

---

## PRESENTACIÓN

El presente volumen de la Revista de Análisis contiene tres artículos de actualidad económica, dos de los cuales se presentaron en el Decimotercer Encuentro de Economistas de Bolivia (13EEB). El primero de ellos, titulado “Crisis política y sanitaria: Respuesta de la política monetaria en tiempos de incertidumbre”, corresponde a los autores Mauricio Mora, Juan Carlos Heredia y Paul Estrada y fue merecedor de una mención honorífica en la categoría tema central en el 13EEB. El mismo está referido a la cuantificación de los efectos de la incertidumbre que ha suscitado la pandemia de Covid-19 en la economía mediante un modelo SVAR estimado con técnicas bayesianas. Los resultados reflejan que periodos de alta incertidumbre tienen un impacto negativo y significativo sobre la actividad económica, los cuales se transmiten, principalmente, por una caída del consumo y de la inversión. Ante esta situación se debe responder con una política monetaria expansiva, inyectando recursos a la economía, pero la misma tiene sus limitaciones.

El artículo “Dinámica e impacto del Covid-19 en la economía boliviana”, de Christian Mauricio Huanto, también fue merecedor de una mención honorífica en la categoría central del 13EEB. Este artículo analiza cuál ha sido la dinámica del Covid-19 y cómo es que la misma ha impactado en la economía boliviana. Para ello, el autor hace una revisión de los modelos de salud pública acerca de contagios en pandemias, selecciona uno de ellos para luego conectarlo a un modelo de equilibrio general. Encuentra que la pandemia ha suscitado efectos negativos en la economía, medidos a través de los impactos en el consumo y en la productividad. Esto, a su vez, habría incidido en la oferta y demanda agregadas, y habría existido un severo *trade-off* entre el crecimiento económico y la reducción de la letalidad de la población.

El tercer artículo, correspondiente al autor Jonnathan Cáceres, se titula “Modelos de *Machine Learning* para el análisis y pronóstico de la situación financiera de bancos – Caso boliviano”. En este escrito, el autor analiza y pronostica el comportamiento financiero de los principales bancos de Bolivia para el periodo comprendido entre enero de 2001 y febrero de 2020, para lo cual utilizó modelos de *machine learning*: redes neuronales supervisadas,

redes neuronales no supervisadas y máquinas de vectores de soporte. Este análisis permite identificar el comportamiento de dichas entidades financieras en un entorno de permanente cambio e innovación, lo que implica mayor complejidad financiera y, con ello, mayores riesgos.

Estos artículos llevan a tener una perspectiva académica de los problemas y asuntos económicos de actualidad. Esperamos que su lectura permita contribuir en la discusión de los mismos a mayor profundidad.

**Sergio Cerezo Aguirre**  
**Asesor Principal de Política Económica**

# **Crisis política y sanitaria: Respuesta de la política monetaria en tiempos de incertidumbre**

**Mauricio Mora Barrenechea**

**Juan Carlos Heredia Gómez**

**Paul Estrada Céspedes**

## **Resumen**

Periodos de alta incertidumbre tienen consecuencias considerables sobre la actividad económica, por lo que los hacedores de política monetaria deben tener en cuenta el grado de incertidumbre en el cual se desenvuelve la economía. En el caso particular de Bolivia, la pandemia global del COVID-19, junto a un periodo de transición política, generó un inusitado incremento en la incertidumbre y, actualmente, es una de las principales fuentes de los efectos adversos en la economía. Utilizando un modelo SVAR, estimado con técnicas bayesianas, se cuantificaron los efectos de la incertidumbre sobre la economía. Los resultados obtenidos reflejan que periodos de alta incertidumbre tienen un impacto negativo y significativo sobre la actividad económica, el cual se transmite, principalmente, por una caída del consumo y de la inversión. El Banco Central de Bolivia responde con una política monetaria expansiva, inyectando recursos a la economía, pero esta tiene sus limitaciones.

**Clasificación JEL:** *C32, E20, E32, E51, E52, E58*

**Palabras clave:** *Incertidumbre, inestabilidad, COVID-19, política monetaria, SVAR bayesiano*

# Crisis política y sanitaria: Respuesta de la política monetaria en tiempos de incertidumbre\*

Mauricio Mora Barrenechea\*\*

Juan Carlos Heredia Gómez\*\*\*

Paul Estrada Céspedes\*\*\*\*

## RESUMEN

Periodos de alta incertidumbre tienen consecuencias considerables sobre la actividad económica, por lo que los hacedores de política monetaria deben tener en cuenta el grado de incertidumbre en el cual se desenvuelve la economía. En el caso particular de Bolivia, la pandemia global del COVID-19, junto a un periodo de transición política, generó un inusitado incremento en la incertidumbre y, actualmente, es una de las principales fuentes de los efectos adversos en la economía. Utilizando un modelo SVAR, estimado con técnicas bayesianas, se cuantificaron los efectos de la incertidumbre sobre la economía. Los resultados obtenidos reflejan que periodos de alta incertidumbre tienen un impacto negativo y significativo sobre la actividad económica, el cual se transmite, principalmente, por una caída del consumo y de la inversión. El Banco Central de Bolivia responde con una política monetaria expansiva, inyectando recursos a la economía, pero esta tiene sus limitaciones.

**Clasificación JEL:** C32, E20, E32, E51, E52, E58

**Palabras clave:** Incertidumbre, inestabilidad, COVID-19, política monetaria, SVAR bayesiano

---

\* Las conclusiones, opiniones y puntos de vista expresados en este documento no representan necesariamente aquellos del Banco Central de Bolivia ni de sus autoridades y son de exclusiva responsabilidad de los autores.

\*\* Contacto: mmora@bcb.gob.bo; lmaurimorab@gmail.com

\*\*\* Contacto: jheredia@bcb.gob.bo

\*\*\*\* Contacto: pestrada@bcb.gob.bo

# Political and Health Crisis: Monetary Policy Response in Times of Uncertainty\*

Mauricio Mora Barrenechea\*\*  
Juan Carlos Heredia Gómez\*\*\*  
Paul Estrada Céspedes\*\*\*\*

## ABSTRACT

Periods of high uncertainty have considerable consequences on economic activity, therefore, monetary policy makers must take into account the degree of uncertainty in which the economy operates. In the particular case of Bolivia, the global COVID-19 pandemic, coupled with a period of political transition, generated an unusual increase in uncertainty and is currently one of the main sources of adverse effects on the economy. Using a SVAR model, estimated with Bayesian techniques, effects of uncertainty on the economy were quantified. The obtained results reflect that periods of high uncertainty have a negative and significant impact on economic activity, which is mainly transmitted by a drop in consumption and investment. The Central Bank of Bolivia responds with an expansive monetary policy, injecting resources into the economy, but this has its limitations.

**JEL Classification:** C32, E20, E32, E51, E52, E58

**Keywords:** *Uncertainty, instability, COVID-19, monetary policy, Bayesian SVAR*

---

\* The conclusions, opinions and points of view expressed in this document do not necessarily represent those of the Central Bank of Bolivia or its authorities and are the sole responsibility of the authors.

\*\* Contact: mmora@bcb.gob.bo; lmaurimorab@gmail.com

\*\*\* Contact: jheredia@bcb.gob.bo

\*\*\*\* Contact: pestrada@bcb.gob.bo

## I. Introducción

*“La incertidumbre no es solo una característica importante del panorama de la política monetaria; es la característica definitoria. Como consecuencia, la conducción de la política monetaria [...], en su esencia, involucra elementos cruciales de la gestión del riesgo, un proceso que requiere una comprensión de las muchas fuentes de riesgo e incertidumbre que enfrentan los responsables de la formulación de políticas y la cuantificación de esos riesgos cuando sea posible. También implica diseñar, a la luz de esos riesgos, una estrategia de política dirigida a maximizar las probabilidades de lograr, en el tiempo, nuestro objetivo de estabilidad de precios y el máximo crecimiento económico sostenible que le asociamos”. [Traducción libre de Greenspan, 2003].*

*“Puede pensarse que las fuentes de incertidumbre serán aún mayores para países en desarrollo, usualmente más vulnerables a los vaivenes de la economía internacional, y más aún para economías en transición [...] donde no se conocen con precisión las relaciones entre las variables macroeconómicas fundamentales en general, y los canales de transmisión de la política monetaria en particular.” (Nota del editor, Hernán Lacunza, en Basco et al., 2007).*

Los mensajes de Alan Greenspan y Hernán Lacunza denotan la importancia, para los hacedores de política monetaria, de tener en cuenta el grado de incertidumbre en el cual se desenvuelve la economía, más aún si se considera que *“las fuentes de incertidumbre que afectan la toma de decisiones de política monetaria son muy variadas y se presentan en numerosos planos”* (Basco et al., 2007, p. 21).

Aun cuando no se ha alcanzado un consenso sobre la definición del concepto de incertidumbre, la literatura relacionada ha encontrado diferentes maneras de cuantificar los efectos de la misma en la actividad real. En ese sentido, a lo largo del tiempo, surgieron diferentes indicadores que, en algunos casos, son conceptualmente diferentes, tanto en metodología como en la fuente de información que emplean (Deutsche Bundesbank–DB, 2018). Los estudios realizados con estas metodologías demostraron que sí existen efectos adversos tanto sobre las variables micro como macroeconómicas.

