



Minutas Citadas en el IPoM de Diciembre 2025

División Política Monetaria - Banco Central de Chile

RECUADRO I.1: EFECTOS DE LA INTELIGENCIA ARTIFICIAL EN LA ECONOMÍA GLOBAL

Benjamín Álvarez, Guillermo Carlomagno, María Teresa Reszczynski, Juan M. Wlasiuk y Gabriel Zelpo

RECUADRO I.2: COMPORTAMIENTO RECIENTE DE LOS PRECIOS DE BIENES

Felipe Guzmán, Lucas Bertinatto, Rodrigo Heresi, Eduardo Herrera, David Kohn, Jennifer Peña y Matías Pizarro

RECUADRO II.1: PERSPECTIVAS PARA EL PRECIO DEL COBRE

Benjamín Álvarez, Guillermo Carlomagno, Gustavo González, Valentina Hernández, Víctor Riquelme, Agustín Sanhueza y Gabriel Zelpo

RECUADRO II.2: TASA DE POLÍTICA MONETARIA NEUTRAL

Agustín Arias, Sofía Bauducco, Benjamín García, Mario Giarda, Nicolás Leiva y Carlos Molina

Minuta citada en el Recuadro I.1

Efectos de la Inteligencia Artificial en la economía global


Benjamín Álvarez, Guillermo Carlomagno, María Teresa Reszczynski, Juan M. Wlasiuk y Gabriel Zelpo

El entusiasmo por la inteligencia artificial (IA) ha impulsado fuertes inversiones en infraestructura y anuncios de nuevos planes de desarrollo, llevando la valorización de mercado de empresas tecnológicas a máximos históricos. Dada su relevancia en la economía global, resulta necesario identificar los principales efectos de este *boom*, además de analizar los riesgos asociados y las dudas que persisten sobre su impacto en el mediano plazo.

En el presente documento se detalla el análisis de los ejercicios presentados en el Recuadro I.1, “Efectos de la Inteligencia Artificial en la economía global”, del IPoM de diciembre 2025. Se incluyen los detalles de : (1) el ejercicio para cuantificar el efecto de la inteligencia artificial en el PIB de Estados Unidos, (2) el impacto en el consumo derivado del efecto riqueza producto del aumento en las valorizaciones bursátiles, (3) un ejercicio diseñado para cuantificar cuánto deberán aumentar los ingresos de las empresas IA para ser rentables en los próximos 5 años considerando distintos factores, y (4) los cálculos de los anuncios de las inversiones circulares realizadas durante el último año.

1. Impacto en cuentas nacionales

El auge de la inteligencia artificial se ha convertido en un motor relevante para la inversión, el comercio y los mercados financieros a nivel global. El gráfico 1 presenta algunas partidas relacionadas con la inversión en Estados Unidos que han mostrado un incremento significativo. Desde el lanzamiento de ChatGPT en noviembre de 2022, el gasto real en la construcción de centros de datos en Estados Unidos se ha triplicado. Asimismo, durante el primer semestre de este año, la inversión en equipos de procesamiento de información registró una variación real anual superior al 20%, muy por encima del promedio de 1,2% observado entre 2015 y 2023.



Nota: USD constantes 2017, miles de millones, anualizado y ajustado estacionalmente. Dato de gasto en centro de datos provienen del Census Bureau, deflactado por IPP de construcción.


Con el objetivo de cuantificar el impacto de la inversión en el PIB de Estados Unidos, se utilizan las partidas de cuentas nacionales relacionadas con el desarrollo de centros de datos y la infraestructura necesaria para su funcionamiento: inversión en equipos de procesamiento de información, en software y en investigación y desarrollo.

Dado que el auge de la inteligencia artificial es reciente, no es posible identificar en los datos de cuentas nacionales la inversión específica en infraestructura asociada a su desarrollo, es decir, centros de datos y la infraestructura energética requerida para su operación. Para aproximar estas inversiones, se emplearon datos del *Value of Construction Put in Place* del *Census Bureau*, que incluye series exclusivas sobre la construcción de centros de datos e infraestructura energética.

Las partidas de la inversión antes mencionadas asociadas a la IA tuvieron un importante crecimiento durante la primera mitad del 2025. Sin embargo, también se registraron aumentos significativos en las importaciones de productos asociados a esa inversión, sobre todo en el primer trimestre. Para cuantificar de manera correcta la contribución del auge de la IA al PIB, se tomaron en consideración las exportaciones netas de equipos de telecomunicaciones, computadores y accesorios, y semiconductores.

Con esto, la contribución de la inversión en IA al crecimiento anual del PIB se puede ver en el gráfico 2. En su conjunto, el aporte al crecimiento del segundo trimestre es de 0,8pp, explicando más de un tercio del crecimiento real anual del PIB en dicho período.

Gráfico 2: Contribución IA al PIB de Estados Unidos
(contribución en pp a variación a/a)



Nota IA incluye inversión Eq. De procesamiento de información, software, I+D, centro de datos, infraestructura energética y exportaciones netas de bienes relacionados a lo anterior. Contribución en pp a variación anual del PIB s.a.

2. Efecto riqueza–consumo

La inteligencia artificial también influye en la demanda agregada mediante un mayor consumo derivado del incremento en la riqueza financiera de los hogares, impulsado por la valorización de acciones de empresas vinculadas a esta tecnología. En esta sección estimamos cómo las variaciones en la riqueza accionaria afectan el consumo privado, considerando el reciente desempeño del mercado bursátil asociado a la IA. Para ello, calculamos el aumento de riqueza generado por el boom accionario y lo multiplicamos por una propensión marginal a consumir (PMC), calculado para variaciones de riqueza.

Para estimar el efecto riqueza en el consumo derivado del aumento en la valorización bursátil, se utilizaron datos de la base “[Financial Accounts of the United States \(Z.1\)](#)” publicada por la Reserva Federal. Esta base reporta trimestralmente el balance de los hogares incluyendo activos, pasivos y patrimonio neto. En particular, se emplearon las series que registran la tenencia de acciones—tanto directa como indirecta a través de fondos mutuos y planes de pensiones— y el patrimonio neto total de los hogares. En el gráfico 3, se puede observar que la tenencia de acciones (tanto directa como indirecta) como porcentaje de la riqueza neta de los hogares aumentó en los últimos trimestres a niveles superiores al 30%.

Gráfico 3: Tenencia de acciones de los hogares
(Porcentaje del total de riqueza neta de los hogares)



Nota: Datos de la Reserva Federal de Estados Unidos. Tenencia de acciones incluye aquellas mantenidas tanto de manera directa como indirecta (a través de compañías de seguro, fondos de pensiones, entre otros).

Para estimar el incremento neto en la riqueza accionaria atribuible a las valuaciones de IA, se calculó la variación observada desde fines de junio del presente año hasta la fecha y se ajustó restando el rendimiento promedio histórico registrado entre 1990 y 2019. Este procedimiento arroja un aumento accionario neto de 5,3%, el cual se aplicó posteriormente sobre la riqueza accionaria directa e indirecta existente a fines de junio.

Posteriormente, multiplicamos el aumento de la riqueza por la PMC calculada para aumentos de riqueza en la literatura. En particular, utilizamos $PMC = 0,035$, estimación de Aladangady y Feiveson (2018) en el modelo FRB/US¹, ampliamente empleada como parámetro de referencia de largo plazo en ejercicios de política y simulación macroeconómica de la Reserva Federal. Los valores a 2 y 4 trimestres (para 2025 y 2026) se obtienen de la dinámica de las IRFs implícitas en el modelo FRB/US.

En términos reducidos, el canal riqueza se aproxima por:

$$\Delta C_t \approx \beta \cdot \Delta W_t^{eq}$$

¹ Basado en el modelo FRB/US (Brayton y Tinsley, 1996); el modelo establece un nivel de consumo de equilibrio (C^*) determinado por los recursos totales disponibles, donde los cambios en la riqueza bursátil presentan un coeficiente sobre el consumo de 0.035, consistente con el rango canónico de 0.03-0.05 documentado por Reifschneider et al. (1999). Los cambios en las variables son registrados a partir de cambios respecto a tendencias históricas, en este caso, el rendimiento promedio histórico de la bolsa de valores desde 1990 al 2019. El modelo estima que aproximadamente el 60-65% del ajuste se completa en el primer año y cerca del 90% al cabo de dos años.

Donde ΔW_t^{eq} es el cambio en la riqueza accionaria de los hogares respecto a su tendencia histórica, en este caso en el valor de acciones corporativas directa e indirectamente mantenidas. Por su parte, β es la propensión marginal por consumir (0,035) ante el aumento de la riqueza de los hogares en acciones. De ello resulta en un aumento del consumo en el orden de 0,2% a 0,3% entre el 2025 y el 2026.

3. Ejercicio depreciación y aumento de ingresos

La inversión en inteligencia artificial (IA) requiere elevados desembolsos iniciales y genera gastos recurrentes significativos, principalmente asociados a la depreciación. Los centros de datos necesarios para ejecutar modelos de IA demandan inversiones sustanciales en infraestructura física y equipamiento especializado, incluyendo chips de alto rendimiento, sistemas avanzados de refrigeración y redes de baja latencia. Estos activos presentan ciclos de vida relativamente cortos debido a la rápida obsolescencia tecnológica, lo que acelera la depreciación física y contable, y obliga a reinversiones frecuentes para mantener la competitividad.

Como resultado, diversas estimaciones sugieren que para alcanzar el punto de equilibrio será necesario multiplicar la facturación de servicios de IA hasta quince veces los niveles actuales. Un artículo de Sequoia Capital proyecta que se requerirán ingresos anuales cercanos a USD 600 mil millones², mientras que un reporte de JP Morgan estima USD 650 mil millones hacia 2030³, frente a los aproximadamente USD 45 mil millones actuales.

Ejercicio de estimación

Este es un ejercicio simple y conservador, cuyo objetivo es dimensionar las magnitudes involucradas. Asumimos una inversión inicial de USD 720 mil millones⁴, consistente con la inversión ya realizada y conservadora frente a proyecciones hacia 2030 (McKinsey y Goldman Sachs estiman cerca de USD 5 billones; Bank of America proyecta USD 846 mil millones solo entre 2025 y 2026⁵).

Del total, 70% corresponde a hardware (en línea con reportes sobre inversiones en datacenters), y el resto a infraestructura complementaria (sistemas de refrigeración, redes y edificación). A partir de esto, se calcula un costo anual de depreciación, que depende de la vida útil asumida para los activos.

La vida útil contable es crítica: compañías como Alphabet, Amazon, Microsoft y Meta han extendido la vida útil de sus servidores de 3–4 años a un promedio de 6 años⁶, reduciendo el impacto de la depreciación. Sin embargo, persiste incertidumbre sobre la durabilidad real de los chips, dada la inmadurez del sector.

² David Cahn, AI's \$600B Question, Sequoia Capital, publicado el 20 de junio de 2024. Disponible en: <https://www.sequoiacap.com/article/ais-600b-question/>

³ J.P. Morgan, AI Capex – Financing the Investment Cycle: Implications of the Upcoming AI/Data Center Funding Surge, publicado en noviembre de 2025.

⁴ Cálculo realizado a partir de la contribución de la inversión en las distintas partidas asociadas a la IA, desde el primer trimestre del 2024 al segundo trimestre del 2025.


⁵ Goldman Sachs Investment Banking. The Building Blocks Behind AI's Next Wave. Octubre 2025. Disponible en: <https://www.goldmansachs.com>. McKinsey & Company. The cost of compute: A \$7 trillion race to scale data centers. Abril 2025. Disponible en: <https://www.mckinsey.com>. Bank of America Global Research. AI Capex Outlook: Hyperscaler Spending and Financing Needs. Mayo 2025.

