Los destinos turísticos naturales y culturales de Argentina. Casos en estudio. Primera Parte* (pp. 83-99). Posadas: UNM.
74. Wierny, M. (Ed.). (2012). *Producto Bruto Geográfico del Partido de General Pueyrredon. Año base 2004. Estimaciones y metodología*. Mar del Plata: Universidad Nacional de Mar del Plata. ISBN 978-987-544-431-4
75. Woelflin, M.; Ghilardi, M.; Lapelle, H.; López Asensio, G.; Yoya, A.; Geli, M.; Zabala, P. (2012). ¿Regiones exitosas en la postdevaluación? El Gran Rosario y su comparación con el Gran Córdoba. *Decimoséptimas Jornadas "Investigaciones en la Facultad" UNR*.
76. Yiu, M. S., & Chow, K. K. (2011). Nowcasting Chinese GDP: Information content of economic and financial data. *China Economic Journal*, 4(1), 53–70. <https://doi.org/10.1080/17538963.2011.563069>