Diferentes acontecimientos y factores han incentivado la aparición de un mayor número de estudios: la globalización, las crisis económicas y financieras, la volatilidad en los precios de las materias primas, las tensiones en el comercio internacional, eventos con repercusiones mundiales (como el *Brexit*), entre otros. Recientemente, la pandemia global del COVID-19 (*COronaVirus Disease*, 19 según su nomenclatura) impulsó el surgimiento de estudios con el propósito de comprender sus efectos sobre la actividad económica mundial. Un grupo de estas investigaciones se enfocó en los efectos de este fenómeno

a través del canal de la incertidumbre, encontrando resultados desfavorables para la actividad económica (Baker et al., 2020; Leduc y Liu, 2020; y Pinshi, 2020).

En el presente documento, se emplea un modelo de Vectores Autorregresivos Estructurales (SVAR), estimado con técnicas bayesianas, para cuantificar los efectos macroeconómicos de la incertidumbre en el caso de Bolivia. Para aproximar el nivel de incertidumbre, se utilizó el índice WUI\_BOL que se obtuvo de la página web del Índice de Incertidumbre Mundial (*World Uncertainty Index – WUI*). Este índice muestra que los periodos en los que se registró una alta incertidumbre se caracterizaron principalmente por inestabilidad política y social y, en menor medida, desaceleración económica. La aparición del COVID-19, junto con un periodo de transición política, generó un inusitado incremento en la incertidumbre. Los resultados obtenidos reflejan que periodos de alta incertidumbre tienen un impacto negativo significativo sobre la actividad económica, lo cual se transmite principalmente a través de una caída del consumo y de la inversión. El Banco Central de Bolivia (BCB) responde con una política monetaria expansiva, inyectando recursos a la economía, pero esta tiene sus limitaciones.

En la siguiente sección, se presenta una breve revisión bibliográfica, destacando las principales consecuencias de la incertidumbre encontradas en los estudios. Posteriormente, se describe cuáles fueron las principales características de los periodos con alta incertidumbre. Asimismo, se describe, brevemente, cómo respondió el BCB en los últimos años. En la cuarta sección, se explican los principales rasgos de la metodología que se empleó. En la quinta sección, se muestran los resultados obtenidos y se explican las limitaciones de la política monetaria. Al final se presentan las conclusiones.

## II. Revisión bibliográfica

Los primeros análisis sobre los efectos de la incertidumbre pueden rastrearse desde inicios del siglo XX. Por ejemplo, se pueden mencionar los trabajos de Veblen [2005 (1904)] y Schumpeter [1934 (1912)]. Sin embargo, en los años ochenta comenzaron a expandirse los estudios sobre los efectos de la incertidumbre en la economía con el surgimiento de trabajos como el de Bernanke (1983). En los tiempos modernos, la globalización, las crisis económicas y financieras mundiales, la volatilidad de los precios de las materias primas, las tensiones en el comercio internacional, eventos con repercusiones mundiales (como el *Brexit*) y el reciente impacto de la pandemia del COVID-19, han colocado, en el centro de la atención de los hacedores de política, la incógnita sobre las consecuencias de periodos de alta incertidumbre en el contexto macroeconómico.

## II.1. Los canales de transmisión de la incertidumbre

La literatura referida llegó a la conclusión de que la incertidumbre es un fenómeno que, dada su magnitud, merece una mayor atención por parte de los tomadores de decisiones en la formulación de la política monetaria y en la gestión de crisis (Greespan, 2003; Basco et al., 2007; Bloom, 2009; Aastveit et al., 2013; Pinshi, 2020, entre otros). Según Pinshi (2020), en base al trabajo de Drumetz et al. (2015), existen tres factores clave que los bancos centrales deben tomar en cuenta: i) la incertidumbre sobre el estado de la economía, ii) la incertidumbre relacionada con la estructura de la economía y, iii) la más importante, la incertidumbre estratégica.

La evaluación del impacto macroeconómico de la incertidumbre depende de la captura adecuada de este fenómeno (DB, 2018). Si bien han existido avances teóricos hacia una definición del concepto de incertidumbre, todavía no se ha alcanzado un consenso, lo cual ha dado por resultado el surgimiento de diferentes medidas que, en algunos casos, son conceptualmente diferentes, tanto en metodología como en la fuente de información que emplean<sup>1</sup>. Los indicadores de incertidumbre generalmente empleados son una combinación de incertidumbre, riesgo y, en ciertos casos, sorpresa (DB, 2018).

Dada la naturaleza de la incertidumbre, en principio, existiría un extenso número de canales de transmisión por los cuales la incertidumbre puede llegar a afectar negativamente a la producción (Bloom, 2013). Uno de los canales más estudiados por estos estudios es el de la inversión, encontrando resultados disímiles. Como indica Caballero (1991), el signo de la relación entre la incertidumbre y las variables que reflejan la inversión no es evidente *a priori*. Puede ser negativo, acorde con numerosos estudios (Rodrik, 1991; Bloom, 2009; Bloom, 2013; Kang et al., 2014; Glover y Levine, 2015; Baker et al., 2015; o Gulen e Ion, 2016), positivo en el caso de la inversión general (la incertidumbre puede tener un efecto positivo si las empresas consideran que sí vale la pena poder adaptarse a diferentes condiciones políticas y económicas en el futuro) o incluso, ni negativo ni positivo, si la incertidumbre abre una brecha entre la entrada y salida de inversiones.

Varios documentos encontraron que la incertidumbre también tiene efectos adversos sobre el empleo y el consumo. En el primer caso, los empleadores pueden optar por esperar y ver, antes de contratar trabajadores, lo que contribuye a un mayor desempleo (Bloom, 2009; Baker et al., 2015; Caggiano et al., 2017; o Leduc y Liu, 2020). En el segundo caso, periodos de alta incertidumbre provocan recortes de gastos y un aumento del ahorro por

---

1 Para mayor información sobre los diferentes tipos de indicadores de incertidumbre que se desarrollaron se recomienda ver el artículo de DB (2018).



parte de los hogares, por razones de precaución (Bernanke, 1983), lo cual provoca una disminución del consumo (Romer, 1990; y Basu y Bundick, 2017), especialmente, de bienes duraderos (Eberly, 1994; Bertola et al. 2005; y Belke y Kronen, 2017). El cúmulo de estos efectos provoca una caída en el producto.

En el caso de la inflación, si bien algunos documentos encuentran que esta disminuye dando indicios de la presencia de un co-movimiento entre el producto y el nivel de precios (Leduc y Liu, 2016), otros estudios señalan que la inflación aumenta debido a que las empresas podrían aumentar sus precios en respuesta a choques de incertidumbre adversos (Born y Pfeifer, 2014). Por su parte, diferentes investigaciones señalan que no existe un efecto significativo (DB, 2018).

Otras consecuencias encontradas por las investigaciones fueron: efectos adversos sobre los créditos del sistema financiero (Bordo et al., 2016), mayor costo del financiamiento externo por alza de la prima por riesgo (Gilchrist et al., 2014), retroalimentación, pues la desaceleración de la actividad económica conduce a una mayor incertidumbre (Fajgelbaum et al., 2014) y dificultades para pronosticar las variables económicas (Orlik y Veldkamp, 2014).

## ***II.2. El canal de la incertidumbre del COVID-19***

La pandemia COVID-19 impulsó el surgimiento de varios estudios con el propósito de comprender sus efectos sobre la actividad económica mundial. Un grupo de estas investigaciones se centró en los efectos de este fenómeno a través del canal de la incertidumbre.

Se puede mencionar el trabajo de Baker et al. (2020), quienes señalan que la crisis generada por la pandemia del coronavirus representa un desafío para los hacedores de política debido a la rapidez con la que se ha desarrollado. A partir del uso de diferentes indicadores que brindan medidas de incertidumbre en tiempo real, encontraron que el sustancial aumento de la incertidumbre económica tendrá un rol importante en la contracción del Producto Interno Bruto (PIB) real de Estados Unidos.

Leduc y Liu (2020), también con datos para Estados Unidos, señalan que, además de la trágica pérdida de vidas humanas, la pandemia del COVID-19 afectará drásticamente a la actividad económica, a medida que las políticas de distanciamiento social y las cuarentenas obliguen a las personas a quedarse en casa y se reduzcan las actividades comerciales y minoristas no esenciales. El impacto negativo en la economía puede amplificarse y prolongarse aún más por la creciente incertidumbre. Sus resultados indican que existirá un periodo prolongado de desempleo y una disminución significativa de la tasa de inflación.

Pinshi (2020), con datos para el Congo, utilizando un modelo VAR bayesiano, encuentra que los efectos de la incertidumbre generada por el COVID-19 son significativos y afectan la demanda agregada, los precios, el tipo de cambio, el grado de apertura, y ponen en disyuntiva a los hacedores de política monetaria (incentivar a la economía o frenar la inflación). Concluye que la incertidumbre reduce la capacidad del banco central para influir en la economía y controlar la inflación.

### ***II.3. Efectos de la incertidumbre en Bolivia***

En el caso de Bolivia, los estudios sobre los efectos de la incertidumbre en el comportamiento de la economía no son muy extensos. Un gran número de ellos indica que, durante el proceso hiperinflacionario de los años ochenta, existió una elevada incertidumbre que tuvo un impacto adverso sobre la actividad económica, pero no analizan específicamente los efectos de la incertidumbre de la economía nacional.

Varela (2010) analizó los efectos de la incertidumbre en las economías de América del Sur, incluida Bolivia. Se enfocó en el canal de incertidumbre-producto que opera a través de la estrategia financiera de la empresa. Encuentra que mayor incertidumbre aumenta la probabilidad de quiebra de las empresas, elevando los costos marginales esperados de la quiebra y reduciendo la producción óptima de una empresa neutral al riesgo.