⁶ Sobre la extensión de vidas útiles de servidores en big tech: Microsoft en agosto de 2022 modificó de cuatro años en promedio a seis años, Alphabet/Google en enero de 2023 lo hizo de 4 a 6 años, Amazon Web Services en enero de 2024, de 5 a 6 años y Meta en 2023 de 4,5 a 5 años.

A estos costos se suman gastos operativos fijos y variables, incluyendo mantenimiento de software y chips, y costos eléctricos (por ejemplo, USD 0,15 por kWh, considerando uso a capacidad plena). Sobre esta base, se incorpora una rentabilidad del 50%⁷, para estimar los ingresos necesarios que permitan cubrir gastos operativos y absorber la depreciación total.

Resultados

El efecto de la vida útil sobre los ingresos requeridos es altamente no lineal: con 6 años, los ingresos deberían aumentar entre 11 y 12 veces; con 4 años, el incremento sería de 13 veces; y con 2 años, el aumento llegaría a 21 veces, llevando la facturación actual hasta cerca de USD 1 billón anual, equivalente a casi el doble de la facturación global por smartphones (Gráfico 4).



Nota: cálculo en base a anuncios de inversión por USD 720 mil millones y supuestos especificados en minuta. Fuente: elaboración propia

4. Inversión circular

En el entorno actual de la inteligencia artificial han surgido preocupaciones sobre una posible “burbuja” en el sector. Esto responde a varios factores: el fuerte aumento en las valorizaciones de empresas vinculadas a la IA, las inversiones masivas en infraestructura, y también a la circularidad de este ecosistema. Cada vez son más frecuentes los acuerdos entre desarrolladores de modelos, proveedores de infraestructura y grandes *hyperscalers* que difuminan las fronteras entre clientes, proveedores y socios estratégicos.

Para dimensionar la magnitud de la inversión circular en el ecosistema IA, recopilamos anuncios públicos desde 2024 en los que empresas del sector declaran que invertirán en otras compañías IA. Por ejemplo, Nvidia planea invertir en torno a US\$100.000 millones en OpenAI, compañía que luego compra chips a Nvidia. De manera similar, Amazon ha invertido US\$4.000 millones en Anthropic, desarrollador de modelos de IA que también es cliente de sus servicios de computación en la nube. El ejemplo más reciente llegó en noviembre de 2025, cuando Microsoft y Nvidia anunciaron planes para invertir hasta US\$15.000 millones en Anthropic, la cual se comprometió a comprar US\$30.000 millones en capacidad de cómputo de los centros de datos de Microsoft utilizando chips de Nvidia (ver tabla con detalle de los anuncios recopilados en el Anexo 1). Estas operaciones ilustran la circularidad potencial del ecosistema: clientes que aseguran cómputo a largo plazo —es decir, garantizar la disponibilidad de capacidad de procesamiento— y, a la vez, proveedores de infraestructura y semiconductores que invierten en desarrolladores de modelos cuyos productos consumen su propia capacidad. El total de los anuncios suma

⁷ Utilizando márgenes de “Healthcare Information and Technology” de Damodaran, A. (2025). Margins by Industry: U.S. Companies. NYU Stern School of Business. Recuperado de https://pages.stern.nyu.edu/~adamodar/New_Home_Page/datafile/margin.html

aproximadamente US\$700.000 millones, lo que corresponde a algo más del 20% del total de necesidades de inversión en IA⁸. Una de las preocupaciones sobre la circularidad en el ecosistema de IA es que estos tipos de acuerdo tienden a impulsar el precio de las acciones de las empresas involucradas, pero con poco valor creado. En apariencia, señalan demanda y tracción, pero, en muchos casos, esa “demanda” es financiada por los balances de la empresa original (como en el ejemplo de Nvidia y OpenAI).

Conclusión

El auge de la inteligencia artificial ha impulsado inversiones históricas en infraestructura y elevado las valorizaciones tecnológicas, contribuyendo significativamente al crecimiento económico reciente mediante el aumento de la formación de capital y el efecto riqueza. No obstante, persisten desafíos vinculados a la concentración de inversiones y a la presión sobre la rentabilidad derivada de costos de depreciación, en un contexto donde la circularidad de acuerdos corporativos sugiere una demanda externa aún incipiente. Estos factores podrían generar volatilidad en las valoraciones y estrechamiento de las condiciones financieras globales.

Referencias

Aladangady, A., & Feiveson, L., 2018. “A” Not-So-Great Recovery in Consumption: What is holding back household spending?” (FEDS Notes). Board of Governors of the Federal Reserve System.

Brayton & Tinsley, 1996 “A guide to FRB/US: a macroeconomic model of the United States”. Finance and Economics Discussion Series, No. 96-42. Board of Governors of the Federal Reserve System.

Reifschneider, Tetlow & Williams, 1999. “Aggregate disturbances, monetary policy and the macroeconomy: The FRB/US perspective”. Federal Reserve Bulletin

Cahn, D. - Sequoia Capital, 2024. “AI’s \$600B Question”. <https://www.sequoiacap.com/article/ais-600b-question/>

J.P. Morgan, 2025. “AI Capex – Financing the Investment Cycle: Implications of the Upcoming AI/Data”

Goldman Sachs Investment Banking, 2025. “The Building Blocks Behind AI’s Next Wave”.

McKinsey & Company, 2025. “The cost of compute: A \$7 trillion race to scale data centers.”

Bank of America Global Research, 2025. “AI Capex Outlook: Hyperscaler Spending and Financing Needs.”

Anexo 1: Tabla con detalles de anuncios de empresas IA relacionados a inversión circular

Fecha anuncio	Inversor	Receptor	USD (billion)	Detalle	Link
23-01-2024	Microsoft	OpenAI	(Soporte Continuo)	Participación de ingresos: OpenAI comienza a pagar bajo términos extendidos en los que Microsoft recupera su capital vía créditos de	openai.com/index/next-chapter-of-microsoft-openai-partnership/

⁸ Según cálculos de [Goldman Sachs](#), la inversión acumulada para esta década en IA es de US\$3-4 billones de dólares.

Azure y puede recibir hasta 73% de las ganancias hasta alcanzar dicho umbral.

26-02-2024	Microsoft	Mistral AI	15	Distribución/licenciamiento: Microsoft se convierte en distribuidor de Mistral en Azure, con precompra de cómputo y soporte para el lanzamiento de Mistral Large; incluye garantías de crédito y acuerdos de consumo. Financiamiento con garantía: operación de deuda en la que las GPUs y flujos de cómputo actúan como colateral; NVIDIA aporta respaldo tecnológico y aseguramiento de capacidad.	mistral.ai/en/news/mistral-large
17-05-2024	NVIDIA (vía Blackstone)	CoreWeave	7,5	Licencias + nube: Google licencia modelos de Character.AI (no compra la empresa) y provisiona compute en Google Cloud; el paquete ayuda a regularizar facturas pendientes y a asegurar capacidad futura. Colaboración estructurada: tras el acuerdo estratégico, Amazon refuerza el vínculo con AWS (entrenamiento y servicio), incluyendo compromisos de compra de cómputo y aportes de capital adicionales.	CoreWeave - CoreWeave Secures \$7.5 Billion Debt Financing Facility led by Blackstone and Magnetar
04-08-2024	Google	Character.AI	2,7	Contrato de cómputo multianual: OpenAI acuerda comprar ~US\$300.000 millones en capacidad de cómputo de Oracle a ~5 años, uno de los mayores contratos de nube reportados.	goog012714-ars.pdf
22-11-2024	Amazon	Anthropic	4	Alianza estratégica: OpenAI y NVIDIA anuncian despliegue de 10 GW de sistemas NVIDIA en centros de datos; inversión cruzada y aseguramiento de suministro de hardware.	https://www.aboutamazon.com/news/aws/amazon-invests-additional-4-billion-anthropic-ai
10-09-2025	OpenAI	Oracle	300	Compromiso de despliegue: OpenAI se compromete a desplegar ~6 GW de GPUs AMD Instinct (MI450) de alta eficiencia dentro de un acuerdo multianual de suministro.	https://www.reuters.com/technology/openai-oracle-sign-300-billion-computing-deal-wsj-reports-2025-09-10/
22-09-2025	NVIDIA	OpenAI	100	Precompra de servicios de nube: OpenAI anuncia intención de adquirir ~US\$250.000 millones en servicios Azure (IaaS/PaaS), con prioridad de acceso y descuentos por volumen.	OpenAI and NVIDIA Announce Strategic Partnership to Deploy 10 Gigawatts of NVIDIA Systems NVIDIA Newsroom
06-10-2025	AMD	OpenAI	9	Participación + suministro: NVIDIA toma participación en Nokia y acuerdan que Nokia compre plataformas de próxima generación (GB) y GPUs para su infraestructura de redes y edge.	https://openai.com/index/openai-amd-strategic-partnership/
28-10-2025	OpenAI	Azure	250		https://blogs.microsoft.com/blog/2025/10/28/the-next-chapter-of-the-microsoft-openai-partnership/
28-10-2025	NVIDIA	Nokia	1		Nokia partners with Nvidia

18-11-2025	NVIDIA / Microsoft	Anthropic	15	Inversiones cruzadas + compute: NVIDIA se compromete a invertir hasta US\$10B y Microsoft hasta US\$5B en Anthropic; la startup se compromete a comprar ~US\$30B de Azure compute y hasta 1 GW con sistemas NVIDIA.	https://blogs.nvidia.com/blog/microsoft-nvidia-anthropic-announce-partnership/
26-11-2025	Consorcio / NVIDIA	xAI	6	Hardware: xAI asegura financiación para la compra de ~120k GPUs NVIDIA (H200/Blackwell) destinadas al cluster 'Colossus', con compromisos de entrega y soporte técnico.	https://x.ai/news/series-c

Minuta citada en el Recuadro I.2:

Comportamiento reciente de los precios de bienes

Felipe Guzmán, Lucas Bertinatto, Rodrigo Heresi, Eduardo Herrera, David Kohn, Jennifer Peña y Matías Pizarro^{1/ 2/}

El IPC está compuesto por bienes y servicios, que en la canasta con año base 2023 = 100, representan un 55% y 45% del total, respectivamente. Tras la última actualización del IPC, la participación de los bienes en la canasta aumentó 4,5pp (50,6% en la canasta 2018 = 100), incrementando así su relevancia sobre la evolución agregada de la medición de inflación en el país^{3/}.

En los años recientes, la variabilidad mensual en los precios de los bienes ha aumentado por sobre lo observado en años previos, a diferencia de lo que ha ocurrido en el caso de los servicios, para los que la variabilidad parece haberse mantenido relativamente estable (Gráfico 1)^{4/}. Este incremento en la variabilidad mensual de los precios de los bienes también se observa en los índices de difusión —i.e. porcentaje de productos cuyo precio aumenta o disminuye en el mes— que durante el último año han oscilado entre máximos y mínimos históricos (Gráfico 2).

A pesar de esto, la inflación anual de los bienes, tras experimentar importantes aumentos y disminuciones entre 2020 y 2023, se ha ubicado en torno a los niveles actuales desde 2024 (Gráfico 3). La simultaneidad de estos procesos sugiere que —al menos desde 2024— la mayor variabilidad mensual en los precios de los bienes se ha tendido a compensar a lo largo del tiempo (en particular, a lo largo de un mismo año), sin impactar de forma relevante sobre la evolución de la inflación anual de este agregado.

