



“Nowcasting para el PIB de Chile y el impacto de nuevos datos”

**TESIS PARA OPTAR AL GRADO DE
MAGÍSTER EN ANÁLISIS ECONÓMICO**

**Alumno: Matías Pacheco Robert
Profesor Guía: Óscar Landerretche Moreno**

Santiago, Mayo 2023

Resumen

A partir de un conjunto de indicadores de alta frecuencia, se realiza un pronóstico anticipado (*nowcast*) del producto interno bruto (PIB) de Chile del siguiente trimestre. El *nowcast* se estima mediante un modelo de factores dinámicos y posteriormente se emplea un suavizador de Kalman para manejar de manera eficiente las complicaciones asociadas a utilizar series de distinta frecuencia. Además, el modelo permite descomponer el impacto de la publicación de nuevos datos económicos en la proyección del producto. Por último, se realiza un *backtest* del modelo, obteniendo un mejor rendimiento que un modelo autorregresivo de orden uno.

Índice

1. Introducción	3
2. Datos	7
3. Metodología	12
3.1. Estimación nowcast	12
3.2. Descomposición de nuevos datos	14
4. <i>Nowcasting PIB de Chile</i>	16
4.1. Nowcast cuarto trimestre 2022	16
4.2. Backtesting	19
5. Conclusión	21

1. Introducción

El producto interno bruto (PIB) es uno de los indicadores más relevantes para conocer el estado de una economía, ya que su medición permite monitorear tanto el nivel de actividad como el crecimiento económico de un país. Sin embargo, en muchos casos la publicación de este dato presenta un rezago importante, lo que dificulta significativamente la toma de decisiones en tiempo real por parte de los hacedores de política y los inversionistas. En el caso de Estados Unidos, el PIB se publica cuatro semanas después de concluir el trimestre respectivo. En la zona Euro, el rezago es mayor, publicándose seis semanas después del fin del trimestre [Modugno et al. \(2016\)](#). En Chile, este dato se publica 48 días corridos después de terminado el trimestre, dificultando significativamente la toma de decisiones de corto plazo, especialmente en períodos de alta incertidumbre y volatilidad.

El índice mensual de actividad económica (IMACEC) es una variable que actúa como *proxy* del producto y que permite tener cierta noción del nivel de actividad económica en Chile. Esta variable es mensual y permite extraer una gran parte de la información del producto [Pedersen \(2010\)](#). No obstante presenta el mismo problema anteriormente descrito, ya que esta variable tiene un rezago de 31 días corridos. Por lo anterior, toma más relevancia el poder tener un modelo que pueda estimar de forma acertada y anticipada el producto del país.

Para resolver el problema del rezago en la publicación del PIB, se han desarrollado una serie de metodologías de predicción inmediata o *nowcast*. En un inicio, era común la utilización de las ecuaciones puente y los vectores autorregresivos (VAR, por sus siglas en inglés). El primero corresponde a regresiones que relacionan el crecimiento trimestral del PIB con una o varias variables mensuales agregadas a frecuencia trimestral. En esta metodología, las variables mensuales se pronostican utilizando modelos auxiliares como un modelo autorregresivo (ARMA) [Giannone](#)

et al. (2013b). El segundo es un modelo lineal más general, en donde cada variable depende de su propio rezago y del rezago de las variables explicativas Bok et al. (2017). Su excesiva parametrización puede llevar a inferencias inestables y pronósticos imprecisos fuera de muestra, especialmente en estimaciones con muchas variables Giannone et al. (2015). Algunos ejemplos de este tipo de estimación son Giannone et al. (2010) y Cimadomo et al. (2020).

Posteriormente, surgió el modelo MIDAS (por sus siglas en inglés, *mixed data sampling regression*), el cual utiliza regresiones de forma reducida y estrechamente parametrizadas entre una variable de baja frecuencia y un conjunto de indicadores de alta frecuencia. Para lidiar con las diferencias de frecuencia, la variable explicativa de mayor frecuencia se modela utilizando polinomios de rezago distribuido altamente parsimoniosos Foroni and Marcellino (2013).