Por otra parte, Banegas et al. (2019), a partir de un modelo SVAR con datos para el período entre 2000T1 y 2018T2, analizan los efectos de la incertidumbre internacional económica y financiera. Utilizando el Índice Global de Incertidumbre en la Política Económica (GEPU por sus siglas en inglés) y dos medidas alternativas de volatilidad financiera internacional, encontraron que existen efectos negativos y significativos sobre el crecimiento del PIB real, el resultado fiscal y la cuenta corriente. Consideraron que el canal de propagación eran los términos de intercambio.

### **III. Hechos estilizados**

La cuantificación de los efectos macroeconómicos de la incertidumbre ha sido ampliamente estudiada gracias al uso de diversos indicadores que capturan este factor. Diversos estudios emplean más de un indicador de incertidumbre para poder complementar y corroborar los resultados obtenidos.

En el caso de Bolivia, para aproximar los efectos de la incertidumbre, se utilizó el Índice de Incertidumbre Mundial (*World Uncertainty Index – WUI*)

desarrollado por Ahir et al. (2018)<sup>2</sup>. Por la metodología que se emplea, este indicador correspondería a las medidas basadas en periódicos (*Newspaper-Based Measures*), salvo que en vez de utilizar la información de los periódicos usan la información de reportes económicos (Baker et al., 2020). Este índice trimestral ya ha sido utilizado previamente en investigaciones (Ahir et al. 2018, o Pinshi, 2020) y cuenta con un índice de incertidumbre específico para Bolivia (WUI\_BOL).


### ***III.1. Indicador de incertidumbre WUI\_BOL***

Durante los años noventa, el WUI\_BOL no reflejó niveles elevados de incertidumbre a pesar de que, a finales de los años 1990 y principios de los años 2000, la economía boliviana advirtió una importante desaceleración. Desde el año 2002, se aprecia un aumento de la incertidumbre, alcanzando un punto máximo a inicios del año 2006. A partir de entonces, la incertidumbre reflejó una disminución con algunos repuntes temporales, especialmente a mediados de 2013. Nuevamente se observa un repunte de la incertidumbre desde inicios de 2018, alcanzando niveles históricamente elevados a finales de 2019 y en lo que va de 2020 (Gráfico 1).

---

2 Construyen índices trimestrales de incertidumbre económica para 143 países, utilizando recuentos de frecuencia de la palabra “incertidumbre” y sus variantes, en los informes trimestrales por país, de la Unidad de Inteligencia de la Economía (*Economist Intelligence Unit – EIU*) de la revista *The Economist*. Los informes de la EIU discuten los principales acontecimientos políticos y económicos de cada país, junto con análisis y previsiones de las condiciones políticas y económicas. Son creados por equipos de analistas específicos de cada país y un equipo editorial central de EIU. Para que la WUI sea comparable entre países, los recuentos brutos se escalan por el número total de palabras en cada informe. Este indicador refleja un comportamiento similar a otros índices de incertidumbre. Para mayor información se puede visitar su página web: [https://www.policyuncertainty.com/wui\\_quarterly.html](https://www.policyuncertainty.com/wui_quarterly.html).

**Gráfico 1: WORLD UNCERTAINTY INDEX PARA BOLIVIA**



Fuente: Ahir et al. (2018)

Nota: WUI\_BOL: El índice se calcula contando la frecuencia de la incertidumbre mundial (o su variante) en los informes de países de la EIU. El índice se normaliza por el número total de palabras y se reescala multiplicándolo por 1.000.

Promedio móvil WUI\_BOL: Este índice representa la media móvil ponderada de tres trimestres del WUI\_BOL. El promedio móvil ponderado de tres trimestres se calcula de la siguiente manera:  $1996Q4 = (1996Q4 * 0.6) + (1996Q3 * 0.3) + (1996Q2 * 0.1) / 3$ . Así se obtiene una versión suavizada del índice.

Los años donde se registran elevados niveles de incertidumbre coinciden con periodos caracterizados principalmente por inestabilidad política, conflictos sociales y, en menor medida, por desaceleración económica. Recientemente, también tuvo un efecto importante la pandemia del COVID-19. A continuación se describen los principales sucesos en estos periodos:

<b>2002-2006: Inestabilidad política y social</b>	
<b>2002</b>	Elecciones presidenciales, consagrando presidente a Gonzalo Sánchez de Lozada y vicepresidente a Carlos Mesa.
	Disputas y rechazo sobre la capitalización de los recursos naturales.
	Una débil economía local afectada por la desaceleración económica mundial. Elevada tasa de desocupación.
<b>2003</b>	Febrero Negro: Un proyecto de ley que establecía el congelamiento de salarios y un incremento de impuestos generó malestar dentro la población y un motín policial. Un ataque con piedras al Palacio de Gobierno terminó en un enfrentamiento entre la policía y las Fuerzas Armadas. El vandalismo se apoderó de las ciudades, varios edificios fueron incendiados, mientras que los comercios fueron saqueados.
	Guerra del Gas: El rechazo a la exportación de gas natural a EEUU y México a través de puertos chilenos derivó en uno de los mayores conflictos sociales del país en octubre. Los conflictos y bloqueos de caminos en señal de protesta fueron intervenidos con exceso de fuerza por operativos militares provocando la muerte de varios civiles. Bloqueos, huelgas de hambre, la sede de Gobierno bloqueada y desabastecida de alimentos y combustibles, y saqueos, provocaron que el Gobierno pierda el control de la situación. Gonzalo Sánchez de Lozada renunció a la Presidencia y salió del país.
	Inicia el gobierno de Carlos Mesa, en un ambiente tenso y lleno de incertidumbre y la fractura de la relación Estado-sociedad.
<b>2004</b>	Si bien en los primeros meses la situación social estuvo casi en calma, muy pronto las demandas de varios sectores terminaron en conflictos sociales y episodios de violencia.
	Las discrepancias entre la Presidencia y el Tribunal Constitucional dificultaron la gobernabilidad en el país.
<b>2005</b>	La falta de apoyo, las disputas internas, la presión de sectores radicales de izquierda y derecha por la nacionalización de los hidrocarburos y las autonomías, el bloqueo nacional de caminos y los conflictos entre la Policía y campesinos y mineros cerca la ciudad de Sucre, provocaron la renuncia de Carlos Mesa. Eduardo Rodríguez asumió la presidencia en junio.
	Por presión de EE.UU., las Fuerzas Armadas entregaron una treintena de misiles de fabricación china que poseían desde los años noventa para su desmantelamiento total. La noticia se filtró y generó una presión de medios y opinión pública que obligó a la devolución de los misiles ya desactivados. Esta decisión derivó en acusaciones contra el Presidente, el Ministro de Defensa y miembros del mando militar.
	Elecciones presidenciales: Ganó el binomio Evo Morales y Álvaro García Linares.
<b>2006</b>	El 1º de mayo el Gobierno dictó el decreto de nacionalización de los hidrocarburos.
	El 2 de julio se realizó un referéndum nacional sobre autonomías departamentales como parte del proceso de descentralización política del Estado y como respuesta institucional a una aguda crisis política e intensa conflictividad social.
<b>2018-2019: Elecciones cuestionadas, un contexto económico adverso y crisis política y social</b>	
<b>2018</b>	El 28 de noviembre de 2017, el Tribunal Constitucional Plurinacional (TCP) habilitó a Morales para ser candidato de forma indefinida a pesar de que el 21 de febrero de 2016, el 51.3% del electorado rechazó la reforma parcial del artículo 168 de la CPE, que establece los límites de la reelección.
	El 4 de diciembre, el Tribunal Supremo Electoral (TSE) autorizó al binomio del MAS para poder participar en los comicios del 20 de octubre de 2019.
<b>2019</b>	El 20 de octubre se llevó adelante la primera ronda de votación para la elección presidencial, sin embargo, el conteo de votos se detuvo repentinamente. Ante las sospechas demoras en la difusión del escrutinio provisorio, diferentes grupos comenzaron a denunciar un posible fraude electoral.
	El 21 de octubre, el Órgano Electoral Plurinacional informó que, con solo 95,3% de los votos verificados, Evo Morales tenía un margen muy por encima de los diez puntos para revertirse, lo que evitaba una segunda vuelta, y entonces Morales permanecería en el poder por un cuarto mandato. El anuncio desató protestas en diferentes ciudades del país.
	Diferentes grupos sociales se unieron a las protestas en contra de los resultados de los comicios. Entre el 8 y 9 de noviembre la policía se amotinó en varias ciudades.
	El 10 de noviembre, la Organización de los Estados Americanos (OEA) presentó un informe preliminar de su auditoría, revelando que existieron vulnerabilidades en el sistema que podrían haber manipulado los resultados. El comandante en jefe de las Fuerzas Armadas sugirió "al presidente del Estado que renuncie a su mandato presidencial, permitiendo la pacificación y el mantenimiento de la estabilidad". Evo Morales renunció a su cargo.
	Se iniciaron protestas en las ciudades de El Alto, La Paz y Cochabamba, provocando daños a la propiedad privada y pública, se formaron bloqueos de camino, desabastecimiento de alimentos y combustibles a las ciudades.
	Se instauró un gobierno de transición con Jeanine Áñez Chávez como Presidente Constitucional de Bolivia.
	Los conflictos sociales y políticos dejaron secuelas adversas en la actividad económica.
<b>2020: La pandemia del COVID llega en el peor momento</b>	
<b>2020</b>	En febrero, varios sectores empezaron a sentir los primeros efectos del COVID-19: la industria cárnica (envíos postpuestos), las automotrices (repuestos y accesorios limitados), la construcción (falta de insumos, atraso de entregas de obras), las importadoras de insumos agrícolas (escasez de insecticidas, herbicidas y fungicidas), el turismo (viajes cancelados, poca afluencia de turistas) y el transporte pesado (menor mercadería procedente de China).
	El 10 de marzo se registraron los primeros casos de coronavirus en Bolivia y se aplicaron diferentes medidas para evitar un contagio masivo. El 21 de marzo se decretó la cuarentena total en todo el territorio nacional. Las fechas de las elecciones fueron postpuestas por la emergencia sanitaria.
	A finales de abril, las limitaciones del sistema de salud comenzaron a ser más evidentes ante el avance de los contagios por COVID-19, diferentes centros empezaron a colapsar, observándose escasez de insumos y personal.
	Desde mayo en diferentes partes del país se produjeron marchas y bloqueos por grupos que exigían las elecciones y levantar la cuarentena en Bolivia. Estos provocaron desabastecimiento de alimentos, artículos de primera necesidad e insumos médicos en las ciudades, principalmente del Occidente.
	La economía nacional, al igual que la economía mundial, sufrió un <i>shock</i> adverso sin precedentes. Tanto la oferta como la demanda fueron afectadas.