Esta minuta analiza los cambios en la volatilidad mensual en los precios de bienes, profundizando en algunas de las diversas razones detrás de su aumento en los años recientes. Esta se divide en cinco secciones. La primera sección estima la evolución de la volatilidad mediante el uso de modelos de volatilidad condicional a nivel de subclases del IPC. La segunda sección presenta evidencia internacional sobre la variabilidad de precios de bienes. La tercera sección presenta un análisis de frecuencia de ajustes de precios de bienes a partir de microdatos. La cuarta sección evalúa la relevancia de eventos de descuentos masivos en años recientes como

^{1/} Se agradecen comentarios y sugerencias de Markus Kirchner y Ernesto Pastén.


^{2/} Este estudio se realiza en el ámbito de la agenda de investigación que desarrolla el Banco Central de Chile (BCCh) en materias económicas y financieras de su competencia, en el marco de la cual el BCCh tiene acceso a información innominada de diversas entidades públicas y privadas, en virtud de convenios de colaboración suscritos con esas instituciones. Para garantizar la privacidad de trabajadores y empresas, el BCCh exige que el desarrollo, la extracción y la publicación de los resultados no deben permitir la identificación, directa o indirecta, de personas naturales o jurídicas. Funcionarios del BCCh procesaron los datos desagregados. Todo el análisis fue realizado por los autores y no involucra ni compromete al Servicio de Impuestos Internos (SII). La información contenida en las bases del SII es de carácter tributario proveniente de autodeclaraciones de los contribuyentes presentados ante el SII. La veracidad de dichos datos no es responsabilidad del Servicio.

^{3/} Al considerar la evolución de los ponderadores implícitos, también se observa un incremento en la participación de bienes respecto a la canasta previa. Para mayor detalle, ver Blog “Evolución de la inflación según la nueva canasta del IPC” ([febrero 2024](#)).

^{4/} De aquí en adelante se excluyen del análisis los componentes de energía del IPC, debido a que su elevada volatilidad promedio dificultaría el análisis en los agregados de bienes y servicios. El componente de energía del IPC representa un 8,6% del total y está compuesto por servicios, tal como electricidad, como también bienes, tal como la gasolina.

posible determinante de la mayor variabilidad mensual de precios de bienes. Finalmente, la quinta sección entrega algunas reflexiones finales.


Gráfico 1: Inflación mensual IPC bienes y servicios
(variación mensual, porcentaje)



Nota: Líneas horizontales representan los deciles 2 y 8 de las variaciones mensuales respectivas entre 2010 y 2019. Excluye energía.


Fuente: Banco Central de Chile, Instituto Nacional de Estadísticas.

Gráfico 2: Difusión inflacionaria IPC bienes
(porcentaje de productos que reportan alzas mensuales)



Fuente: Banco Central de Chile, Instituto Nacional de Estadísticas.

Gráfico 3: Inflación anual IPC bienes y servicios
(variación anual, porcentaje)



Nota: Excluye energía.

Fuente: Banco Central de Chile, Instituto Nacional de Estadísticas.

1. Modelos de volatilidad condicional a nivel de subclases del IPC

La aparente mayor variabilidad de los precios mensuales de bienes puede responder al comportamiento de un conjunto acotado de productos o, alternativamente, ser reflejo de un proceso más bien generalizado. Para evaluar esto, basado en la literatura de econometría financiera de los años 80s (Engle (1982), Bollerslev (1986)) así como Arango-Castillo et al. (2025) para el caso de la inflación, se estima un conjunto de modelos de volatilidad condicional (*Generalized Autoregressive Conditional Heteroskedasticity* o GARCH, por su sigla en inglés), a nivel de subclases del IPC, los que permiten capturar la dependencia y persistencia de la volatilidad en el tiempo ^{5/}.

En primer lugar, se construye un conjunto de modelos *benchmark* para la inflación mensual de cada subclase del IPC (series originales) ^{6/} entre los años 2000 y 2025, que se estiman con procesos *ARMA(p,q)* ^{7/} seleccionados en base a criterios de información bayesianos (BIC):

$$X_{s,t} = c_s + \sum_{i=1}^p \phi_{s,i} X_{s,t-i} + \varepsilon_{s,t} + \sum_{j=1}^q \theta_{s,j} \varepsilon_{s,t-j} \quad (1)$$

Donde $X_{s,t}$ corresponde a la variación mensual t de la subclase s del IPC (172 en total y 165 al excluir las subclases correspondientes a bienes y productos energéticos), c a la constante, p al número de rezagos seleccionado de la variable dependiente, ε_t al residuo y q al número de rezagos seleccionado de este último. Tras obtener el término de error estimado $\hat{\varepsilon}_t$, se realiza un *test* de Multiplicador de Lagrange (LM test, por su sigla en inglés, Engle (1982)) para heterocedasticidad condicional con hasta cuatro rezagos, con tal de evaluar si la varianza de los errores del modelo seleccionado depende o no de información pasada.

Luego, se desestiman aquellas subclases tanto de bienes como servicios en que no se pueda descartar la existencia de varianza homocedástica (i.e. la variabilidad no cambia a lo largo del tiempo). En particular, se

^{5/} Para esto, se utiliza el empalme histórico de subclases entre 1989 y 2023 (ver Juul y Guzmán, 2025), cuya granularidad y extensión permite analizar cambios en la volatilidad de estas series a lo largo del tiempo.

^{6/} Previo a esto se revisa el orden de integración de la inflación mensual de las subclases para descartar la presencia de raíz unitaria y que las series sean, al menos, débilmente estacionarias de forma asintótica.

^{7/} En particular, se estiman los modelos descritos permitiendo un máximo de dos rezagos, tanto para el componente autorregresivo (AR) como de medias móviles (MA).

encuentra que en 83 de las 172 subclases del IPC existe presencia de heterocedasticidad en los errores estimados, equivalente a un 44% del total de la canasta, de las cuales en torno a dos tercios corresponden a bienes y un tercio a servicios. Luego, para dichas subclases, se estiman modelos $GARCH(r, w)$ ^{8/} que consideran que la varianza depende tanto de los errores cuadráticos (r) así como de la varianza (w) pasados. En particular, considerando:

$$\varepsilon_{s,t} = \sigma_{s,t} z_{s,t} \quad (2)$$

Donde $\sigma_{s,t}^2$ corresponde a la varianza condicional estimada para cada subclase y $z_{s,t} \sim N(0,1)$. Luego, la varianza condicional se estima a partir de^{9/}:

$$\sigma_{s,t}^2 = \delta_s + \sum_{i=1}^r \alpha_{s,i} \varepsilon_{s,t-i}^2 + \sum_{j=1}^w \beta_{s,j} \sigma_{s,t-j}^2 \quad (3)$$

En este caso, δ corresponde a la constante y, los parámetros α_i y β_j se estiman por Máxima Verosimilitud (MLE), representando los coeficientes ARCH (*shocks* previos) y GARCH (persistencia), respectivamente. Además, estos deben cumplir con que $\alpha_i, \beta_j \geq 0$ y $\sum_{i=1}^r \alpha_i + \sum_{j=1}^w \beta_j < 1$ para asegurar que la varianza condicional estimada para cada subclase sea estacionaria.

Luego, para detectar la presencia de *clusters* de aumentos o disminuciones de variabilidad condicional a nivel de subclases, se aplica análisis de componentes principales (PCA, por su sigla en inglés) que permite reducir la dimensionalidad de los datos al mismo tiempo que mantiene la mayor cantidad posible de información (varianza). Para esto, se estima la matriz de covarianza de las series estandarizadas:

$$C = \frac{1}{n-1} X'X \quad (4)$$

Donde n representa el total de observaciones y X es la matriz de volatilidades condicionales estimadas previamente. A partir de esto se estiman valores propios λ_m y vectores propios v_m de la matriz C tal que $Cv_m = \lambda_m v_m$. Luego se ordenan los valores propios de forma descendente $\lambda_1 \geq \lambda_2 \geq \lambda_3 \geq \dots \geq \lambda_S$, donde $S \leq 172$ (siendo este número el total de subclases del IPC). Finalmente, cada componente principal es una combinación lineal del tipo:

$$CP_k = X^* v_k \quad (5)$$

En que se seleccionan k componentes principales. La varianza explicada se calcula como $\lambda_k / \sum_{i=1}^S \lambda_i$. Por su parte, X^* representa la matriz de volatilidades condicionales centrada/estandarizada. Lo anterior se estima de forma separada para aquellas subclases que pertenecen al IPC de bienes respecto de aquellas que pertenecen al IPC de servicios (excluyendo energía en ambos casos).


Los resultados muestran que en el primer componente principal de bienes se observa un incremento generalizado y común en la volatilidad del cambio mensual de sus precios. Este aumento fue notorio a fines de 2020 y desde entonces se ha mantenido en niveles relativamente elevados en comparación con la década

^{8/} Se opta por modelos tipo GARCH, en línea con lo planteado por Hossain & Arwatchanakarn (2016), quienes argumentan que su ventaja radica en la modelación condicional cambiante a lo largo del tiempo, a diferencia de otras medidas de volatilidad.

^{9/} Al igual que en la selección del proceso $ARMA(p, q)$, la varianza condicional estimada a partir de los modelos $GARCH(r, w)$ se estiman permitiendo un máximo de dos rezagos, tanto para los residuos cuadrados (r) como también de la varianza pasada (w).

previa. En cambio, en los servicios, la variabilidad se mantiene cerca de su promedio histórico tras experimentar un incremento más marcado en el año 2023 (Gráfico 4). Destaca además que el primer componente principal captura un 33% de la varianza en el caso de bienes y un 25% en el caso de los servicios, sugiriendo una mayor relevancia del componente común para explicar los cambios en la volatilidad condicional de los bienes respecto a los servicios^{10/}.

Gráfico 4: Componente principal de volatilidad mensual de IPC de bienes y servicios
(índices normalizados)



Nota: Corresponde al primer componente principal de la volatilidad condicional de errores estimados a nivel de aquellas subclases (excluye energía) en que se detecta la presencia de heterocedasticidad.

Fuente: Banco Central de Chile, Instituto Nacional de Estadísticas.

Como complemento al análisis de volatilidad condicional a nivel de subclases del IPC de bienes, se estimó la volatilidad condicional de distintos agregados de IPC y su relación con la volatilidad del tipo de cambio nominal, dada la relevancia de este particularmente en la evolución de corto plazo de los precios de bienes. Para ello, se utiliza una extensión multivariada de los modelos de volatilidad condicional que se enfoca en estimar la correlación condicional dinámica (*Dynamic Conditional Correlation GARCH* o DCC-GARCH, Engle (2002)) entre dos o más variables de interés. En este caso, se consideran los principales agregados del IPC (IPC total, IPC sin volátiles, IPC bienes sin volátiles, entre otros), en conjunto con el tipo de cambio. Para esto, se realizan los mismos tests y filtros implementados para los modelos de volatilidad condicional univariados descritos anteriormente.

Con $\varepsilon_{a,t}$ el error estimado a partir de procesos $ARMA(p, q)$ univariados para cada agregado a y el tipo de cambio nominal, los modelos DCC-GARCH estiman una matriz de covarianzas condicionales H_t :

$$H_t = D_t R_t D_t \quad (6)$$

Donde $D_t = \text{diag}(\sigma_{1t}, \dots, \sigma_{at})$ es la matriz diagonal de desvíos estándar condicionales estimados a partir de modelos GARCH univariados y R_t es la matriz de correlaciones dinámicas de estos. Así, se estiman las correlaciones condicionales dinámicas entre la volatilidad condicional de cada agregado de interés del IPC y el tipo de cambio.