A mediados de la década de los 2000, se desarrolló el modelo de factores dinámicos (DFM, por sus siglas en inglés). Esta metodología surgió con la publicación de Giannone et al. (2007), en donde el autor realizó un *nowcast* del PIB y la inflación de Estados Unidos, a partir de una representación de estado espacio. Esta representación permite el uso del suavizador de Kalman para obtener proyecciones tanto para las variables observadas como para las variables de estado no observadas Giannone et al. (2013b). A partir de esta investigación, surgió una vasta literatura relacionada. Algunos ejemplos son el PIB de la zona Euro Giannone et al. (2010), PIB de Estados Unidos Banbura et al. (2013), PIB de Turquía Modugno et al. (2016) y el PIB de Japón Kyosuke Chikamatsu (2018).

Para estimar el PIB de Chile, se utilizará el modelo de factores dinámicos, en conjunto con un suavizador de Kalman. Lo anterior permite que a partir de un conjunto de variables de alta frecuencia, como el índice de precios al consumidor (IPC), índice mensual de actividad económica (IMACEC), datos de ventas del comercio entre otras variables, se estime la variación año contra año del PIB trimestral de

Chile.

Para la estimación del *nowcast* se eligió el DFM debido a cuatro razones. En primer lugar, este modelo se formula naturalmente en una forma de espacio-estado y, por lo tanto, la inferencia se puede realizar utilizando técnicas de suavizador de Kalman, que a su vez proporcionan un marco conveniente y natural para tratar con datos de frecuencia mixta [Giannone et al. \(2013b\)](#). En segundo lugar, lidia de forma eficiente con el problema de la dimensionalidad, ya que el modelo aprovecha la colinealidad de las series, resumiendo toda la información disponible en unos pocos factores comunes, lo que elimina la limitación asociada a los grados de libertad [Giannone et al. \(2007\)](#). Tercero, como se demostró en [Doz et al. \(2012\)](#) las estimaciones de los factores comunes no solo son consistentes cuando el tamaño de la muestra y la dimensión son grandes, sino también robustas frente a la especificación incorrecta a nivel transversal, la correlación temporal de los componentes idiosincráticos y la no gaussianidad de los datos. Por último, la metodología permite descomponer el impacto de la publicación de nuevos datos en la variable de interés.

A pesar de que los *nowcast* son relativamente nuevos, rápidamente se han desarrollado para distintos países de América y Europa. Hasta ahora, no se cuenta con modelos de predicción inmediata de PIB para Chile. La publicación más cercana a lo propuesto, corresponde a un estudio del Banco Central de Chile, en donde utilizando datos en tiempo real se analiza cuánta información contiene el indicador mensual de actividad económica chilena (IMACEC) del PIB final, definido como la tasa de crecimiento que ha estado sujeta, al menos, a dos revisiones anuales [Pedersen \(2010\)](#). Por lo tanto, esta investigación viene a complementar una vasta literatura reciente sobre *nowcast* con modelos de factores dinámicos. Además, sienta las bases para el desarrollo de modelos de predicción inmediata para Chile a partir de datos de alta frecuencia.

La investigación se desarrolla de la siguiente forma: la sección dos presenta los

datos empleados para la estimación, además de las transformaciones aplicadas a dichas series. La tercera sección aborda en detalle la metodología utilizada, tanto para la predicción como para la descomposición del impacto de los nuevos datos. En el caso de la sección cuatro, se presenta la estimación del *nowcast* para Chile, luego se aborda el impacto que tuvieron los nuevos datos en el producto y posteriormente, el *backtest* del modelo. Finalmente, la sección cinco contiene las conclusiones de la investigación realizada.

2. Datos

La variable de interés a estimar con el *nowcast*, es el PIB volumen a precios del año anterior encadenado. La Figura 1 presenta la evolución de las variaciones con respecto al mismo trimestre del año anterior del PIB trimestral, desde 1997 hasta 2022. En primer lugar, la figura muestra el impacto que han tenido las distintas crisis en la actividad del país. Se observa como durante 1999, el PIB se contrajo un 3,23 %, luego durante la crisis del 2008-2009, la actividad cayó casi un 3,0 %. En el caso de la crisis asociada al Covid-19, la caída fue de 14,65 % aunque al año siguiente, el rebote fue de un 18,9 %.



Figura 1: Producto interno bruto, referencia 2018 (miles de millones de pesos), medido como porcentaje de variación con respecto al mismo período del año anterior.

Fuente: Elaboración propia basado en Banco Central de Chile.