Fuente: <https://www.educa.com.bo/content/historia-de-bolivia>, periódicos nacionales y otros.

### ***III.2. La respuesta del Banco Central de Bolivia***


En respuesta a las diversas crisis que afectaron el desempeño económico mundial, los balances de muchos bancos centrales han reflejado un crecimiento sustancial (Caruana, 2012) que se explica por los efectos de la política monetaria en las condiciones financieras y macroeconómicas, con el objetivo de aumentar el grado de acomodación monetaria y apoyar la demanda agregada. Además de aumentar el tamaño de sus balances, también cambió su composición toda vez que los bancos centrales tuvieron que idear nuevos mecanismos con el propósito de poder inyectar grandes cantidades de liquidez a sus economías (flexibilización monetaria), lo que implicó un aumento importante de la base monetaria.

El BCB no fue la excepción puesto que la base monetaria<sup>3</sup> ha presentado un crecimiento importante desde 2005 (Gráfico 2). El mayor repunte se observó entre 2005 y 2008, un periodo en el cual la apreciación de la moneda nacional incentivó a los agentes económicos a vender sus dólares ante la pérdida de su valor respecto a la moneda local. Esto implicó un mayor uso de la moneda nacional, tanto para transacciones como para ahorrar, generando un mayor espacio de acción para la política monetaria. Desde entonces, la base monetaria ha mantenido su tendencia creciente, especialmente entre los años 2009–2010, 2014–2015 y 2020, en los cuales la política monetaria adoptó una posición expansiva con el fin de estimular la demanda interna.

---

3 La base monetaria comprende los pasivos del BCB que sustentan la expansión del dinero en sentido amplio, y del crédito. Se la denomina dinero de alto poder porque sus variaciones generalmente dan lugar a incrementos más grandes del dinero y del crédito por un efecto multiplicador. La base monetaria es una medida del dinero primario, que constituye la base de los agregados monetarios, puesto que incluye los billetes y monedas emitidos por el Banco Central. También incluye otros componentes que no forman parte de los agregados monetarios, como son los depósitos de las entidades de intermediación financiera en el Banco Central (reservas bancarias) y sus tenencias de moneda nacional.

**Gráfico 2: BASE MONETARIA**  
(En millones de bolivianos)



Fuente: Banco Central de Bolivia

Nota: La serie fue desestacionalizada utilizando el procedimiento *Census X12* con el programa Eviews.

En 2020, los efectos sin precedentes de la pandemia global del COVID-19 han representado un importante reto para los bancos centrales de diferentes países, los cuales se ven en la necesidad de apoyar a sectores económicos que están atravesando por una situación difícil. El BCB ha implementado diferentes medidas con el propósito de inyectar recursos a la economía<sup>4</sup>. Como resultado, la base monetaria creció, en términos interanuales, en 12% en junio. Asimismo, como consecuencia, los agregados monetarios también evidenciaron un aumento relevante.

#### IV. Metodología

Para cuantificar los efectos de la incertidumbre sobre la actividad económica se utilizó un Modelo SVAR estimado con técnicas bayesianas. A lo largo del tiempo, esta metodología se ha constituido en uno de los principales instrumentos para poder comprender con mayor precisión los impactos de la incertidumbre (Bloom, 2009; Belke y Kronen, 2017; Caldara et al., 2016; DB, 2018; o Pinshi, 2020). Estos modelos de ecuaciones múltiples permiten capturar las relaciones dinámicas entre un gran número de variables macroeconómicas clave. Los valores residuales de las diversas ecuaciones individuales se utilizan luego para identificar los determinantes del modelo (*shocks* estructurales).

4 Para información detallada ver el Informe de Política Monetaria, julio 2020 (BCB, 2020b).

### IV.1. Modelo SVAR

El modelo SVAR se representa de la siguiente manera.

$$Ay_t = A_1^* y_{t-1} + \dots + A_p^* y_{t-p} + B\mu_t \quad (1)$$

Un vector ( $k \times 1$ ) de variables endógenas representado por  $y_t$  está asociado a una matriz ( $k \times k$ ) de coeficientes estructurales  $A_p^*$  y a un vector de residuos  $\mu_t$  ruido blanco. Premultiplicando la ecuación por la matriz inversa de  $A$ , se obtiene la expresión (2):

$$A^{-1}Ay_t = A^{-1}[A_1^* y_{t-1} + \dots + A_p^* y_{t-p} + B\mu_t] \quad (1')$$

$$A^{-1}Ay_t = A^{-1}A_1^* y_{t-1} + \dots + A^{-1}A_p^* y_{t-p} + A^{-1}B\mu_t \quad (1'')$$

$$y_t = A_1 y_{t-1} + \dots + A_p y_{t-p} + e_t \quad (2)$$

donde:

$$e_t = C\mu_t \quad (3)$$

Las restricciones del modelo se incorporan en la matriz  $C$  de la ecuación (3), las cuales permiten realizar la identificación de los *shocks* estructurales que afectan a cada una de las variables del SVAR. Para tal efecto, se incorporaron restricciones de largo plazo utilizando una matriz de forma recursiva. La identificación del modelo normalmente se logra mediante una descomposición de Cholesky de los residuos.

De acuerdo a Lütkepohl (2017), los modelos del tipo SVAR recursivo son identificados por restricciones a corto plazo sobre los efectos de impacto de los choques estructurales. Equivalen a restringir  $A$  o  $B$  en la ecuación (1) para que sean triangulares superiores o inferiores. Si el SVAR se configura como modelo  $A$  o  $B$ , se puede construir una estimación de  $B$  a partir de la inversa de la estimación de  $A$  y viceversa. En un modelo recursivo también se puede realizar una identificación parcial donde, por ejemplo, solo se identifica una relación económica o solo un choque estructural es de interés (Lütkepohl, 2017, p. 424).

### IV.2. Estimación bayesiana

Un aspecto importante en este tipo de modelos es su estimación. En el caso de los SVAR, depende del tipo de identificación que se realice, que también está en función de la modelación específica. Entonces, una vez construido el modelo junto a sus restricciones estructurales, se puede estimar siguiendo



recomendaciones como en Breitung et al. (2004), Lütkepohl (2005) y Kilian y Lütkepohl (2017), mediante mínimos cuadrados ordinarios (MCO), método de momentos generalizado, máxima verosimilitud, técnicas bayesianas, entre otros.

La estimación bayesiana se basa en la teoría de probabilidades que se aplica a la estimación de parámetros, así como la estimación de proyecciones econométricas, acorde con los desarrollos de Koop (2003). Los problemas clásicos de los tradicionales modelos VAR son encarados con un enfoque de restricciones utilizando probabilidades tal como se indica en Litterman (1986), Doan et al. (1984) y Todd (1988).

Uno de los temas importantes son las *priors*. Jaramillo (2009) realiza una sistematización de las mismas en base al trabajo de Litterman (1986), identificando tres de sus principios básicos: que prioricen la dinámica propia en relación a la dinámica de otras variables; que el efecto de los rezagos disminuya en el tiempo; y que, si las series son estacionarias, exista cointegración.

En el presente documento, el modelo SVAR se estimó con cuatro rezagos, número que permite mantener la estabilidad del modelo. Dado que se utilizará tanto una identificación recursiva como no recursiva, como se detalla más adelante, para la estimación del modelo, se utilizó el algoritmo Markov Chain Monte Carlo (MCMC), un método de muestreo estocástico para obtener una muestra de la distribución de la *posterior* basado en una *prior* que se obtuvo estimando el modelo SVAR por MCO. Después se utilizó la *posterior* obtenida como propuesta de *prior* para el algoritmo Metropolis-Hastings. Es decir, se ajustó el modelo completo usando el MCMC con actualizaciones del algoritmo Metropolis-Hastings para la *prior* basado en la *posterior* de la etapa anterior como propuesta. Los resultados de la estimación se obtuvieron de 30.000 iteraciones con el algoritmo Metropolis-Hastings, descartando las primeras 15.000 iteraciones para la convergencia. Para evitar una posible autocorrelación de los *draws*, se usaron 5 de cada 150 *draws* para la inferencia.