Al enfocar el análisis en el componente subyacente del IPC, se observa que existe una correlación condicional positiva en el tiempo, es decir, que periodos de mayor volatilidad condicional del tipo de cambio coinciden

^{10/} Como robustez adicional se replicó este análisis a nivel de series desestacionalizadas para las respectivas subclases del IPC, obteniéndose resultados similares sobre la evolución de la volatilidad condicional de bienes y servicios.

con épocas de mayor variabilidad en dichos precios, manteniéndose esta relación relativamente estable desde 2015 en adelante. Respecto al IPC de bienes sin volátiles (excluidos los alimentos), la correlación condicional con la volatilidad del tipo de cambio es, en promedio, mayor al del resto de los agregados del IPC analizados, destacando la volatilidad cambiaria como un factor determinante de la volatilidad de los precios los bienes.

2. Variabilidad global de precios de bienes


Siguiendo la misma estructura de modelos de volatilidad condicional univariados descrita previamente, se estiman modelos GARCH en base a series de IPC globales^{11/} estandarizadas (Bajraj et al., 2023), en particular, para los agregados de bienes industriales sin energía. La muestra considera el periodo 2006 – 2025 y se reporta la mediana de las distintas medidas de volatilidad condicional del conjunto de países disponibles.

Los resultados sugieren que la mayor variabilidad mensual de precios de bienes no solo se ha observado en Chile, sino también en otras economías, ubicándose en este último caso por sobre lo observado en años previos a 2020 (Gráfico 5). Esto se evidencia a partir de la mediana de los modelos GARCH univariados estimados (volatilidad condicional), como también en el aumento del desvío estándar de la variación mensual de precios de bienes observada en los últimos años (volatilidad incondicional).

Los resultados entregan una evidencia complementaria a los resultados de Arango-Castillo et al. (2025), quienes reportan que aumentos generalizados en la volatilidad inflacionaria de economías avanzadas y emergentes coinciden con episodios de elevados niveles de inflación a nivel mundial.

Este incremento en la volatilidad mensual de los precios de los bienes a nivel global es coincidente con la ocurrencia de numerosos *shocks* durante los últimos años, como fueron los *lockdowns* y cierre de fábricas durante la pandemia, las medidas de estímulos implementadas en varias economías durante 2020 y 2021, significativos incrementos en los costos de transporte internacional y, más recientemente, la imposición de aranceles al comercio internacional de estos, entre otros.

Gráfico 5: IPC bienes industriales sin energía
(desvío estándar)



^{11/} Considera: Austria, Australia, Bélgica, Bulgaria, Bolivia, Brasil, Canadá, Suiza, Chile, Colombia, Chipre, República Checa, Alemania, Dinamarca, Ecuador, Estonia, España, Finlandia, Francia, Reino Unido, Grecia, Croacia, Hungría, Irlanda, Israel, Islandia, Italia, Japón, Corea del Sur, Lituania, Luxemburgo, Letonia, Macedonia del Norte, Malta, México, Países Bajos, Noruega, Nueva Zelanda, Perú, Filipinas, Polonia, Portugal, Paraguay, Rumania, Serbia, Suecia, Singapur, Eslovenia, Eslovaquia, Turquía, Taiwán, Estados Unidos.

Nota: Para Chile se utilizó el IPC Bienes que excluye energía, mientras que la serie global corresponde al IPC Bienes industriales sin energía en base a Bajraj et al., 2023. Para las series globales, se presenta la mediana entre todos los países considerados.

Fuente: Bajraj et al. 2023, Banco Central de Chile, Instituto Nacional de Estadísticas.

3. Frecuencia de ajustes de precios de bienes a partir de microdatos

En esta sección, se analizan los cambios en la frecuencia de ajustes de precios de bienes a partir de microdatos. Los resultados obtenidos de este análisis, tanto a partir de datos de documentos tributarios electrónicos como de datos del INE, sugieren que durante el periodo 2024-25 (2025 para datos INE) los precios de bienes se ajustaron con mayor frecuencia que lo observado en los años 2018-19. Esta mayor frecuencia de ajuste se observa tanto ante aumentos como caídas de los precios de los bienes, y es significativa desde un punto de vista estadístico. Por otro lado, el análisis a partir de los microdatos del INE sugiere que los cambios en las frecuencias de ajuste de precios de los servicios son más acotados en términos relativos.

3.1. Análisis con microdatos de Factura Electrónica (FE)

Datos y metodología

En este análisis usamos datos del universo de transacciones entre empresas para el periodo 2018 a 2025, en base a datos de documentos tributarios electrónicos recolectados por el Servicio de Impuestos Internos (SII). Cuando una empresa realiza transacciones comerciales con otra empresa, la firma vendedora debe emitir una factura que detalla la operación. La obligatoriedad en el uso de la factura electrónica fue introducida gradualmente en Chile desde 2014 para empresas grandes, hasta abarcar al universo de firmas del país a partir de febrero de 2018.

Cada factura incluye una descripción en texto libre de los productos vendidos. Utilizando métodos de aprendizaje automático como se describe en Acevedo et al. (2025), se clasifica cada bien transado en categorías estandarizadas de productos según el Clasificador de Consumo Individual por Finalidad (CCIF), utilizado por el Instituto Nacional de Estadísticas (INE) en la construcción del Índice de Precios al Consumidor (IPC). Con esta clasificación, utilizamos los microdatos de la factura electrónica para estimar medidas de rigidez de precios, enfocándonos en la frecuencia de los cambios de precios por productos, como se explica a continuación.

Se aplican filtros para eliminar *outliers*, productos fuera de la canasta del IPC, y variaciones de precios relacionadas con ofertas y no con patrones regulares (siguiendo a Nakamura & Steinsson, 2008). En particular, variaciones menores a \$10 pesos para una misma tupla firma-variedad de producto entre el mes t y $t + 1$ no son consideradas como cambios de precios. Además, se corrigen cambios temporales en los precios mediante un filtro de ofertas que elimina ajustes revertidos en el periodo siguiente, y se descartan observaciones con incrementos superiores al 30% o reducciones mayores al 20%. Estos pasos garantizan que las estadísticas reflejen cambios genuinos en precios y no distorsiones por ruido o eventos atípicos.

La base de datos utilizada para este análisis comprende 184 productos de un total de 283 que tiene la canasta completa del IPC, todos son bienes (no se incluyen servicios) y representan un 57% de la canasta del IPC.

Se define la frecuencia de cambio de precios (F) para cada categoría de producto " j " y mes " t " como:

$$F_{jt} = \frac{\sum_{i \in j} \mathbb{1}(P_{it} \neq P_{it-1})}{\sum_{i \in j} 1} * 100$$


Donde “ i ” es una variedad y “ j ” una categoría de producto (CCIF). Por lo tanto, F_{jt} representa el porcentaje de variedades del producto j que cambiaron su precio entre el mes $t - 1$ y el mes t .^{12/} El precio P_{it} es el precio mediano al que se comercializó la variedad “ i ” en el mes t .

Para cada categoría j , computamos el promedio de la frecuencia de cambios de precios en el período pre-pandemia (2018-2019) y el período más reciente (2024-2025). Finalmente, para agregar los indicadores en una medida general de frecuencia de cambio de precios, utilizamos los ponderadores oficiales del IPC-INE^{13/}.

Resultados

El Gráfico 6 compara las distribuciones de la frecuencia de cambios de precios en el período pre-pandemia (2018-2019) con el período más reciente (2024-2025), distinguiendo entre incrementos (panel A) y reducciones de precios (panel B). Las líneas verticales punteadas indican la mediana de la frecuencia de ajustes de precios en cada periodo que aumentó de 11% antes del COVID a 14% en 2024-2025 para los incrementos de precios, mientras que para las reducciones subió de 7% a 9%. Algo similar se evidencia al analizar las medias de la frecuencia de incrementos y reducciones de cambios de precios que aumentó de 14% en 2018-2019 a 17% en 2024-2025 para incrementos, y de 10% a 13% para reducciones de precios. Los aumentos en la frecuencia de cambio de precios tanto para la mediana como para la media son estadísticamente significativos, como se muestra en la Tabla 1^{14/}.

Gráfico 6: Distribución de frecuencia de ajuste de precios de bienes a partir de microdatos de FE (porcentaje)



Notas: Líneas verticales punteadas indican mediana de frecuencia de ajustes de precios en 2018-2019 y 2024-2025 para incrementos y reducciones de precios. Fuente: Banco Central de Chile en base a datos del Servicio de Impuestos Internos.

^{12/} Una variedad se define como una combinación única de firma vendedora y detalle del producto (como marca, volumen, color, etc.). En nuestros datos es la desagregación más fina dentro de cada categoría de producto.

^{13/} Los ponderadores originales son normalizados para el subconjunto de los productos del IPC para los que tenemos datos.

^{14/} Previo chequeo de normalidad, realizamos un test t para comparar las medias de las frecuencias de incrementos y reducciones entre los periodos 2024-2025 y 2018-2019, y un test de Wilcoxon no paramétrico para las medianas. En ambos casos, la diferencia resultó estadísticamente significativa al 1%.

Tabla 1: Comparación de medias y medianas muestrales de frecuencia de incrementos y reducciones de precios de bienes entre los periodos 2018–2019 y 2024–2025


	Diferencia de medias	Diferencia de medianas
Incrementos	0.025*** (0.003)	0.028***
Reducciones	0.021*** (0.003)	0.019***

Notas: Se reporta error estándar entre paréntesis para el caso de la diferencia de medias, en cuyo caso se usa test *t* para evaluar significancia estadística. Para el caso de diferencia de medianas, se usa el test no paramétrico de Wilcoxon. *** indica significancia estadística al 1%. Fuente: Banco Central de Chile en base a datos del Servicio de Impuestos Internos.

3.2. Análisis con microdatos de INE

Aplicando una metodología similar a la antes descrita para precios a nivel de variedad-establecimiento recolectados y procesados por el INE, es posible comparar el cambio en la frecuencia de ajuste de precios entre bienes y servicios del IPC. Dadas las diferencias en las características entre los datos públicos del INE y de factura electrónica, es esperable que la medición de frecuencia de ajuste de precios no sea idéntica. En particular, destaca que: i) los datos del INE debiesen ser más representativos de los precios que enfrentan los consumidores finales; ii) los datos del INE están sujetos a cambios metodológicos en su medición que podrían afectar la frecuencia de ajuste de precios, y; iii) los datos públicos del INE corresponden a información menos granular que aquella que puede observarse a partir de los microdatos de registros administrativos. Dicho esto, al analizar los cambios en la frecuencia de ajuste de precios promedio en 2018-19 versus 2025 según los datos del INE, también se observa un incremento similar tanto para aumentos como caídas de precios de los bienes (Gráfico 7). En el caso de los servicios, los cambios en las frecuencias de ajuste de precios se perciben más acotados en términos relativos.

Gráfico 7: Frecuencia de ajuste de precios según microdatos del INE
(porcentaje)



Fuente: Banco Central de Chile en base a información del Instituto Nacional de Estadísticas.

4. Eventos de descuentos masivos y su rol en el comportamiento del precio de los bienes

Una de las posibles explicaciones detrás del aumento en la variabilidad mensual del IPC de bienes apunta hacia el rol de eventos de descuentos masivos en años recientes.