Para predecir el producto se seleccionaron un conjunto de variables económicas y financieras, tanto objetivas como subjetivas (encuestas) publicadas por el Banco Central de Chile, Bloomberg y Google Earth, que se detallan en el Cuadro 1. Este cuadro presenta cada una de las variables utilizadas para la estimación del modelo. La segunda columna corresponde a la frecuencia con la que se publica cada variable,

la tercera columna muestra qué transformación se le realizó o si se utilizó en nivel, para asegurar la estacionariedad de las series. Finalmente, la columna llamada rezago muestra cuántos días luego de terminado el mes se publica el dato.

A continuación se hará una breve explicación sobre por qué se escogieron ciertas variables de las citadas anteriormente. En primer lugar, se seleccionó el IMACEC y la generación eléctrica, la primera corresponde a una *proxy* del PIB, mientras que la segunda ha sido ampliamente utilizada en la literatura como uno de los determinantes de la actividad (Pedersen (2010) y Urrutia A. and Sánchez Y. (2008)).

En segundo lugar, se incorporó la variación en la concentración de dióxido de nitrógeno (NO_2). A pesar de que no existen estimaciones previas que empleen esta variable en Chile, si se ha utilizado en otros países como China para proyectar la actividad Barcelona et al. (2022). Tal como se detalla en la Figura 2, al realizar una regresión entre esta variable y el IMACEC, se encuentra que existe una correlación positiva y significativa, lo que explica su incorporación.

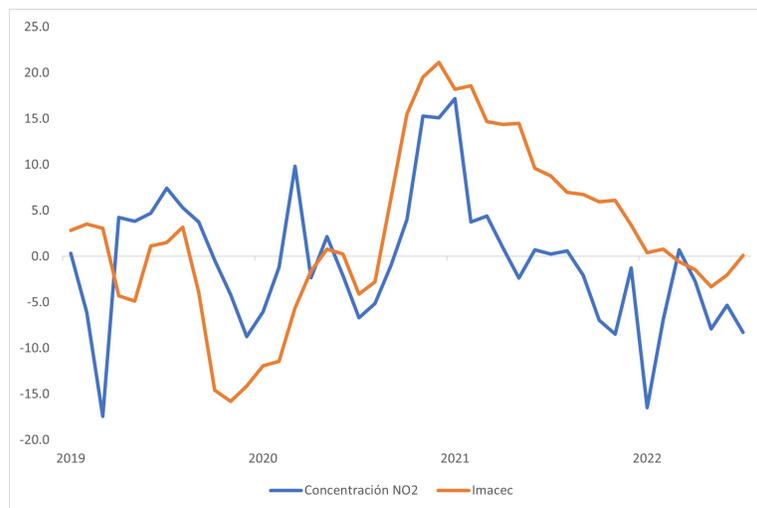


Figura 2: Relación histórica entre la concentración de dióxido de nitrógeno (NO_2) y el índice mensual de actividad económica, medidos como porcentaje.

Fuente: Elaboración propia basado en Google earth engine y Banco Central de Chile.

A su vez, se incluyó el índice de precios del consumidor (IPC) y el IPC sin volátiles, dado que una alta inflación implica que la economía se debe desacelerar mediante un alza de la tasa de política monetaria (variable también incluida). También se añadieron series de mercado, como el IPSA y las permutas de incumplimiento crediticio, por cuanto el mercado se ajusta rápidamente a cambios en la economía local. Por último, se agregó el índice de confianza empresarial, la confianza empresarial y la encuesta de expectativas del Banco Central, por cuanto como demuestra [Banbura et al. \(2013\)](#), la información blanda o proveniente de encuestas, resulta muy relevante a principios del trimestre, ya que no se dispone de información objetiva.

Cuadro 1: Cada fila corresponde a una serie utilizada para la estimación. La columna 1 presenta el nombre de la serie a utilizar. La segunda columna indica la frecuencia con que se publica cada serie. La columna 3 informa la transformación aplicada a cada serie para que sean estacionarias. Por último, la columna 4 reporta el número de días luego de finalizado el mes con que se publica cada dato.