### ***IV.3. Datos e identificación***

Para aproximar la incertidumbre, se empleó el promedio móvil del índice WUI\_BOL (la información puede ser descargada de la página web de esta institución mencionada en la sección 3.1.). El crecimiento económico se captura a partir de variaciones del Producto Interno Bruto real acumulado (PIBrealAcum). El consumo (Gasto de Consumo Final de los Hogares e Ipsfl) y la inversión (Formación Bruta de Capital Fijo más Variación de Existencias) se obtuvieron del PIB por tipo de gasto. La inflación se calculó con el Índice de Precios al Consumidor (IPC). La información de estas variables se obtuvo de la página web del Instituto Nacional de Estadística (INE).

Se utilizó el tipo de cambio real como variable que captura los efectos del contexto externo, toda vez que Bolivia es una economía pequeña y abierta. Esta variable no observable se aproxima a partir de las variaciones del Índice de Tipo de Cambio Efectivo y Real (ITCER<sup>5</sup>). La información de esta variable, así como de la base monetaria total (BMT), proviene de la página web del BCB. Cabe mencionar que todas las variables, excepto el índice de incertidumbre, fueron introducidas en logaritmos y variaciones a doce meses, con el propósito de evitar lidiar con la estacionalidad de las series. Se emplearon datos con frecuencia trimestral tomando en cuenta el periodo entre 1991T1 y 2020T2.

Para identificar los *shocks* estructurales de la incertidumbre sobre las variables macroeconómicas, se empleó una identificación recursiva. Bajo este método se asume que los *shocks* de algunas variables, inicialmente, tienen un impacto retardado en variables seleccionadas. Es decir, no tienen ningún efecto directo en el mismo período (Sims, 1980). En esta estrategia de identificación, el orden de las variables dentro del modelo de estimación determina la rapidez con la cual los indicadores individuales reaccionan a ciertas perturbaciones a lo largo del tiempo. Esta ha sido la identificación más utilizada por diferentes documentos de investigación, situando el índice de incertidumbre por encima del resto de las variables, es decir, asumiendo que los *shocks* de incertidumbre tienen un impacto inmediato sobre el resto de las variables. Dado el número de restricciones utilizadas, el modelo está exactamente identificado.

$$\begin{bmatrix} c_{11} & 0 & 0 & 0 & 0 & 0 & 0 \\ c_{21} & c_{22} & 0 & 0 & 0 & 0 & 0 \\ c_{31} & c_{32} & c_{33} & 0 & 0 & 0 & 0 \\ c_{41} & c_{42} & c_{43} & c_{44} & 0 & 0 & 0 \\ c_{51} & c_{52} & c_{53} & c_{54} & c_{55} & 0 & 0 \\ c_{61} & c_{62} & c_{63} & c_{64} & c_{65} & c_{66} & 0 \\ c_{71} & c_{72} & c_{73} & c_{74} & c_{75} & c_{76} & c_{77} \end{bmatrix} \begin{bmatrix} u_{WUIbol} \\ u_{PIB} \\ u_{IPC} \\ u_{Cons} \\ u_{Inv} \\ u_{BMT} \\ u_{ITCER} \end{bmatrix} = \begin{bmatrix} e_{WUIbol} \\ e_{PIB} \\ e_{IPC} \\ e_{Cons} \\ e_{Inv} \\ e_{BMT} \\ e_{ITCER} \end{bmatrix}$$

Con el propósito de corroborar los resultados obtenidos con la anterior identificación, se estimó un segundo modelo, pero esta vez utilizando una identificación no recursiva. Se asume que los *shocks* de incertidumbre tienen efectos sobre el resto de las variables, pero con un periodo de rezago. Se

5 El ITCER es un índice que se calcula a partir de un promedio ponderado geométrico de las tasas de inflación y las variaciones de los tipos de cambio de los principales socios comerciales.

realizó este ejercicio siguiendo el artículo presentado por DB (2018) realizado con el objetivo de lograr la cuantificación más conservadora posible de los efectos de la incertidumbre sobre la economía real, entre otros aspectos.

$$\begin{bmatrix} c_{11} & c_{21} & c_{31} & c_{41} & c_{51} & c_{61} & c_{71} \\ 0 & c_{22} & 0 & 0 & 0 & 0 & 0 \\ 0 & c_{32} & c_{33} & 0 & 0 & 0 & 0 \\ 0 & c_{42} & c_{43} & c_{44} & 0 & 0 & 0 \\ 0 & c_{52} & c_{53} & c_{54} & c_{55} & 0 & 0 \\ 0 & c_{62} & c_{63} & c_{64} & c_{65} & c_{66} & 0 \\ 0 & c_{72} & c_{73} & c_{74} & c_{75} & c_{76} & c_{77} \end{bmatrix} \begin{bmatrix} u_{WUIbol} \\ u_{PIB} \\ u_{IPC} \\ u_{Cons} \\ u_{Inv} \\ u_{BMT} \\ u_{ITCER} \end{bmatrix} = \begin{bmatrix} e_{WUIbol} \\ e_{PIB} \\ e_{IPC} \\ e_{Cons} \\ e_{Inv} \\ e_{BMT} \\ e_{ITCER} \end{bmatrix}$$

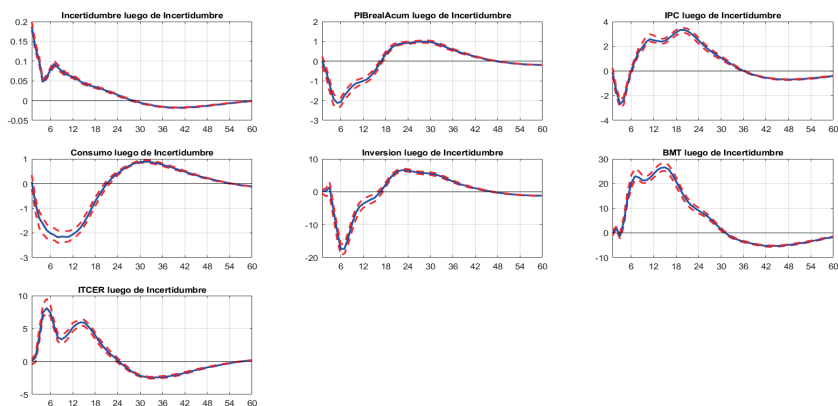
## V. Resultados

Dado que la interpretación de coeficientes únicos es de poca utilidad, se presentan las funciones impulso-respuesta estimadas con el modelo SVAR. Estas permiten identificar las reacciones dinámicas de las variables macroeconómicas a los *shocks* de incertidumbre. En ese sentido, en esta sección, se presentan las respuestas de las variables macroeconómicas seleccionadas ante un aumento de la incertidumbre.

### V.1. *Funciones impulso respuesta modelo recursivo*

La respuesta de las diferentes variables macroeconómicas a un *shock* de incertidumbre va en línea con los resultados encontrados en otros documentos (Gráfico 3).

### Gráfico 3: RESPUESTA DE LAS VARIABLES MACROECONÓMICAS ANTE UN *SHOCK* DE INCERTIDUMBRE. MODELO 1: IDENTIFICACIÓN RECURSIVA



Nota: Funciones impulso-respuesta con intervalos de confianza del 90%.

Un mayor nivel de incertidumbre reduce tanto el consumo de los hogares como la inversión de las empresas. En el caso del consumo, se observa una disminución por un largo periodo (le toma casi cinco años recuperarse), mientras que la inversión se recupera en un menor tiempo (luego de tres años), pero su caída es de mayor magnitud.

Según Bernanke (1983), una de las explicaciones sobre los efectos en la inversión es que los periodos de alta incertidumbre inducen a las empresas a posponer inversiones y la contratación de personal cuando es muy costoso parar un proyecto y/o despedir trabajadores. Una vez que el nivel de incertidumbre disminuye, las empresas aumentan la contratación y la inversión con el fin de satisfacer la demanda acumulada. Otros trabajos como el de Bordo et al. (2016) señalan que, en periodos de incertidumbre, se ve afectado el financiamiento bancario, lo cual también va en detrimento de la inversión.

Mayor incertidumbre genera mayor desempleo (Bloom, 2009; Baker et al., 2015; Caggiano et al., 2017; y Leduc y Liu, 2020), puesto que un contrato laboral representa una relación laboral a largo plazo y las decisiones de contratación son costosas de revertir. Cuando aumenta la incertidumbre, los empleadores pueden optar por esperar y ver antes de convocar a nuevos puestos. Ante esta coyuntura, se generan recortes de gastos y un aumento del ahorro por parte de los hogares por razones de precaución (Bernanke, 1983), por ejemplo, por temor a perder sus fuentes laborales (Leduc y Liu, 2020), provocando una disminución del consumo.

Ambos efectos terminan provocando una caída tanto en el producto como en la inflación. La caída de la actividad económica, así como de la inflación, está en línea con los resultados de Leduc y Liu (2016), quienes señalan que un *shock* de incertidumbre afecta a la economía de manera similar a una reducción de la demanda agregada. El PIB se recupera principalmente gracias a la inversión. Por su parte, la inflación refleja inicialmente una disminución debido a un menor consumo por parte de los hogares. No obstante, dicha caída es de menor duración: solo dura un año y medio. Dicho comportamiento podría explicarse por las respuestas tanto de la base monetaria como del tipo de cambio.