Para evaluar su impacto, se estima un conjunto de procesos $ARMAX(p, q, w)$, bajo el mismo esquema que el presentado en la sección de modelos de volatilidad condicional. En particular, se estima el siguiente modelo:

$$X_{s,t} = c_s + \sum_{i=1}^p \phi_{s,i} X_{s,t-i} + \sum_{l=0}^w \beta_{s,l} y_{s,t-l} + \varepsilon_{s,t} + \sum_{j=1}^q \theta_{s,j} \varepsilon_{s,t-j} \quad (9)$$

Donde $y_{s,t}$ corresponde a una variable *categorica ordinal* que toma el valor cero si no ocurrió un evento de descuento masivo durante el mes, y que toma un valor positivo si ocurrió un evento durante el mes, cuya magnitud será igual a la cantidad de días del mes que dura el evento ^{15/}. Además, se realizan estimaciones adicionales donde se utiliza, para la identificación del evento de descuento masivo, no solo variables categóricas en los días que ocurre el evento, sino también una *dummy* en el mes previo o posterior.


Un elemento importante para tener en consideración es que la medición del impacto del evento en el IPC depende de múltiples factores, entre los que destaca la coincidencia entre la fecha de ocurrencia del evento y la fecha de recolección de la información por parte del INE considerando que, para varios bienes, se recolectan los precios una sola vez al mes. Así, se considerará como aquellos eventos con mayor probabilidad de ser medidos los que ocurren entre los días 4 y 24 de cada mes, acorde a la metodología de medición vigente del IPC y a lo sugerido tras observar los distintos eventos de descuento masivos de los últimos años.

Tras la estimación, definimos a los bienes sensibles a descuentos durante estos eventos a aquellos en que el coeficiente β es negativo y estadísticamente significativo al 15%. Lo anterior nos permite identificar aquellas subclases cuyo precio, en promedio, reacciona de forma relevante ante la ocurrencia de estos eventos, una vez controlado por la dinámica descrita en la ecuación (9). Este ejercicio se realiza únicamente para los bienes (excluyendo energía) considerando que son estos, en general, los productos susceptibles de descuentos durante los eventos de descuentos masivo.

Dependiendo de la ventana muestral y el criterio utilizado sobre la probabilidad de medición de dichos eventos, los resultados sugieren que entre un 20% y 30% del total de bienes que contempla el IPC (entre 10% y 15% de la canasta total) serían sensibles a la ocurrencia de estos eventos. Como especificación base, se contempla el periodo muestral más reciente (2021 – 2025) y se consideran solamente los eventos que cumplen con el criterio de medición antes descrito (que el evento ocurra entre el 4 y 24 de cada mes). Bajo este esquema, los resultados sugieren que, tanto en el mes del evento como en los meses precedente y siguiente, estos bienes tienen variaciones mensuales mayores a las que se observan en el resto de las subclases, explicando una parte importante del cambio mensual del IPC de bienes en torno a dichos eventos (Gráfico 8).

Gráfico 8: Inflación mensual IPC bienes sensibles a eventos de descuentos masivos
(variación mensual, incidencia, puntos porcentuales)

^{15/} Dada la metodología de medición de precios del INE, mientras más días dura un evento de descuento masivo, mayor debiese ser el efecto que se captura en el IPC, dado que la cantidad de establecimientos para los que se recolectan precios durante esos días irá aumentando.




Nota: El índice de bienes sensibles corresponde a aquellas subclases del IPC de bienes (excluye energía) en que se estima que los eventos de descuentos masivos de los últimos cinco años que han incidido negativa y significativamente. Líneas verticales indican meses con eventos de descuentos masivos seleccionados.

Fuente: Banco Central de Chile, Instituto Nacional de Estadísticas.

Los resultados sugieren que la reacción de los precios durante estos eventos ha tendido a aumentar en los últimos años, lo que ha coincidido con el aumento de las ventas en torno a estos. De hecho, el gasto anual en estos eventos como fracción del consumo durable se ha duplicado respecto a lo observado en el año 2019 (Gráfico 9). En esta línea, se estima que el impacto de estos eventos sobre aquellos bienes sensibles del IPC en los últimos cinco años es más del doble que su efecto promedio de los últimos 15 años (Gráfico 10). Así, la evidencia sugiere que parte de la mayor variabilidad mensual del precio de bienes se explica por el aumento en la relevancia de los eventos de descuentos masivos en el comportamiento de los precios de los bienes.


El Gráfico 10 presenta las estimaciones del beta promedio para un día de evento de descuento masivo con dos especificaciones. La primera es la descrita en la ecuación (9). La segunda considera una especificación alternativa en la que, para identificar el efecto de los eventos de descuento masivos, también se tiene en cuenta el cambio en el precio el mes previo o posterior a la ocurrencia del evento (que se espera sea positivo). Es interesante notar que el beta estimado ante ambas especificaciones es similar, sugiriendo los descuentos aplicados durante estos eventos suelen revertirse el mes siguiente o anticipan mayores alzas el mes previo.

Gráfico 9: Participación de algunos eventos de descuentos masivos en el Consumo Privado
(gasto en eventos anuales como fracción del total trimestral, porcentaje)



Fuente: Cámara de Comercio de Santiago, Banco Central de Chile.

Gráfico 10: IPC bienes sensibles a eventos de descuentos masivos
(coeficiente promedio ponderado en IPC bienes sensibles)



Nota: La muestra completa (2000 – 2025) contempla el total de eventos. Evento (T) representa el coeficiente promedio asociado a un día del evento (β), mientras que Evento (T-1; T+1) es el coeficiente promedio ponderado cuando se considera un efecto adelantamiento (T-1) y recuperación (T+1) en torno a un evento de descuento masivo (se reporta el coeficiente del mes T).

Fuentes: Banco Central de Chile, Instituto Nacional de Estadísticas.

5. Conclusiones

La presente minuta analiza la variabilidad mensual de los precios de bienes y servicios, sus cambios a través del tiempo y las posibles causas detrás de estos cambios. Distintas mediciones dan cuenta de un incremento en la variabilidad de los precios de los bienes, así como de la frecuencia de ajuste de precios de estos.

Distintos factores podrían explicar este comportamiento. Por un lado, la ocurrencia de shocks (globales y locales) que afectaron a los precios de los bienes aumentó durante los últimos años. Por otro, el impacto de eventos de descuento masivo en los precios de los bienes ha aumentado durante los últimos años, también entregando mayor variabilidad mensual en el precio de los bienes. Otras causas no exploradas en esta minuta

(como cambios en la estructura de costos de las empresas tras la mayor relevancia del canal de ventas digital, o posibles cambios en los costos de menú) también podrían ser otros factores que considerar.

REFERENCIAS

- Acevedo, P., Luttini, E., Pizarro, M., Quevedo, D., & Rojas, M. (2025). "Invoices rather than surveys: Using ML to monitor the economy". Mimeo.
- Arango-Castillo, L., Orraca, M. & Briseño, R. (2025). "Inflation volatility across advanced and emerging economies during the COVID-19 pandemic". Working Papers N° 2025-13. Banco Central de México.
- Bajraj, G., Carlomagno, G. & Wlasiuk, J. (2023). "Where is the inflation? The diverging patterns of prices of goods and services". Documento de Trabajo N°969. Banco Central de Chile
- Bollerslev, T. (1986). "Generalized autoregressive conditional heteroskedasticity". Vol. 31, Issue 3, P. 307-327, *Journal of Econometrics*.
- Breusch, T. & Pagan, A. (1979). "A simple test for heteroskedasticity and random coefficient variation". Vol. 47, Issue 5, P. 1287 – 1294, *Econometrica*.
- Engle, R. (1982). "Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation". Vol. 50, no. 4, *Econometrica*.
- Engle, R. (2002). "Dynamic Conditional Correlation: A simple Class of Multivariate GARCH Models". *Journal of Business & Economic Statistics*, Vol. 20(3), P. 339-350.
- Hossain, A. & Arwatchanakarn (2016). "Inflation and inflation volatility in Thailand". *Journal of Applied Econometrics*, Vol. 48(30), P. 2792-2806.
- Juul, M. & Guzmán, F. (2025). "Empalme de Subclases del IPC entre 1989 y 2023". Estudio Económico Estadístico N° 145. Banco Central de Chile
- Nakamura, E., & Steinsson, J. (2008). "Five facts about prices: A reevaluation of menu cost models". *The Quarterly Journal of Economics*, 123(4), 1415-1464.

Minuta citada en el Recuadro II.1

Perspectivas para el precio del cobre

Benjamín Álvarez, Guillermo Carlomagno, Gustavo González, Valentina Hernández, Víctor Riquelme, Agustín Sanhueza y Gabriel Zelpo

1. Introducción

Esta minuta brinda detalles acerca del análisis de la evolución reciente del precio del cobre, presentado en el Recuadro II.1 del IPoM de diciembre 2025, donde se justifica una corrección al alza de la perspectiva de precio del cobre a US\$4,6 la libra, desde los 4,3 previos.

A continuación, se entregan antecedentes relevantes por el lado de la oferta y de la demanda de cobre, para luego desarrollar un ejercicio econométrico que descompone la evolución del precio en función de distintos shocks estructurales, derivados de un análisis de alta frecuencia de precios de activos. En base a estos factores y a un juicio asociado a su persistencia, se elabora una proyección para el precio del metal hacia adelante.


2. Desarrollos recientes de la demanda

La demanda por cobre se ha acelerado durante los últimos años, impulsada principalmente por factores geopolíticos y tecnológicos, en desmedro de determinantes más tradicionales, más asociados a la industria establecida. Entre estos últimos sectores se cuentan el de la construcción, el eléctrico y el de elaboración de bienes electrónicos. En los últimos 10 años, la demanda tradicional por cobre ha aumentado 11%, mientras que la demanda proveniente de nuevas fuentes se ha multiplicado por cuatro veces, pasando a representar cerca del 15% del consumo total del cobre (Gráfico 1).

Entre las fuentes no tradicionales encontramos a la demanda asociada a factores geopolíticos, la transición energética y el impulso de la IA. El aumento de tensiones geopolíticas a nivel global ha llevado a varios países avanzados a impulsar planes de expansión del gasto en defensa y de reserva estratégica de minerales (ver [Recuadro I.1 del IPoM de septiembre de 2025](#)). Por su parte, la demanda asociada a la transición energética, explicada por el desarrollo de la energía solar, la energía eólica y la movilidad eléctrica, es la más significativa fuente no tradicional, alcanzando el 10% de la demanda total de cobre. Finalmente, la creación de centros de datos es una fuente de demanda incipiente, necesaria para la inteligencia artificial (IA), que ya explica 1,5% de la demanda total y con expectativas de que se duplique para 2030.

Gráfico 1: Consumo de cobre por sector

(eje izquierdo: millones de toneladas; eje derecho: porcentaje del total)



Nota: Eje izquierdo representa consumo de cobre anual expresado en millones de toneladas. Eje derecho muestra la proporción de fuentes no tradicionales de demanda respecto al consumo total, expresadas en toneladas.

Fuente: Estimaciones propias basadas en BNEF y USGS.

Demanda relacionada con centros de datos

La acelerada expansión de los centros de datos, impulsada por el auge de la IA, ha posicionado al cobre como un metal estratégico, dada su importancia en la construcción de esa infraestructura. En este contexto, el cobre se ha consolidado como un insumo crítico para la infraestructura digital moderna, gracias a sus características, como su alta conductividad eléctrica, capacidad térmica y durabilidad.