Nombre serie	Frecuencia	Transformación	Rezago
Índice mensual de actividad económica	Mensual	Variación 12 meses	31
Generación eléctrica	Mensual	Variación 12 meses	30
Índice de producción industrial	Mensual	Variación 12 meses	30
Concentración de NO ₂	Mensual	Variación 12 meses	1
Despachos de cemento	Mensual	Variación 12 meses	30
Índice Mensual de Actividad de la Construcción	Mensual	Variación 12 meses	30
Índice de ventas mensual del comercio minorista	Mensual	Variación 12 meses	21

Continúa en la siguiente página

Cuadro 1 – *Continuación de la página anterior*

Nombre serie	Frecuencia	Transformación	Rezago
Masa monetaria	Mensual	Variación 12 meses	7
Índice de precios del consumidor	Mensual	Variación 12 meses	8
Índice de precios del consumidor sin volátiles	Mensual	Variación 12 meses	8
Tasa de política monetaria	Mensual	Variación 12 meses	1
Tasa de desempleo	Mensual	Variación 12 meses	Último día hábil del mes siguiente
índice de avisos laborales de internet	Mensual	Nivel	7
Exportaciones	Mensual	Variación 12 meses	7
Importaciones	Mensual	Variación 12 meses	7
Índice de Precios Selectivo de Acciones	Mensual	Variación 12 meses	1
Precio del Cobre	Mensual	Variación 12 meses	1
Precio del barril de petróleo	Mensual	Variación 12 meses	1
Permutas de incumplimiento crediticio de 5 años	Mensual	Variación 12 meses	1
Confianza del consumidor	Mensual	Nivel	30
PIB esperado por la Encuesta de Expectativas Económicas	Mensual	Variación 12 meses	11

Continúa en la siguiente página

Cuadro 1 – *Continuación de la página anterior*

Nombre serie	Frecuencia	Transformación	Rezago
Indicador Mensual de Con- fianza Empresarial: total	Mensual	Nivel	Último día hábil del mes

A partir de las series anteriormente descritas, se realiza un pronóstico inmediato de la variación del PIB a precios del año anterior encadenado en 12 meses. Aquí es importante mencionar que el número de variables seleccionadas es sumamente relevante. Si el número de series es demasiado pequeño, no se podrán captar de buena forma las dinámicas de la economía y el pronóstico será inexacto. Por otra parte, como ya se ha documentado, aquellos modelos construidos con un número excesivo de variables tampoco resulta óptimo en términos de precisión [Banbura and Modugno \(2014\)](#). Por lo tanto, se incluyó una cantidad de variables similar a las empleadas en el *nowcasting* de la Reserva Federal de Nueva York, ya que logra un buen equilibrio entre capturar las dinámicas de la economía y una cierta parsimonia del modelo.

3. Metodología

3.1. Estimación nowcast

Para la estimación del *nowcast*, se empleará un modelo de factores dinámicos, el cual se basa en el supuesto de que la presencia de fluctuaciones comunes en diferentes sectores de la economía implica fuertes correlaciones transversales, lo que sugiere que la mayor parte de las fluctuaciones son impulsadas por unas pocas fuentes comunes Bok et al. (2017).

Siguiendo la notación de Bok et al. (2017), este modelo asume que muchas variables observadas $(y_{1,t}, \dots, y_{n,t})$ son impactadas por unos pocos factores dinámicos no observados $(f_{1,t}, \dots, f_{r,t})$, mientras que las características que son específicas de las series individuales, como los errores de medición, son capturadas por errores idiosincráticos $(e_{1,t}, \dots, e_{n,t})$. El modelo se puede resumir en la siguiente ecuación:

$$y_{i,t} = \lambda_{i,1}f_{1,t} + \dots + \lambda_{i,r}f_{r,t} + e_{i,t}, \text{ para } i = 1, \dots, n \quad (1)$$

Esta ecuación relaciona la data $y_{i,t}$ con los r factores latentes comunes $f_{1,t}, \dots, f_{r,t}$ a través de los factores $\lambda_{i,1}, \dots, \lambda_{i,r}$. En conjunto, dan lugar al componente común $\sum_{j=1}^r \lambda_{i,j}f_{j,t}$, mientras que el componente idiosincrático $e_{i,t}$ captura los movimientos específicos de cada variable i Bok et al. (2017).

Para llevar a cabo la estimación del DFM mediante máxima verosimilitud y suavizador de Kalman, es necesario modelar tanto los factores comunes como el componente idiosincrático como procesos Gaussianos autorregresivos, dando cuenta de su correlación serial y persistencia Bok et al. (2017). En términos matemáticos, lo anterior se resume en dos ecuaciones:

$$f_{j,t} = \alpha_j f_{j,t-1} + \mu_{j,t}; \quad \mu_{j,t} \sim^{i.i.d.} N(0, \sigma_{\mu_j}^2) \quad \text{para } j = 1, \dots, r \quad (2)$$

$$e_{i,t} = \rho_i e_{i,t-1} + \epsilon_{i,t}; \quad \epsilon_{i,t} \sim^{i.i.d.} N(0, \sigma_{\epsilon_i}^2) \quad (3)$$

Las ecuaciones (1), (2) y (3) forman un modelo estado-espacio (EE), en donde los factores comunes e idiosincráticos son estados no observados. En este tipo de modelos, la ecuación (1) se conoce como ecuación de medición, la cual cumple el rol de vincular los datos con los estados no observados. Las ecuaciones (2) y (3) corresponden a las ecuaciones de transición, las que describen la dinámica del sistema [Bok et al. \(2017\)](#).