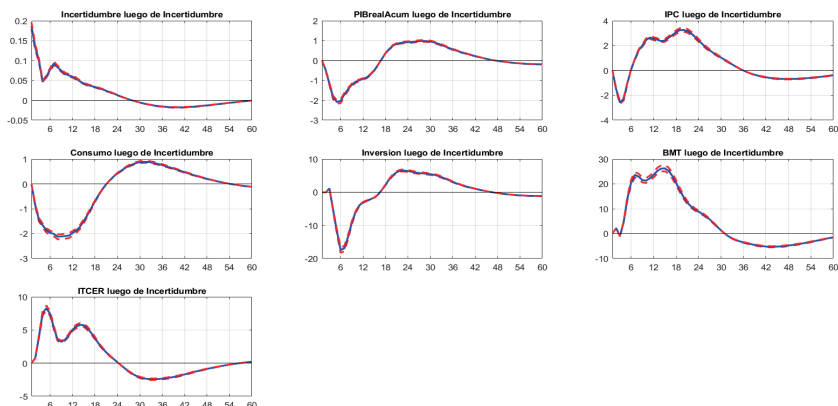
El Banco Central flexibiliza la política monetaria con el propósito de inyectar liquidez y mitigar los efectos de la incertidumbre. Dicha respuesta se refleja en un aumento de la base monetaria de forma inmediata. No obstante, como era de esperarse, no se tienen efectos inmediatos sobre las variables macroeconómicas. El Banco Central, como asegurador final de liquidez, debe proporcionar la suficiente liquidez al sistema financiero con el propósito de que los bancos y otras entidades de intermediación financiera cuenten con los recursos necesarios para financiar y apoyar al sector empresarial.

En el caso del ITCER, este responde al *shock* de forma positiva. Es decir, se observa una depreciación real. En un principio, esta se explicaría por la disminución de la inflación doméstica. Posteriormente, se explicaría por una depreciación nominal, toda vez que no hay razones para que la inflación externa se vea afectada.

## ***V.2. Funciones impulso respuesta: modelo no recursivo***

Siguiendo a DB (2018), ahora se asume que los *shocks* de incertidumbre tienen efectos sobre el resto de las variables, pero con un periodo de rezago. Según los autores, este ejercicio se realiza con el objetivo de lograr la cuantificación más conservadora posible de los efectos de la incertidumbre sobre la economía real, entre otros aspectos. En ese sentido, como se especificó, en este caso se empleó una identificación no recursiva, obteniendo los siguientes resultados:

**Gráfico 4: RESPUESTA DE LAS VARIABLES MACROECONÓMICAS ANTE UN SHOCK DE INCERTIDUMBRE. MODELO 2: IDENTIFICACIÓN NO RECURSIVA**



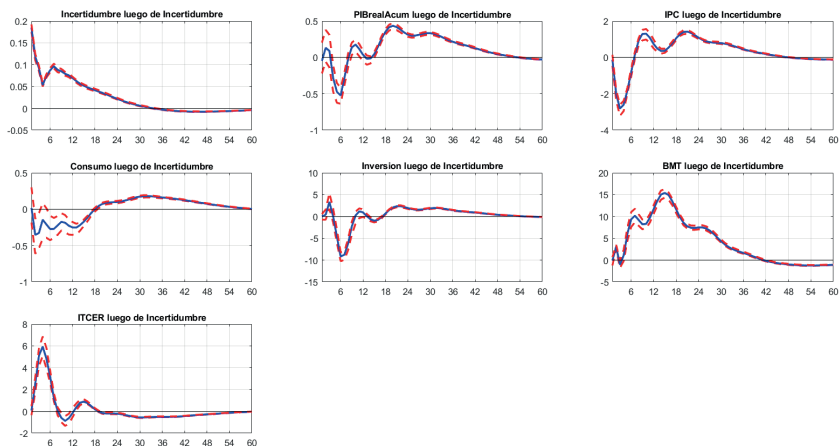
Nota: Funciones impulso-respuesta con intervalos de confianza del 90%.

Los resultados obtenidos con una identificación no recursiva (Gráfico 4) son básicamente los mismos que los obtenidos con una identificación recursiva en el Modelo 1 (Gráfico 3), por lo que se corroboran los efectos adversos de la incertidumbre sobre las variables macroeconómicas.

**V.3. Ejercicios de robustez**

En cuanto a los resultados obtenidos, se debe tener en cuenta que están considerando los efectos inusuales de la pandemia COVID-19. La llegada del coronavirus y las medidas adoptadas para evitar una propagación descontrolada tuvieron efectos importantes tanto en el nivel de la incertidumbre como en las variables macroeconómicas internas. Distintas variables presentaron cambios bruscos, lo cual podría estar amplificando los efectos de la incertidumbre debido a que no se cuenta con una variable que, explícitamente, refleje los efectos del COVID-19 y la cuarentena. Por lo tanto, se restimaron los modelos, pero esta vez con datos hasta 2019 para tener una mejor comprensión de los efectos macroeconómicos de la incertidumbre.

### Gráfico 5: RESPUESTA DE LAS VARIABLES MACROECONÓMICAS ANTE UN *SHOCK* DE INCERTIDUMBRE. MODELO 3: IDENTIFICACIÓN RECURSIVA SIN COVID-19



Nota: Funciones impulso-respuesta con intervalos de confianza del 90%.

Los resultados, sin considerar los efectos del COVID-19 (Gráfico 5), en general, son similares a los obtenidos en los Modelos 1 y 2, aunque las respuestas de las variables son de menor magnitud.

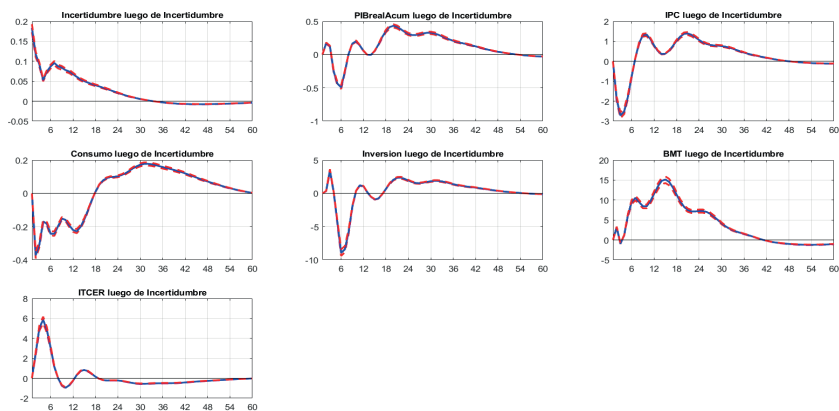
En el caso de la inversión, se observa una caída, aunque esta no es instantánea como se observa en los anteriores casos. En este modelo, la inversión disminuye después de cuatro periodos (un año) y se recupera en un menor tiempo (después de casi un año y medio). Si bien la mayor parte de los documentos señalan que periodos de alta incertidumbre generan una menor inversión, algunos trabajos encontraron resultados diferentes. Como señalan Caballero (1991) y Belke y Kronen (2017), en el caso de la inversión general, la incertidumbre puede tener un efecto positivo si las empresas consideran que sí vale la pena poder adaptarse a diferentes condiciones políticas y económicas en el futuro. En el caso de Bolivia, se puede inferir que, en principio, las empresas mantienen un cierto optimismo, pero este no dura mucho tiempo, posiblemente porque el resto de las variables económicas empiezan a verse afectadas.

Instantáneamente, el consumo refleja una disminución. Sin embargo, su caída es de menor magnitud y se recupera en un menor tiempo (casi en cuatro años). El comportamiento del PIB está determinado por la respuesta de la inversión. Por su parte, la inflación cae instantáneamente, afectada por el menor consumo. La política monetaria, nuevamente, responde inyectando recursos, por lo que

umenta la base monetaria. Por su parte, se observa una depreciación real (la cual está impulsada por la caída de la inflación y, posiblemente, por una depreciación nominal) aunque por un periodo menos extenso (casi dos años).

Nuevamente, con el propósito de complementar estos resultados, se realizó un ejercicio con una identificación no recursiva asumiendo que los *shocks* de incertidumbre tienen efectos sobre el resto de las variables con un periodo de rezago. Los resultados obtenidos (Gráfico 6) son similares a los del Modelo 3 (Gráfico 5) ratificando la importancia de los efectos de la incertidumbre en la economía boliviana.

**Gráfico 6: RESPUESTA DE LAS VARIABLES MACROECONÓMICAS ANTE UN SHOCK DE INCETIDUMBRE. MODELO 4: IDENTIFICACIÓN NO RECURSIVA SIN COVID-19**



Nota: Funciones impulso-respuesta con intervalos de confianza del 90%.

#### V.4. ¿Cómo se ve afectada la política monetaria?


El Banco Central flexibiliza la política monetaria para estimular la demanda interna y, por ende, mitigar los efectos de los periodos de alta incertidumbre, pero esto no representa una tarea simple. Bolivia, como muchas economías pequeñas y abiertas, tiene una economía en la que circulan dos monedas, la nacional (el boliviano) y una extranjera (el dólar estadounidense), las cuales son utilizadas por los hogares y las empresas tanto para transacciones como para ahorro. Los estudios han encontrado que, en periodos de alta incertidumbre, se da una sustitución de monedas por parte de los agentes económicos, provocando un proceso de dolarización (la preferencia por una moneda extranjera sobre la moneda nacional para cumplir con las funciones tradicionales de dinero).