A medida que estas instalaciones se han vuelto más intensivas en términos de consumo energético, el uso de cobre por gigavatio instalado ha aumentado significativamente. Según la IEA¹, los centros de datos de mayor escala (sobre los 100 megavatios), que son cada vez más comunes en las nuevas inversiones que están entrando en curso, tienen un consumo anual de electricidad equivalente al utilizado por 350 mil – 400 mil autos eléctricos.

Diversas fuentes han estimado su intensidad en el uso de cobre, situándola entre 27 mil y 33 mil toneladas de cobre por gigavatio instalado (Tabla 1). El caso más cercano desde la industria proviene de un reporte de Microsoft, que en 2009 construyó un centro de datos de 80 megavatios (MW) de capacidad, en donde utilizó 2.177 toneladas métricas de cobre, lo que equivale a una intensidad de uso de 27 toneladas por MW.

Tabla 1: Intensidad de uso de cobre en centros de datos de IA
(miles de toneladas métricas/GW)


	miles de toneladas/GW
CRU	27
Copper Development Association	27
JP Morgan	30
Bloomberg Intelligence	27-33
Microsoft	27

Fuente: Elaboración propia

¹ International Energy Agency. (2024).

Utilizando una intensidad de cobre de 27 mil toneladas por gigavatio, correspondiente al rango inferior de las estimaciones antes mencionadas, y considerando las proyecciones de diversas fuentes sobre la construcción de centros de datos y su capacidad instalada en gigavatios, se estimó la demanda de cobre asociada a estas instalaciones (Gráfico 2). En el rango mínimo de las estimaciones, se requerirán entre 300 mil y 500 mil toneladas anuales para el desarrollo de centros de datos.

Gráfico 2: Demanda de cobre asociada a la construcción de centro de datos
(Miles de toneladas)



Nota: Estimación de demanda en base a proyección de contrapartes sobre la adición de capacidad en gigavatios por centro de datos construido. “Min” corresponde a la menor estimación de las contrapartes respecto al consumo de cobre para centro de datos, mientras que “Max” a la máxima. Se utiliza una intensidad de cobre de 27 mil toneladas por GW de capacidad añadida.

3. Oferta de cobre

Para identificar los shocks de oferta sobre la producción de cobre en frecuencia semanal, se elaboró un índice en base a las noticias sobre producción de cobre a nivel global, cuyo resultado se muestra en el Gráfico 3. Para su construcción, se utilizan las principales 70 minas por nivel de producción (que representaron 70% de la oferta global de 2025) y se realiza un seguimiento de las distintas noticias desde 2014 a la actualidad. Definimos noticias de oferta como aquellos cambios inesperados sobre la producción de cobre a nivel de mina. En este sentido, eventos negativos de oferta pueden deberse a paralizaciones laborales (por ej., Escondida 2017), accidentes operacionales (Spence, 2018), fallas técnicas (Olympic Dam, 2018), desastres naturales y/o actividad sísmica (inundaciones en el norte de Chile 2015, deslizamientos en Grasberg 2017), entre otros.


A lo largo de este año, han destacado los accidentes derivados de fenómenos naturales. Ejemplos de estas situaciones son las ocurridas en las minas de Kamo-Kakula, en la República Democrática del Congo, en El Teniente, en Chile, y en Grasberg, en Indonesia. Sin embargo, este año también hubo eventos positivos, como los aumentos en capacidad derivados de los proyectos de expansión en las minas de Antamina y Quellaveco, en Perú. Un listado de los shocks de oferta ocurridos durante 2025 se puede hallar en la Tabla 2. El Gráfico 3 presenta la perspectiva histórica.

Tabla 2: Shocks de oferta 2025

Mina	Shock (toneladas)	Razón	País
Grasberg	-246.000	Desastre natural	Indonesia
Kamo-Kakula	-155.000	Actividad sísmica	R. D. Congo
Quebrada Blanca	-72.200	Problemas técnicos	Chile

Collahuasi	-59.000	Clima y restricciones hídricas	Chile
El Teniente	-48.000	Actividad sísmica	Chile
El Soldado	-2.500	Leyes minerales	Chile
Quellaveco	30.000	Expansión producción	Perú
Antamina	60.000	Expansión producción	Perú

Gráfico 3: Noticias de oferta neta negativas
(Millones de toneladas)



Noticias de oferta definidos como incrementos o disminuciones inesperadas de producción de las 70 mayores minas expresadas en toneladas.

Fuente: Elaboración Propia


4. Costos de producción en Chile

Una dimensión relevante para el análisis sobre el impacto de los mayores precios del cobre sobre la economía chilena es el incremento sostenido de los costos de producción en los últimos años. Este fenómeno puede atenuar el efecto macroeconómico y fiscal de los mayores ingresos por ventas de cobre, incluso en términos reales, dado que la expansión de costos reduce los márgenes operativos, afectando la rentabilidad de los proyectos y, en consecuencia, la base imponible impositiva.

En este contexto, resulta fundamental considerar los costos asociados a la producción de una libra de cobre. Un indicador ampliamente utilizado es el *Cash Cost*, que corresponde al costo directo de producción e incluye gastos operacionales, como remuneraciones, energía eléctrica, insumos, tratamiento y refinación. Este indicador refleja la eficiencia operativa: cuando el precio del cobre se sitúa por encima del *Cash Cost*, la operación minera genera un margen positivo. De manera complementaria, se emplea el concepto de *Net Cost*, que incorpora además depreciación de equipos, gastos indirectos y costos financieros, proporcionando una visión integral de la rentabilidad más allá del desempeño operativo.

Según estimaciones de Cochilco, en Chile, los costos de producción actuales son significativamente más altos que los exhibidos en el período 2015-2020. En el Gráfico 4 se puede apreciar como en 2025 el *Cash Cost* se ubicó en USD/lb 1,77 mientras que el *Net Cost* lo hizo en USD/lb 3,02, lo que representa aumentos de 34% y 15%, respectivamente, respecto a diez años atrás.

Gráfico 4: Evolución de los costos en Chile
(US\$/lb)



Fuente: Cochilco

5. VAR estructural bayesiano

Para capturar las interacciones entre los distintos determinantes del precio del cobre, se emplea la misma metodología descrita en [Minuta Recuadro Junio 2024](#), un VAR estructural (SVAR) con identificación mediante restricciones de signo. El modelo es extendido para incorporar las disrupciones de oferta y la importancia creciente de los centros de datos en la demanda total de cobre.

El modelo usa datos semanales, con seis rezagos desde la primera semana de 2014 hasta la primera de diciembre del presente año. La especificación usada es la siguiente:

$$A_0 y_t = \mu + \sum_{j=1}^6 A_j y_{t-j} + \epsilon_t \quad \epsilon_t \sim N(0, \Sigma), \quad t = 1, \dots, T \quad (1)$$

Donde y_t es un vector con (i) el precio del cobre en base al contrato futuro a 3 meses transado en LME en US\$/lb (ii) un componente principal de los precios de metales tradicionales (iii) el ratio de un componente principal del precio de las principales bolsas accionarias sobre el precio del cobre (iv) el ratio de un componente principal del precio de ETF de acciones de defensa sobre el precio del cobre (v) el ratio de un componente principal del precio de ETF de empresas relacionadas a la transición energética y de centros de datos sobre el precio del cobre y (vi) las noticias de oferta descritas en la sección 3². Las variables (i) a la (v) se incorporan en diferencias logarítmicas, mientras que la variable (vi) de noticias de oferta está en porcentaje respecto a la producción total. Por su parte, A_i son matrices de coeficientes de 6x6, con A_0 invertible; μ es un vector 6x1 de constantes; y ϵ_t es un vector de shocks estructurales con media 0 y matriz de covarianzas Σ , que corresponde a la matriz identidad. La forma reducida del VAR es obtenida de (1)

$$y_t = c + \sum_{j=1}^6 B_j y_{t-j} + v_t$$

² Detalles de la elaboración de variables se encuentran en el anexo

Donde $B_i = A_0^{-1}A_i$, $c = A_0^{-1}\mu$ y $v_t = A_0^{-1}\epsilon_t$, tal que $E(v_tv_t') = \Omega = (A_0'A_0)^{-1}$

Los parámetros se estiman por métodos bayesianos, con Minnesota *priors*.

6. Identificación del modelo

Se identifican cinco shocks estructurales en el modelo en base a restricciones de signo y magnitud en las funciones de impulso respuesta, siguiendo el algoritmo de Arias et al. (2018). La Tabla 3 describe las restricciones de signo.

Tabla 3: Restricciones de signo					
	Demanda Tradicional	Oferta	Financiero	Verde & IA	Geopolítico
Cobre	+	+	+	+	+
Commodity tradicional	+	-			
Indice acciones / cobre	-	-	+	-	-
Empresas defensa / cobre	-	-			+
ETF verde y datacenters / cobre	-	-		+	
Noticias de oferta		+			


Además de las restricciones de signo, tanto el shock de demanda verde & IA como el geopolítico incorporan restricciones de magnitud. Esta práctica, común en la literatura, permite distinguir shocks cuando las restricciones tradicionales resultan insuficientes y se requiere información adicional para descartar modelos económicamente implausibles (Díaz y Ramírez, 2018).

Para identificar los shocks Verde & IA y Geopolítico, empleamos la magnitud relativa (ranking) de las respuestas como criterio explícito de clasificación, siguiendo la metodología de *Ranking Restrictions* validada por Albonico et al. (2022). En particular, ante un shock geopolítico, el impacto contemporáneo sobre el ratio entre el precio de las acciones de empresas de defensa y el precio del cobre debe ser mayor que el observado en el ratio entre el precio de los ETF verdes y de centros de datos y el precio del cobre. Por el contrario, ante un shock asociado a transición verde e inteligencia artificial, el efecto sobre el ratio de los ETF verdes y centros de datos respecto al cobre debe superar al del ratio de las empresas de defensa.

Finalmente, la implementación se realiza mediante el algoritmo de Arias, Rubio-Ramírez y Waggoner (2018), que trabaja con shocks estructurales estandarizados. Esto garantiza que la restricción de magnitud relativa compare elasticidades estructurales, asegurando interpretaciones consistentes y comparables entre variables.

7. Resultados descomposición histórica

La descomposición del precio del cobre en los distintos shocks descritos en la sección anterior se muestra en el Gráfico 5. Desde febrero de este año destacan los shocks de oferta ocurridos a comienzos de año, como el asociado a la mina Collahuasi, junto con las disrupciones en los mercados financieros derivadas de los aranceles impuestos por la administración Trump. Hacia mediados de año sobresale el impacto del factor geopolítico, en un contexto donde varios países incrementaron significativamente su gasto en defensa, beneficiando a empresas del sector. Posteriormente, se observa el repunte del factor verde y de IA, impulsado por la creciente demanda de centros de datos y su efecto sobre el consumo energético -en particular, renovable-, además del buen desempeño que esto generó en los mercados financieros. Finalmente, vuelve a cobrar relevancia el factor de oferta, con las disrupciones registradas en las minas de Grasberg y El Teniente, entre otras.



Nota: VAR con restricción de Signo, con 6 rezagos en frecuencia semanal desde la primera semana del 2014 hasta la primera semana de diciembre del 2025. Variación acumulada desde principios de febrero se muestra en eje izquierdo. Total (eje derecho) es el precio del cobre LME US\$/libra.
Fuente: Elaboración propia y Bloomberg

Asumiendo que los componentes de oferta, financiero y el residuo se disiparán paulatinamente y el resto de los componentes tendrán un carácter más persistente, se llega a una corrección al alza del supuesto de precio hacia el 2027 del orden de 7%, compatible con una corrección a US\$4,6 por libra, desde los 4,3 anteriores.