Para realizar la estimación de este modelo, se utiliza el método de maximización de expectativas. Lo anterior se debe a que este algoritmo es capaz de lidiar con patrones arbitrarios de datos faltantes, tal como se demuestra en [Banbura and Modugno \(2014\)](#). Por lo tanto, resulta menos restrictivo que otros métodos como el de dos etapas, al permitir que las series de tiempo tengan diferentes frecuencias.

Detallando la estimación paso por paso, el algoritmo comienza aplicando componentes principales y los parámetros del modelo se estiman mediante una regresión por mínimos cuadrados ordinarios, tratando los componentes principales como si fueran verdaderos factores comunes. En el segundo paso, dados los parámetros estimados, se obtiene una estimación actualizada de los factores comunes utilizando el filtro de Kalman. Finalmente, la estimación de máxima verosimilitud se obtiene iterando los dos pasos hasta la convergencia, teniendo en cuenta en cada paso la incertidumbre relacionada con el hecho de que los factores son estimados [Bok et al. \(2017\)](#).

3.2. Descomposición de nuevos datos

La estimación del PIB no se limita a una predicción puntual, sino que a medida que se van publicando nuevos datos, es posible de actualizar la estimación para el PIB del período en curso. Cada vez que esto ocurre, es posible descomponer el impacto que tuvieron los nuevos datos en el PIB, es decir, comprender en qué magnitud y con qué signo incidieron estos nuevos datos.

La descomposición del impacto de los nuevos datos, es posible debido a que dentro de un marco de espacio-estado, el mismo modelo también genera pronósticos para todas las variables, lo que permite extraer las novedades o el componente "inesperado" de los datos publicados [Banbura et al. \(2013\)](#).

Siguiendo la notación de [Giannone et al. \(2013a\)](#), se define Ω_v como el conjunto de datos disponibles hasta el mes v . En donde la estimación del PIB corresponde a la proyección ortogonal de y_t^Q basado en la información de Ω_v , lo que resulta equivalente a calcular la esperanza condicional $E(y_t^Q | \Omega_v)$.

En el período $v + i$, con $i = 1, \dots$, se publica nueva información, con lo que se produce una reestimación del producto a partir de Ω_{v+1} . Lo anterior implica que se producen diferencias en dos dimensiones entre ambos set de datos. Por un lado, se agregan nuevos datos, es decir, la base se vuelve más larga. Por otro lado, es posible que los datos sufran revisiones. Considerando lo anterior, podemos definir el *nowcast* del PIB como:

$$E[y_t^Q | \Omega_{v+i}] = E[y_t^Q | \Omega_v] + [y_t^Q | I_{v+i}] \quad (4)$$

En donde $[y_t^Q|\Omega_{v+i}]$ y $[y_t^Q|\Omega_v]$ son los *nowcast* nuevo y antiguo respectivamente. Por otra parte, $[y_t^Q|I_{v+i}]$ es la revisión en las dos estimaciones consecutivas. I_{v+i} representa la sorpresa entre la estimación y el dato efectivo o dicho de otro modo, $I_{v+i} = y - [y|\Omega_v]$. Lo anterior implica que para que se produzca una variación en la estimación del producto, se requiere que el dato nuevo difiera del valor estimado por el modelo DFM [Modugno et al. \(2016\)](#).

4. *Nowcasting PIB de Chile*

4.1. Nowcast cuarto trimestre 2022

La Figura 3 presenta la proyección del PIB realizada por el *nowcast* y el dato efectivo para el cuarto trimestre de 2022. La primera estimación cuenta con datos hasta octubre de 2022, con lo que se obtiene una proyección de producto de -1,82%. Al repetir la estimación un mes después, se obtiene un valor esperado de -2,03%. Finalmente, en la última iteración, el valor esperado es de -2,1%. Por lo tanto, se evidencia como a principios del trimestre, el modelo presenta una diferencia considerable entre el PIB efectivo y el pronosticado. Sin embargo, a medida que se van incorporando nuevos datos, la estimación se vuelve más precisa.