La dolarización ha sido la respuesta a periodos de volatilidad económica, caracterizados principalmente por procesos inflacionarios severos (Berg y Borensztein, 2000; y Demidenko, 2017) y/o cuando existe incertidumbre acerca de las políticas macroeconómicas internas (Neanidis y Savva, 2006). En ese sentido, Burdisso y Corso (2011) señalan que para las autoridades monetarias, comprender cómo la incertidumbre afecta el grado de sustitución entre los activos denominados en moneda local y en otras divisas, constituye un interés de primer orden, especialmente en países recurrentemente expuestos a episodios de estrés cambiario y financiero.

La historia de América Latina ha estado marcada por la presencia de diferentes crisis, económicas y sociales. En el caso de Bolivia, recientemente, los conflictos sociales y políticos de octubre y noviembre de 2019 determinaron abruptos incrementos en la demanda de dólares por parte del público por motivos precautorios (BCB, 2020a) habiéndose registrado niveles récord (Gráfico 7). Una vez que el orden social y político fue restablecido, la demanda de dólares se normalizó en diciembre.

**Gráfico 7: VENTAS DE DÓLARES DEL SISTEMA FINANCIERO AL PÚBLICO GENERAL**  
(Flujos netos mensuales en millones de dólares)



Fuente: Informe de Política Monetaria, enero 2020, BCB (2020a)

Una mayor demanda de dólares afecta a la política monetaria puesto que reduce la eficiencia de sus mecanismos de transmisión, toda vez que parte de la inyección de moneda nacional se revierte, debido a que los agentes económicos venden moneda nacional para adquirir moneda extranjera. Las ventas de dólares que el sistema financiero realizó al público, entre octubre y noviembre, fueron atendidas con divisas que se proveyeron desde la Autoridad Monetaria (BCB, 2020a).

Una mayor demanda de dólares puede provocar pérdida de Reservas Internacionales Netas (IMF, 2011; Iordachi et al., 2017). La base monetaria comprende los pasivos del BCB que sustentan la expansión del dinero, por lo que esta debe estar respaldada por activos, entre los cuales se encuentran las Reservas Internacionales Netas. Instituciones como el Fondo Monetario Internacional recomendaron que todas las operaciones de los bancos centrales deben estar debidamente garantizadas (IMF, 2020). En ese sentido, una pérdida de reservas puede limitar la capacidad de reacción de la política monetaria.

En este periodo de alta incertidumbre ocasionada por la pandemia del COVID-19 y, particularmente en el caso de Bolivia por los efectos rezagados que dejaron los conflictos sociopolíticos de 2019 y el periodo electoral, la participación del BCB ha sido relevante para mitigar los efectos de estos *shocks* adversos. Sin embargo, como el FMI (2020) señala, si bien en este momento los bancos centrales se ven en la necesidad de apoyar a sectores económicos que están atravesando por una situación difícil, deben tener en cuenta que existe un punto en el que continuar inyectando recursos puede poner en riesgo la estabilidad financiera. En ese sentido, si bien la política monetaria juega un rol importante en la recuperación de la actividad económica, se debe tener en cuenta que esta tiene límites y debe ser complementada con otras políticas (fiscales) para alcanzar el objetivo de estabilidad económica.

Adicionalmente, los resultados obtenidos señalan que la expansión monetaria está condicionada al surgimiento de un proceso inflacionario posterior (después de un año y medio). Si bien, en este momento, el BCB debe inyectar recursos para apoyar a la reactivación de la economía local, no debe descuidar su objetivo de mantener la estabilidad de precios internos. Este es otro factor que limita los alcances de la política monetaria.

## VI. Conclusiones

Periodos de alta incertidumbre, tienen consecuencias considerables sobre la actividad económica, por lo que los hacedores de política monetaria deben tener en cuenta el grado de incertidumbre en el cual se desenvuelve la economía. En el caso particular de Bolivia, la pandemia del COVID-19, junto a un periodo de transición política, generó un inusitado repunte en la incertidumbre y es una de las principales fuentes de los efectos adversos en la economía.

Utilizando un modelo SVAR estimado con técnicas bayesianas, se analizaron los efectos del incremento del nivel de la incertidumbre sobre las principales variables macroeconómicas. La incertidumbre se aproxima por medio del índice WUI\_BOL, el cual se obtuvo de la página web del Índice de Incertidumbre Mundial (WUI, por sus siglas en inglés). Este índice muestra que los periodos

en los que se registró una alta incertidumbre se caracterizaron, principalmente, por inestabilidad política y social y, en menor medida, desaceleración económica. Recientemente, también tuvo un efecto importante la pandemia del COVID-19. Los principales resultados encontrados fueron los siguientes:

- Un mayor nivel de incertidumbre reduce tanto el consumo de los hogares como la inversión de las empresas, siendo el primero afectado en un mayor periodo de tiempo que la inversión. No obstante, la caída de la inversión es de mayor magnitud que la del consumo.
- Estos efectos adversos provocan una caída en el crecimiento económico y en la inflación. La principal fuente de recuperación del PIB es la inversión. Por su parte, la inflación refleja una disminución inicial debido a un menor consumo por parte de los hogares, aunque posteriormente aumenta debido a la política monetaria expansiva.
- En ese marco, el Banco Central adopta una política monetaria expansiva con el propósito de inyectar liquidez y mitigar los efectos de la incertidumbre. Dicha respuesta se refleja, de forma inmediata, en un aumento de la base monetaria; sin embargo, no tiene efectos inmediatos sobre las variables macroeconómicas.
- En el caso del tipo de cambio real, este responde al *shock* de forma positiva. Es decir, se observa una depreciación real. En un principio, esta se explicaría por la disminución de la inflación, posteriormente, se explicaría por una depreciación nominal.

Con el objetivo de lograr la cuantificación más conservadora posible de los efectos de la incertidumbre sobre la economía real, se realizó un segundo ejercicio donde se asume que los *shocks* de incertidumbre tienen efectos sobre el resto de las variables, pero con un periodo de rezago. Adicionalmente, con el objetivo de dar mayor robustez a los resultados obtenidos, se estimaron modelos con datos hasta 2019 sin tomar en cuenta los efectos del COVID-19. Los resultados obtenidos corroboran los encontrados con el primer modelo.

Los resultados obtenidos señalan que la respuesta del BCB fue acertada, puesto que un *shock* de incertidumbre afecta a la economía de manera similar a una reducción de la demanda agregada (Leduc y Liu, 2016). El BCB debe mantener una política monetaria expansiva para estimular la demanda interna y, por ende, mitigar los efectos de los periodos de alta incertidumbre, pero esto no representa una tarea simple. La expansión monetaria está condicionada al surgimiento de un proceso inflacionario posterior, por lo que el BCB debe mantener un equilibrio: apoyar a la reactivación económica sin descuidar la estabilidad de precios. Por otra parte, los hechos de 2019 demuestran que,

en periodos de incertidumbre, los agentes económicos adquieren dólares por motivos precautorios (BCB, 2020a), factor que limita el efecto de la política monetaria sobre la actividad económica. De ahí la necesidad de complementar las acciones de política monetaria con medidas fiscales.

## Referencias bibliográficas

AASTVEIT, K. A., G.J. NATVIK, S. SOLA (2013). "Economic uncertainty and the effectiveness of monetary policy" Norges Bank, Working Paper 17, June

AHIR, H., N. BLOOM, D. FURCERI (2018). "The World Uncertainty Index" available at SSRN: <https://ssrn.com/abstract=3275033>, October

BAKER, S. R., N. BLOOM, S. J. DAVIS (2015). "Measuring Economic Policy Uncertainty" Centre for Economic Performance, Discussion Paper No 1379, October

BAKER, S. R., N. BLOOM, S. J. DAVIS, S. J. TERRY (2020). "COVID-Induced Economic Uncertainty" National Bureau of Economic Research, Working Paper 26983, April

BANCO CENTRAL DE BOLIVIA – BCB, (2020a). "Informe de Política Monetaria - enero 2020"

BANCO CENTRAL DE BOLIVIA – BCB, (2020b). "Informe de Política Monetaria - julio 2020"

BANEGAS, R. A., J. SALAS, L. F. ESCOBAR (2019). "Incertidumbre internacional y transmisión de *shocks* en Bolivia" Banco Central de Bolivia, *Revista de Análisis*, 30, pp. 9 - 51

BASCO, E., T. CASTAGNINO, S. KATZ, S. VARGAS (2007). "Política monetaria en contextos de incertidumbre, cambio de régimen y volatilidad pronunciada" Banco Central de la República Argentina, Estudios BCRA, 4, noviembre

BASU, S. and B. BUNDICK (2017). "Uncertainty shocks in a model of effective demand" *Econometrica*, 85 (3), pp. 937 - 958

BELKE, A. and D. KRONEN (2017). "The Impact of Uncertainty on Macro Variables - an SVAR-Based Empirical Analysis for EU countries" Universität Duisburg Essen, Ruhr Economic Papers, # 699

BERG, A. and E. BORENSZTEIN (2000). "The Choice of Exchange Rate Regime and Monetary Target in Highly Dollarized Economies" International Monetary Fund, Working Paper 00/29, February

BERNANKE, B. S. (1983). "Irreversibility, uncertainty and cyclical investment" *The Quarterly Journal of Economics*, 98 (1), pp. 85 - 106