8. Impacto de los distintos shocks sobre el Tipo de Cambio Nominal

En esta sección, ilustramos la importancia de distinguir entre las fuentes de los shocks del precio del cobre al analizar sus consecuencias macroeconómicas. Para analizar los efectos sobre el Tipo de Cambio Nominal (TCN) de los distintos shocks al precio del cobre empleamos funciones de impulso respuesta (IRF), obtenidas con *Local Projections*. El análisis se basa en la siguiente especificación:


$$\Delta \log(TCN_{t+h}) = \theta_h + \sum_{q=0}^4 \beta_{h,q} S_{t-q} + \sum_{q=1}^3 \delta_{h,q} \Delta(Controls_{t-q}) + \epsilon_{t+h}$$

donde la variable dependiente TCN representa la variable macroeconómica de interés, el tipo de cambio nominal peso chileno – dólar de EE.UU. Los shocks estructurales de interés se denotan por S , mientras que *Controls* es un vector que contiene al resto de los shocks estructurales como un conjunto de controles. El término θ_h captura la constante y ϵ_{t+h} es el error idiosincrásico.

El Gráfico 6 muestra la IRF acumulada a 2 semanas de los diversos shocks definidos en la sección 6. El tamaño de los shocks es de un desvío estándar. El impacto más significativo se observa en el de verde & IA, el de demanda tradicional y el financiero. En contraste, los shocks de oferta y geopolíticos tienen impactos cercanos a cero. En el caso del geopolítico, el resultado estaría asociado al deterioro de las perspectivas globales y el aumento de las tasas de interés, que acompañan al aumento

del precio del cobre, lo que termina compensando el efecto apreciativo. En el caso de la oferta, lo mayores precios vienen acompañados de menores cantidades, lo que limita el efecto en la entrada de divisas y, por tanto, en el tipo de cambio.

Gráfico 6 - IRFs acumuladas a dos semanas ante shocks de un desvío estándar



Nota: Estimación realizadas desde octubre del 2019 hasta la primera semana de diciembre. Las funciones impulso-respuesta (FIR) se normalizan para representar un aumento de un desvío estándar al momento del impacto. Los intervalos de confianza se establecen en el 66%.

La heterogeneidad de los efectos de los distintos shocks sobre el TCN podría explicar parte de la menor respuesta reciente de esa variable al precio del cobre. El gráfico 7 muestra la evolución del precio del cobre, comparada con un escenario contrafactual donde solo ocurren shocks de demanda tradicional, verde + IA y financiero. Como allí se observa, desde 2015 hasta 2023, solo con esos tres shocks se logra un buen ajuste del precio. Desde 2023, la relación se pierde y el nivel de precio predicho por esos tres shocks es significativamente menor que el observado. Ello se debe a que los shocks de oferta y geopolíticos cobraron mayor relevancia. Dado que esos shocks tienen impacto en torno a cero sobre el TCN, ello podría explicar un aparente desajuste entre el precio del cobre y el nivel del TCN.

Gráfico 7 - Precio del cobre con factores de demanda




Nota: línea negra representa el precio del cobre explicado solamente con shocks verde & IA, tradicional y financiero.

9. Proyecciones de contrapartes

La dinámica reciente del cobre también ha generado una revisión al alza de su precio en el mediano plazo por parte de distintas contrapartes (gráfico 9). Cochilco remarca que una transición energética acelerada e inversiones en redes y renovables podrían elevar el consumo de cobre por sobre lo previsto. Por su parte, Consensus Forecast subraya la inclusión del metal en la lista de minerales críticos debido a razones de seguridad nacional por parte de Estados Unidos, incentivando una mayor demanda. También recalcaron medidas regulatorias por parte de China, que limitan la capacidad de fundición de cobre, buscando evitar pérdidas en rentabilidad por exceso de oferta y caídas en las tarifas de procesamiento. El modelo desarrollado en secciones anteriores ubica nuestras proyecciones en torno a las de diferentes contrapartes (Gráfico 8).


Gráfico 8: Proyecciones contrapartes 26 vs 27 (1)
(US\$/lb; nominal; círculos vacíos es proy. previa)



(1) Reporte de Consensus compara noviembre contra agosto, CRU noviembre vs julio. Hacienda expertos es proyección de este año vs el anterior. Para Cochilco se usa sólo la proyección de 2026 reportada en agosto (círculo vacío) vs noviembre.

Fuente: Elaboración Propia Consensus Forecast, Copper Research Unit, Comisión Chilena del Cobre, Ministerio de Hacienda y Bloomberg.

Gráfico 9: Proyecciones actuales de contrapartes para el promedio de 2027 vs proyección anterior (2)
(US\$/lb; nominal)



(2) Cifras corresponden al promedio 2027, salvo para Cochilco que corresponde a promedio 2026

Fuente: Elaboración Propia Consensus Forecast, Copper Research Unit, Comisión Chilena del Cobre, y Ministerio de Hacienda.

Conclusión

El ejercicio presentado tiene como objetivo dilucidar el grado de persistencia que existe en el alza del precio del cobre observado este año. Con la aproximación metodológica propuesta, junto con la evaluación de contrapartes especializadas, se puede deducir que los factores persistentes elevarían el precio en torno a 7% para el 2027, lo que equivale a un precio del orden de USD/lb 4,6, en comparación con los 4,3 anteriores.

Referencias

- Albonico, A., Ascari, G., & Paccagnini, A. (2022). *Identification and inference with ranking restrictions*. Journal of Quantitative Economics, 12(1), 1–39.
- Antolín-Díaz, J., & Rubio-Ramírez, J. F. (2018). *Narrative sign restrictions for SVARs*. American Economic Review, 108(10), 2802–2829.
- Arias, Jonas E, Rubio-Ramírez, Juan F, & Waggoner, Daniel F. 2018. *Inference based on structural vector autoregressions identified with sign and zero restrictions: Theory and applications*. Econometrica, 86(2), 685–720.
- BloombergNEF. (2025). *Tracking copper in data centers 2025–2035: Copper crunch climbs*. Bloomberg Finance L.P.
- Cochilco. 2025. *Informe de Tendencias del mercado del cobre. Proyecciones 2025-2026*.
- Comité Consultivo del Precio de Referencia del Cobre. 2025
- Consensus Forecast. Noviembre 2025. *Energy, Metals & Agriculture*.
- Copper Research Unit. 2025
- International Energy Agency. (2024). *What the data centre and AI boom could mean for the energy sector*. IEA.
- Jordá Oscar. 2005. *Estimation and inference of impulse responses by local projections*. American economic review, 95(1), 161–182.
- Kilian, L., & Murphy, D. P. (2012, October). *Why agnostic sign restrictions are not enough: Understanding the dynamics of oil market VAR models*. Journal of the European Economic Association, 10(5), 1166–1188.
- Koop, Gary, & Korobilis, Dimitris. 2010. *Bayesian Multivariate Time Series Methods for Empirical Macroeconomics*. Foundations and Trends in Econometrics, 3(4), 267–358.
- Litterman, Robert B. 1986. *Forecasting with Bayesian vector autoregressions—five years of experience*. Journal of Business & Economic Statistics, 4(1), 25–38.
- Stuerner, Martin. 2017. *Industrialization and the demand for mineral commodities*. Journal of International Money and Finance, 76, 16–27.

Anexo

Especificación de variables

Todos los factores se construyen a partir del primer componente principal de las siguientes variables, que se expresan en logaritmos y se indexan a 100 en enero de 2014:

- **Commodities tradicionales:** plomo, mineral de hierro y petróleo Brent.
- **Factor financiero:** Dow Jones, S&P 500, Nasdaq, Nikkei y Euro Stoxx 50.
- **Acciones de guerra (defensa):** cartera ponderada por capitalización de mercado compuesta por L3Harris Technologies, Howmet Aerospace, TransDigm Group, Northrop Grumman, Taser International y RTX Corporation.
- **Factor verde & IA:** iShares Global Clean Energy Transition, VanEck Semiconductor e iShares Semiconductor

Minuta citada en el Recuadro II.2:

Tasa de Política Monetaria Neutral

Agustín Arias, Sofía Bauducco, Benjamín García, Mario Giarda, Nicolás Leiva y Carlos Molina ¹

Esta minuta describe la actualización de la estimación de la tasa de interés de política monetaria neutral (TPMN). Esta variable se define como el valor al cual se espera que converja la TPM una vez que los efectos de los shocks transitorios se hayan disipado, coherente con un PIB en su senda de equilibrio tendencial y una inflación en la meta. La tasa estimada corresponde al valor de tendencia de una tasa real de corto plazo que no incluye primas por riesgo o por plazo.

La revisión extiende la muestra de datos hasta el tercer trimestre de 2025, cinco trimestres adicionales de información respecto a la última actualización, de septiembre 2024. La naturaleza inobservable e incierta de la TPMN motiva el uso de una batería de modelos habitualmente empleados por otros bancos centrales y la academia. En esta oportunidad, por razones metodológicas que se desarrollan más adelante, se incluyó el método de [Holston, Laubach y Williams \(2023\)](#) — ampliamente utilizado por otros bancos centrales— y se excluyeron los modelos de Regla de Taylor y de Consumo con Hábitos presentes en la última evaluación.²

Los resultados de las estimaciones entregan una media y mediana en torno a 1,2, con un rango entre 0,9% y 1,7%.

El resto de la minuta se estructura de la siguiente manera: la sección 2 presenta el marco conceptual en que se desarrolla este capítulo. La sección 3 describe cambios metodológicos y los resultados obtenidos. La sección 4 resume las principales conclusiones de esta actualización.

2. Marco Conceptual

La tasa de política monetaria neutral –TPMN– se define como el valor al cual se espera que la TPM converja una vez que los efectos de los shocks transitorios se hayan disipado. Esta tasa corresponde al nivel de tendencia de una tasa real de corto plazo libre de riesgo (i.e. no incluye primas por riesgo o por plazo) coherente con un PIB en su senda de equilibrio tendencial y una inflación en su meta de 3%.

Con respecto a sus determinantes, esta tasa de referencia se ve afectada por movimientos de baja frecuencia en diversos factores que inciden sobre el equilibrio entre ahorro e inversión de la economía y, por lo tanto, sobre sus tasas de interés. Por ejemplo, aumentos en las tasas de crecimiento de la productividad aumentan las oportunidades de inversión de las firmas y mejoran las expectativas de ingresos futuros de los hogares. Esto lleva a una mayor inversión y a un menor ahorro, respectivamente, tendiendo a aumentar la TPMN. Algo similar ocurre frente a una reducción en los niveles de incertidumbre que llevan a un menor ahorro precautorio por parte de los hogares y elevan la predisposición de las firmas a invertir. Por su parte, un aumento en la esperanza de vida genera un incremento del ahorro de los hogares que buscan anticiparse a un periodo de retiro más largo. A su vez, mientras el envejecimiento de la población tiende a aumentar el

¹ Se agradecen comentarios y sugerencias de Elías Albagli, Rodrigo Heresi y Markus Kirchner.

² Ver [Minutas citadas en el IPoM de Septiembre de 2024](#).

ratio capital-trabajo, presionando a la baja la TPMN, también tiende a aumentar la tasa de dependencia de la economía, presionando al alza la TPMN. El efecto final dependerá de las fuerzas relativas de ambos canales.

Por otro lado, aumentos en la preferencia por activos seguros y líquidos tienden a producir caídas en la TPMN, mientras que una mayor oferta de activos libres de riesgo –por ejemplo, ante un mayor endeudamiento público– o una mayor inversión que lleve a menor demanda por estos activos tienden a reducir su precio y subir su rendimiento, lo que tiende a aumentar la TPMN.