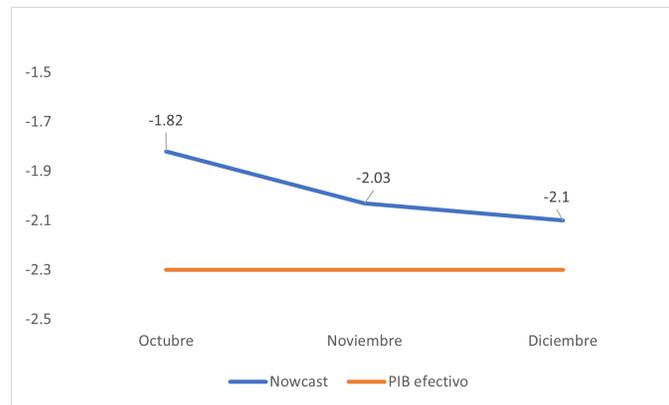


Figura 3: Comparación entre la variación año contra año del PIB proyectado por el nowcast y el PIB efectivo, para el cuarto trimestre del 2022, medido como porcentaje.

Fuente: Elaboración propia.

Cuadro 2: Impacto de la publicación de nuevos datos en la predicción de PIB, medido en puntos base. La segunda columna presenta la incidencia de cada variable en la estimación de noviembre, mientras que la tercera columna corresponde al impacto en la predicción del mes de diciembre.

Nombre serie	Noviembre	Diciembre
Índice mensual de actividad económica	0,00037	0,000072
Generación eléctrica	0,00001	-0,02
Índice de producción industrial	0,029	0,027
Concentración de NO ₂	0,0021	-0,016
Despachos de cemento	-0,06	-0,008
Índice Mensual de Actividad de la Construcción	-0,12	-0,000016
Índice de ventas mensual del comercio minorista	0,017	-0,0043
Masa monetaria	0,00061	-0,000098
Índice de precios del consumidor	0,0006	-0,00017
Índice de precios del consumidor sin volátiles	0	0,00011
Tasa de política monetaria	0,00093	-0,0065
Tasa de desempleo	0,000003	-0,0032
índice de avisos laborales de internet	-0,012	0,00013
Exportaciones	0,012	0,021

Continúa en la siguiente página

Cuadro 2 – *Continuación de la página anterior*

Nombre serie	Noviembre	Diciembre
Importaciones	-0,044	0,0058
Índice de Precios Selectivo de Acciones	-0,030	0,0027
Precio del Cobre	-0,00024	-0,00005
Precio del barril de petróleo	0,0016	0,0045
Permutas de incumplimiento crediticio de 5 años	0,0021	0,0019
Confianza del consumidor	0,0013	0,0031
PIB esperado por la Encuesta de Expectativas Económicas	-0,0045	-0,0053
Indicador Mensual de Confianza Empresarial: total	-0,12	0,037

Para que un dato nuevo tenga un impacto en el producto, se requiere que la publicación sea distinto al valor estimado por el modelo o que el dato anterior se revise. No obstante, dado que las bases de datos son reconstruidas, no es posible que los datos se revisen, por lo que todo el impacto se explica por la divergencia entre el valor efectivo y el estimado.

Como se evidencia en el Cuadro 2, la predicción más negativa de PIB de noviembre, se explica principalmente por la incidencia del índice mensual de actividad de la construcción, con un impacto de -0,12 puntos base. Sumado a lo anterior, también incidieron los despachos de cemento y las importaciones. En la siguiente iteración, la variación se explica principalmente por la generación eléctrica, con una incidencia de -0,02 puntos base.

4.2. Backtesting

A modo de robustez, se comparó el poder predictivo del *nowcast* con un modelo de referencia autorregresivo de orden uno, desde 2019 hasta 2022 ¹. Para esta comparación, se reconstruyeron bases de datos con todos los datos conocidos hasta el último día del trimestre respectivo.

La Figura 4 presenta los datos efectivos de PIB, la estimación del modelo de *nowcast* y el modelo autorregresivo. Visualmente se observa como para el primer dato, ambas estimaciones son relativamente similares, aunque el *nowcast* está más cerca del dato real. En el siguiente período, marcado por el estallido social, el modelo logra ajustarse de manera rápida al impacto que tuvo este en la actividad. En el caso de los años 2020 y 2021, tiempo marcado por la pandemia que implicó cuarentenas, restricciones de movilidad y fuerte estímulo fiscal, el modelo logra ajustarse de mejor manera a la gran contracción y posterior rebote de la economía chilena. Esto debido a que como se observa en el gráfico, el modelo autorregresivo no logra ver la caída del 2020 y en el 2021 tampoco ajusta de buena forma al rebote post reapertura. Ya en el 2022, con una economía más normalizada, se evidencia como el modelo ajusta de forma precisa a los datos de PIB.

El Cuadro 3 presenta métricas de error entre ambos modelos, con el fin de demostrar cuantitativamente que el *nowcast* logra un rendimiento superior al del modelo autorregresivo. Dicho lo anterior, se evidencia como en todas las métricas, es decir, error absoluto medio, error cuadrático medio y la raíz de este último, el *nowcast* obtiene un menor error que el modelo de referencia.

¹Nota: se compara desde 2019 debido a que la medición del dióxido de nitrógeno se posee desde ese período.

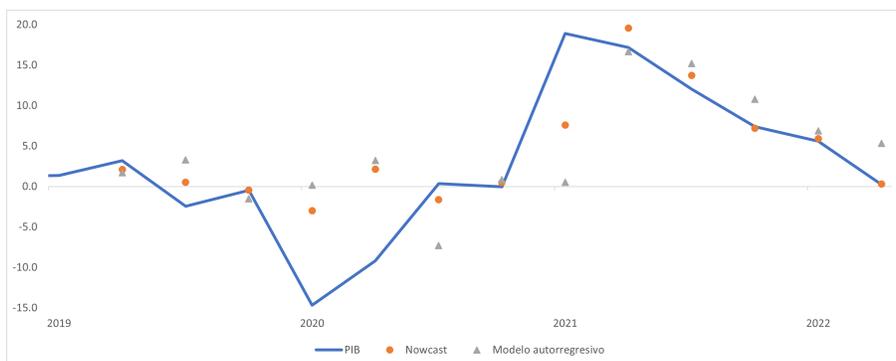


Figura 4: Comparación entre la variación año contra año del PIB efectivo y las predicciones realizadas por el nowcast y el modelo autorregresivo de orden uno.

Fuente: Elaboración propia.

Cuadro 3: Comparación de medidas de error entre el modelo propuesto y el benchmark.

Modelo	Error absoluto medio	Error cuadrático medio	Raíz del error cuadrático medio
Nowcast	3.5	31.9	5.7
Modelo autoregresivo	5.8	65.8	8.1

Fuente: Elaboración propia.

5. Conclusión

Los modelos de predicción inmediata se han vuelto herramientas cada vez más necesarios en la economía moderna, ya que estamos en un mundo donde la información fluye rápidamente. Por lo tanto, la capacidad de obtener una estimación precisa y actualizada del estado de la economía cobra mucha relevancia, tanto para los hacedores de política como para los analistas de mercado.

En el caso de Chile, el desarrollo de este tipo de metodologías aun es incipiente, por lo que este estudio contribuye al desarrollo y aplicación de modelos de predicción inmediata para el PIB, con el fin de mejorar el monitoreo de la economía y la toma de decisiones, especialmente en períodos de alta volatilidad.

Hay un gran potencial para mejorar la capacidad predictiva de estos modelos en el futuro. Esta investigación consideró un set acotado de variables relevantes, sin embargo, la inclusión de más datos de alta frecuencia, puede ser una forma importante de mejorar la precisión y la capacidad predictiva del modelo. Además, el modelo puede extenderse a otras variables macroeconómicas de baja frecuencia como la inversión y el consumo.