En el análisis de la TPMN es importante considerar la integración financiera y comercial a nivel global, que genera dependencia de las tasas domésticas a las del resto del mundo. Ferreira y Shousha (2023) muestran que la tasa de interés neutral de un país puede ser parcialmente explicada por cambios en la productividad y demografía de otras economías. En particular, tasas de crecimiento elevadas en economías emergentes representan oportunidades de inversión para economías avanzadas, lo que redunda en flujos de capitales que reducen las tasas en el primer grupo de países y las aumentan en el segundo. De este modo, las tasa a nivel global tienden a converger, aunque la presencia de preferencias por activos seguros (e.g convenience yields), disponibilidad de activos, u otras fricciones financieras y comerciales pueden producir diferencias.

3. Metodología y resultados

En esta revisión se usan cinco tipos de modelos complementarios: (i) modelos que estiman ciclos y tendencias a partir de series de inflación y tasas de interés cortas y largas, Del Negro et al. (2017); (ii) modelo en base a precios de activos financieros que corrigen por premios por plazo, como se describe en Aldunate et al. (2019); (iii) modelos en forma reducida que relacionan la tasa neutral local con el crecimiento potencial y tendencial del producto y la tasa neutral externa, Carter et al. (2019); (iv) modelo basado en paridad de tasas; y (v) modelo de estado espacio que asume cierta estructura – curva de Philips, curva IS - e identifica la tasa neutral, a partir de la ecuación de Euler, como la suma del crecimiento tendencial y otros determinantes, basado en Holston et al. (2023). Para un tratamiento detallado de las metodologías empleadas en la estimación de la TPMN por parte del Banco Central de Chile ver las minutas anexas en los IPoM de junio 2021, diciembre 2022, y diciembre 2023.

Luego de una revisión y evaluación técnica de los modelos de estimación de TPMN que emplea el Banco Central de Chile, se decidió discontinuar—para esta estimación— dos metodologías: Consumo por hábitos y Reglas de Taylor. La exclusión del primero obedece a que, a partir de la ecuación de Euler, el modelo relaciona la tasa neutral con el crecimiento tendencial de una manera relativamente restrictiva.³ En particular, la inclusión de hábitos responde a que sin ellos esta ecuación arrojaría niveles de tasas libre de riesgo demasiado altas (*equity premium puzzle*). Dadas estas limitaciones, esta metodología ha arrojado valores sistemáticamente por fuera de lo esperable en las últimas actualizaciones.

Los modelos basados en Reglas de Taylor, por su parte, se discontinúan, por un conjunto de razones, que sumadas prescriben cierta cautela. Primero, al estimar la TPMN como la constante de una Regla de Taylor, el modelo asume que la TPMN es constante para toda la muestra, lo que es inconsistente con la idea de que es un concepto dinámico (aunque de baja frecuencia). Vale la pena recordar que una regresión por mínimos

³ Holston, et al. (2023), por ejemplo, modelan la tasa neutral con mayor flexibilidad al asumir un término que permite ajustar su nivel más allá de lo que sugiere el crecimiento tecnológico y las preferencias temporales.

cuadrados ordinarios pondera igual todas las observaciones de la muestra, por lo que no puede capturar cambios estructurales que están ocurriendo contemporáneamente. Segundo, en línea con la crítica de Del Negro et al. (2015) al utilizar promedios para estimar la TPMN, esta metodología puede verse afectada por episodios en los que la TPM se encuentra restringida. Tercero, en línea con Reis (2024), estimar la TPMN a partir de donde está o estuvo puede entrar en conflicto con la idea de que es el punto de llegada de la TPMN. Otras metodologías, como Del Negro et al. (2017) o Holston et al. (2023), buscan determinar la TPMN a partir de identificar hacia donde se está moviendo la tasa.⁴ Cuarto, estimaciones con este método sólo dependen explícitamente de la política monetaria pasada y no de otros fundamentales.

Finalmente, a la vez que se excluyen los modelos anteriores, en esta actualización se incluye el modelo de Holston et al. (2023). La implementación de este modelo, sin embargo, no se basa en la estimación de máxima verosimilitud propuesta por los autores originales, sino en la estimación bayesiana del modelo bajo el supuesto de volatilidad estocástica que proponen Berger y Kampa (2019). Esto se debe a que operacionalmente, y dado el tamaño de la muestra disponible para Chile, esta estrategia de estimación resulta más robusta y estable. En el apéndice se describen los datos utilizados y se presenta gráficamente la dinámica estimada por este método.

La Tabla 1 muestra los resultados de la actualización de las estimaciones de la TPMN usando las metodologías anteriormente descritas.

Tabla 1: Resumen de estimaciones de TPMN real (nivel, porcentaje)

	IPoM Dic.25	IpoM Sep.24	Δ Actualización
Resultados por metodología	25.T3 (1)	24.T2 (2)	(1) – (2)
Tendencia estocástica – BCP10	0,8	1,1	-0,3
Tendencia estocástica – Convenience Yield	0,9	0,9	0,0
Corrección por premios por plazo	1,2	1,1	0,1
Regla de Taylor	-	0,9	-
Regla de Taylor – Expectativa	-	0,6	-
Modelo de Consumo con Hábitos	-	-0,1	-
Modelo de Tendencia Estocástica Común	1,4	1,4	0,0
Paridad de Tasas (DOTS)	1,7	1,6	0,1
Paridad de Tasas (Modelos de EE.UU.)	2,2	2,3	-0,1
Modelo en Forma Reducida (DOTS)	0,9	0,9	0,0
Modelo en Forma Reducida (Modelos de EE.UU.)	1,1	1,2	-0,1
Holston, Laubach y Williams	1,4	-	-
Mediana (*)	1,2	1,1	
Promedio (*)	1,2	1,1	
Rango (*)	[0,9 – 1,7]	[0,6 – 1,6]	

(*) Excluye las estimaciones más bajas y altas en cada IpoM.

Conclusiones

⁴ Ricardo Reis, XXVII Conferencia Anual del Banco Central de Chile, [XXVII Annual Conference of the Central Bank of Chile \(day 1\)](#).



En esta minuta se presentan los resultados obtenidos en la estimación de la tasa de política monetaria neutral para la economía chilena y que se usa como insumo para la actualización de dicho valor de referencia en las proyecciones del IPoM de diciembre de 2025.

Esta actualización extiende la muestra hasta el tercer trimestre de 2025. Asimismo, esta oportunidad, se excluyen dos metodologías anteriormente utilizadas – modelos de Regla de Taylor y de Consumo con Hábitos – y se incorpora el modelo de Holston et al. (2023).

Luego de haber mantenido el nivel de la TPMN en septiembre de 2024 respecto de los estimados para diciembre de 2023, en esta actualización la media y mediana de la TPMN real se revisan al alza, situándose en torno a 1,2%, con un rango aproximado entre 0,9 y 1,7%.

Bibliografía

- Aldunate, Rosario, Francisco Bullano, Mario Canales, Gabriela Contreras, Andrés Fernández, Jorge Fornero, Mariana García, Benjamín García, Jennifer Peña, Matías Tapia y Roberto Zúñiga (2019), "Estimación de Parámetros Estructurales de la Economía Chilena". Minuta citada en el Informe de Política Monetaria de Junio de 2019. Banco Central de Chile.
- Aguirre, Álvaro, Rosario Aldunate, Agustín Arias, Javiera Azócar, Mario Canales, David Coble, Gabriela Contreras, Andrés Fernández, Jorge Fornero, Ignacio Gallardo, Benjamín García, Camila Gómez, Juan Guerra-Salas, Daniel Guzmán, Federico Huneeus, Bernabé López-Martín, Matías Solorza y Manuel Taboada (2021), "Estimación de Parámetros Estructurales de la Economía Chilena". Minuta citada en el Informe de Política Monetaria de Junio de 2021. Banco Central de Chile.
- Arias, Agustín, Guillermo Carlomagno, Valentina Cortés, Nicolás Eterovic, Jorge Fornero, Markus Kirchner, Carlos Molina y Matias Muñoz (2022). "Estimaciones de la Tasa de Interés Real Natural". Minuta citada en el Informe de Política Monetaria de diciembre 2022. Banco Central de Chile.
- Berger Tino y Bernd Kampa (2019). "Testing for Time Variation in the Natural Rate of Interest," *Journal of Applied Econometrics*, 34(5): 836-842.
- Carter, Thomas J., Xin Scott y José Dorich (2019). "The Neutral Rate in Canada: 2019 Update," Staff Analytical Note, 2019-11, Bank of Canada.
- Del Negro, Marco, Marc P. Giannoni, Matthew Cocci, Sara Shahanaghi y Micah Smith (2015). "Why Are Interest Rates So Low?," *Liberty Street Economics*, 20 de Mayo.
- Del Negro, Marco, Domenico Giannone, Marc P. Giannoni y Andrea Tambalotti (2017). "Safety, Liquidity, and the Natural Rate of Interest," *Brookings Papers on Economic Activity, Economic Studies Program*, The Brookings Institution, 48(1): 235-316.
- Ferreira, Thiago y Samer Shousha (2023), "Determinants of global neutral interest rates," *Journal of International Economics*, Vol. 145, <https://doi.org/10.1016/j.jinteco.2023.103833>.
- Holston, Kathryn, Thomas Laubach y John C. Williams (2023). "Measuring the Natural Rate of Interest after COVID-19," *Federal Reserve Bank of New York Staff Report* no. 1063.
- Reis, Ricardo (2022). "Which r-star, Government Bonds or Private Investment? Measurement and Policy Implications," LSE manuscript.
- Wicksell, K (1898), "Geldzins und Güterpreise. Eine Untersuchung über die den Tauschwert des Geldes bestimmenden Ursachen (English translation: Interest and prices: a study of the causes regulating the value of money)", Macmillan, 1936.

Anexo


A continuación, se describen las series de tiempo utilizadas como observables para la estimación del modelo de Holston et al. (2023), siguiendo la especificación de Berger y Kampa (2019).

Las series utilizadas provienen de la Base de Datos Estadísticos del Banco Central de Chile. Para la actividad económica se emplea el PIB trimestral en volumen encadenado con referencia 2018, disponible desde 1996Q1

hasta 2025Q3, el cual se empalma hacia atrás con la serie de PIB trimestral a precios constantes base 1986 desde 1986Q1 hasta 2001Q3. La inflación se construye a partir del IPC sin volátiles en base 2023 = 100 desde 1998Q4 hasta 2025Q3, complementado con la serie IPC X1 en base diciembre 1998 = 100 desde 1985Q1 hasta 2008Q4, también empalmadas. Las expectativas de inflación, para construir la tasa de interés real, provienen de la Encuesta de Expectativas Económicas (EEE) para 11 meses desde 2001Q1 hasta 2025Q3, y se completan con un promedio móvil de cuatro trimestres de la inflación observada entre 1986Q1 y 2000Q4 siguiendo a Holston et al. (2023). Para la tasa de política monetaria (TPM) se utiliza la serie oficial desde 2002Q1 hasta 2025Q3, mientras que para el período anterior se emplean tasas de depósito en pesos a 90 días-1 año desde 1986Q1 hasta 2001Q4.

El Gráfico 1, muestra la dinámica estimada para la tasa natural estimada con la especificación de Berger y Kampa para la muestra construida como se describe en el párrafo anterior.

Gráfico 1
Tasa de política monetaria neutral, (nivel, porcentaje)



Nota: elaboración propia.