Referencias

- BANBURA, M., D. GIANNONE, M. MODUGNO, AND L. REICHLIN (2013): “Nowcasting and the Real-Time Data Flow,” in *Handbook of Economic Forecasting* ed. by Elliott, G., Granger, C., and Timmermann, A. Volume 2 of Handbook of Economic Forecasting: Elsevier, Chap. 0, 195–237, [10.1016/B978-0-444-53683-1](https://doi.org/10.1016/B978-0-444-53683-1).
- BANBURA, M., AND M. MODUGNO (2014): “Maximum likelihood estimation of factor models on datasets with arbitrary pattern of missing data,” *Journal of Applied Econometrics*, 29, 133–160, <https://EconPapers.repec.org/RePEc:wly:japmet:v:29:y:2014:i:1:p:133-160>.
- BARCELONA, W., D. CASCALDI-GARCIA, J. HOEK, AND E. V. LEEMPUT (2022): “What Happens in China Does Not Stay in China,” International Finance Discussion Papers 1360, Board of Governors of the Federal Reserve System (U.S.), [10.17016/IFDP.2022.1360](https://doi.org/10.17016/IFDP.2022.1360).
- BOK, B., D. CARATELLI, D. GIANNONE, A. M. SBORDONE, AND A. TAMBALOTTI (2017): “Macroeconomic nowcasting and forecasting with big data,” Staff Reports 830, Federal Reserve Bank of New York, <https://ideas.repec.org/p/fip/fednsr/830.html>.
- CIMADOMO, J., D. GIANNONE, M. LENZA, F. MONTI, AND A. SOKOL (2020): “Nowcasting with large Bayesian vector autoregressions,” Working Paper Series 2453, European Central Bank, <https://ideas.repec.org/p/ecb/ecbwps/20202453.html>.
- DOZ, C., D. GIANNONE, AND L. REICHLIN (2012): “A Quasi–Maximum Likelihood Approach for Large, Approximate Dynamic Factor Models,” *The Review of Economics and Statistics*, 94, 1014–1024, <https://ideas.repec.org/a/tpr/restat/v94y2012i4p1014-1024.html>.

- FORONI, C., AND M. MARCELLINO (2013): “A survey of econometric methods for mixed-frequency data,” Working Paper 2013/06, Norges Bank, https://ideas.repec.org/p/bno/worpaper/2013_06.html.
- GIANNONE, D., S. AGRIPPINO, AND M. MODUGNO (2013a): “Nowcasting China real GDP,” Technical report, Universite Libre de Bruxelles and CEPR, https://www.cirano.qc.ca/conferences/public/pdf/realtime2013/Papers/Giannone_Miranda.pdf.
- GIANNONE, D., M. LENZA, AND G. PRIMICERI (2015): “Prior Selection for Vector Autoregressions,” *The Review of Economics and Statistics*, 97, 436–451, <https://EconPapers.repec.org/RePEc:tpr:restat:v:97:y:2015:i:2:p:436-451>.
- GIANNONE, D., L. REICHLIN, AND M. BAÑBURA (2010): “Nowcasting,” Working Paper Series 1275, European Central Bank, <https://ideas.repec.org/p/ecb/ecbwps/20101275.html>.
- GIANNONE, D., L. REICHLIN, M. BAÑBURA, AND M. MODUGNO (2013b): “Nowcasting and the real-time data flow,” Working Paper Series 1564, European Central Bank, <https://ideas.repec.org/p/ecb/ecbwps/20131564.html>.
- GIANNONE, D., L. REICHLIN, AND D. SMALL (2007): “Nowcasting GDP and Inflation: The Real-Time Informational Content of Macroeconomic Data Releases,” *Money Macro and Finance Research Group, Money Macro and Finance (MMF) Research Group Conference 2006*, 2005, [10.17016/FEDS.2005.42](https://doi.org/10.17016/FEDS.2005.42).
- KYOSUKE CHIKAMATSU, Y. K. K. O., NAOHISA HIRAKATA (2018): “Nowcasting Japanese GDPs,” Bank of Japan Working Paper Series 18-E-18, Bank of Japan, <https://ideas.repec.org/p/boj/bojwps/wp18e18.html>.
- MODUGNO, M., B. SOYBILGEN, AND E. YAZGAN (2016): “Nowcasting Turkish GDP and news decomposition,” *International Journal of Forecasting*, 32, 1369–

1384, <https://EconPapers.repec.org/RePEc:eee:intfor:v:32:y:2016:i:4:p:1369-1384>.

PEDERSEN, M. (2010): “Extracting GDP Signals From the Monthly Indicator of Economic Activity: Evidence From Chilean Real-Time Data,” Working Papers Central Bank of Chile 595, Central Bank of Chile, <https://ideas.repec.org/p/chb/bcchwp/595.html>.

URRUTIA A., M., AND A. SÁNCHEZ Y. (2008): “Generación de Energía Eléctrica en un Modelo para Proyectar el IMACEC,” *Notas de Investigación Journal Economía Chilena*, 11, 99–108, <https://ideas.repec.org/a/chb/bcchni/v11y2008i2p99-108.html>.