- BERTOLA, G., L. GUIISO, L. PISTAFERRI (2005). "Uncertainty and Consumer Durables Adjustment" *The Review of Economic Studies*, 72 (4), pp. 973 - 1007
- BLOOM, N. (2009). "The Impact of Uncertainty Shocks" *Econometrica*, 77 (3), pp. 623 – 685
- BLOOM, N. (2013). "Fluctuations in Uncertainty" Centre for Economic Performance, Occasional Paper 38, December.
- BORDO, M. D., J. V. DUCA, C. KOCH (2016). "Economic Policy Uncertainty and the Credit Channel: Aggregate and Bank Level U.S. Evidence over Several Decades" National Bureau of Economic Research, Working Paper No. 22021, February
- BORN, B. and J. PFEIFER (2014). "Policy risk and the business cycle" *Journal of Monetary Economics*, 68, pp. 68 - 85
- BREITUNG, J., R. BRÜGGEMANN, H. LÜTKEPOHL "Structural Vector Autoregressive Modeling and Impulse Responses" in LÜTKEPOHL, H. and M. KRÄTZIG (Eds.) (2004) *Applied Time Series Econometrics*, Cambridge University Press, United States of America, pp. 159 - 196
- BURDISSO, T. y E. A. CORSO (2011). "Incertidumbre y dolarización de cartera: El caso argentino en el último medio siglo" Centro de Estudios Monetarios Latinoamericanos – CEMLA, *Monetaria*, XXXIV (4), pp. 461 - 515
- CABALLERO, R. J. (1991). "On the Sign of the Investment-Uncertainty Relationship" *The American Economic Review*, 81 (1), pp. 279 - 288
- CAGGIANO, G., E. CASTELNUOVO, G. PELLEGRINO (2017). "Estimating the real effects of uncertainty shocks at the zero lower bound" Bank of Finland, Research Discussion Paper 6, January
- CALDARA, D., C. FUENTES-ALBERO, S. GILCHRIST, E. ZAKRAJŠEK, (2016). "The macroeconomic impact of financial and uncertainty shocks" *European Economic Review*, 88, pp. 185 - 207
- CARUANA, J. (2012). "Why central bank balance sheets matter" Bank for International Settlements, *BIS Papers No 66*, pp. 2 - 9
- DEMIDENKO, M. (2017). "Dollarization: causes and solutions" Eurasian Development Bank, expert comment. Available at <https://eabr.org/en/press/comments/dollarization-causes-and-solutions/>

DEUTSCHE BUNDESBANK – DB (2018). “The macroeconomic impact of uncertainty” *Monthly Report October*, 70 (10), pp. 49 - 64

DOAN, T., R. LITTERMAN, C. SIMS (1984). “Forecasting and Conditional Projection using Realistic Prior Distributions” National Bureau of Economic Research, Working Paper No 1202, September

DRUMETZ, F., C. PFISTER, J. – G. SAHUC (2015). *Politique monétaire*, 2<sup>e</sup> édition, De Boeck Supérieur s.a., Pays Bas

EBERLY, J. C. (1994). “Adjustment of Consumers’ Durables Stocks: Evidence from Automobile Purchases” *Journal of Political Economy*, 102 (3), pp. 403 - 436

FAJGELBAUM, P., E. SCHAAL, M. TASCHEREAU-DUMOUCHEL (2014). “Uncertainty Traps” National Bureau of Economic Research, Working Paper No. 19973, March

GILCHRIST, S., J. W. SIM, E. ZAKRAJŠEK (2014). “Uncertainty, Financial Frictions, and Investment Dynamics” National Bureau of Economic Research, Working Paper No 20038, April

GLOVER, B. and O. LEVINE (2015). “Uncertainty, investment, and managerial incentives” *Journal of Monetary Economics*, 69, pp. 121 - 137

GREENSPAN, A. (2003). “Monetary Policy under Uncertainty” remarks at a symposium sponsored by the Federal Reserve Bank of Kansas City on August 29, 2003

GULEN, H. and M. ION (2016). “Policy Uncertainty and Corporate Investment” *The Review of Financial Studies*, 29 (3), pp. 523 - 564

INTERNATIONAL MONETARY FUND – IMF (2011). “Assessing Reserve Adequacy” Monetary and Capital Markets, Research, and Strategy, Policy, and Review Departments, February

INTERNATIONAL MONETARY FUND - IMF (2020). “Central Bank Support to Financial Markets in the Coronavirus Pandemic” Monetary and Capital Markets, Special Series on COVID-19, May

IODACHI, V., M. R. TIRLEA, T. PETROVA (2017). “International Reserves Management in The Republic of Moldova” *Economy and Sociology: Theoretical and Scientifical Journal*, Socionet; Complexul Editorial “INCE”, 1-2, pp. 65 - 74

- JARAMILLO, P. (2009). "Estimación de VAR bayesianos para la economía chilena" *Revista de Análisis Económico*, 24 (1), pp. 101 - 126
- KANG, W., K. LEE, R. A. RATTI (2014). "Economic policy uncertainty and firm-level investment" *Journal of Macroeconomics*, 39 (A), pp. 42 - 53
- KILIAN, L. and H. LÜTKEPOHL (2017). *Structural Vector Autoregressive Analysis* Cambridge University Press, United Kingdom.
- KOOP, G. (2003). *Bayesian Econometrics*, John Wiley & Sons Limited, United Kingdom
- LEDUC, S. and Z. LIU (2016). "Uncertainty shocks are aggregate demand shocks", *Journal of Monetary Economics*, 82, pp. 20 - 35
- LEDUC, S. and Z. LIU (2020). "The Uncertainty Channel of the Coronavirus" Federal Reserve Bank of San Francisco, Economic Letter 07, March.
- LITTERMAN, R. B. (1986). "Forecasting with Bayesian Vector Autoregressions: Five Years of Experience" *Journal of Business & Economic Statistics*, 4 (1), pp. 25 - 38
- LÜTKEPOHL, H. (2005). *New Introduction to Multiple Time Series Analysis*, Springer-Verlag, Germany
- LÜTKEPOHL, H. (2017). "Estimation of structural vector autoregressive models" *Communications for Statistical Applications and Methods*, 24 (5), pp. 421 - 441
- NEANIDIS, K. C. and C. S. SAVVA (2006). "The Effects of Uncertainty on Currency Substitution and Inflation: Evidence from Emerging Economies" The University of Manchester, Economics Discussion Paper EDP-0609, March
- ORLIK, A. and L. VELDKAMP (2014). "Understanding Uncertainty Shocks and the Role of Black Swans" National Bureau of Economic Research, Working Paper No. 20445, August
- PINSHI, C. P. (2020). "COVID-19 uncertainty and monetary policy" MPRA Paper No. 100184, May
- RODRIK, D. (1991). "Policy uncertainty and private investment in developing countries" *Journal of Development Economics*, 36 (2), pp. 229 - 242
- ROMER, C. D. (1990). "The Great Crash and the Onset of the Great Depression" *The Quarterly Journal of Economics*, 105 (3), pp. 597 - 624



SCHUMPETER, J. A. (1912). *The Theory of Economic Development. An Inquiry into Profits, Capital, Credit, Interest and the Business Cycle* translated from German by OPIE, R. (1934) Harvard University Press, United States of America

SIMS, C. A. (1980). "Macroeconomics and Reality" *Econometrica*, 48 (1), pp. 1 - 48

TODD, R. M. (1988). "Implementing Bayesian Vector Autorregressions" Federal Reserve Bank of Minneapolis, Working Paper 384, September

VARELA, G. (2010). *Exchange rate expectations, uncertainty and output in the Southern Cone*, Doctoral thesis (DPhil), University of Sussex, Department of Economics, December

VEBLEN, T. (1904). *The Theory of Business Enterprise*, edited by Cosimo Inc. (2005), New York

# **Dinámica e impacto del Covid-19 en la economía boliviana**

**Christian Mauricio Huanto Quispe**

## **Resumen**

El presente documento analiza la dinámica de transición de la pandemia Covid-19 y sus posibles efectos en la economía boliviana. Se utiliza una modelación de dos pasos: primero, se modela de tal manera que sea eficiente la dinámica de la pandemia, expandiendo el modelo clásico SIR para simular la trayectoria de la pandemia; se utilizan métodos numéricos y otra novedosa metodología para recuperar los parámetros de dichos modelos. Segundo, para estudiar los posibles efectos de la pandemia en la economía boliviana, se vincula la modelación del paso anterior con un modelo de equilibrio general. Se encuentra que los efectos de la pandemia generan una recesión grande y persistente en la economía boliviana. Asimismo, las políticas de contención para controlar la pandemia logran ayudar a salvar vidas pero pueden exacerbar aún más la recesión en la economía.

**Clasificación JEL:** *C0, E0, I1, H0*

**Palabras Clave:** *Pandemia, Covid-19, modelos epidemiológicos, economía, recesión*

# Dinámica e impacto del Covid-19 en la economía boliviana\*

Christian Mauricio Huanto Quispe\*\*

## RESUMEN

El presente documento analiza la dinámica de transición de la pandemia Covid-19 y sus posibles efectos en la economía boliviana. Se utiliza una modelación de dos pasos: primero, se modela de tal manera que sea eficiente la dinámica de la pandemia, expandiendo el modelo clásico SIR para simular la trayectoria de la pandemia; se utilizan métodos numéricos y otra novedosa metodología para recuperar los parámetros de dichos modelos. Segundo, para estudiar los posibles efectos de la pandemia en la economía boliviana, se vincula la modelación del paso anterior con un modelo de equilibrio general. Se encuentra que los efectos de la pandemia generan una recesión grande y persistente en la economía boliviana. Asimismo, las políticas de contención para controlar la pandemia logran ayudar a salvar vidas pero pueden exacerbar aún más la recesión en la economía.

**Clasificación JEL:** *C0, E0, I1, H0*

**Palabras Clave:** *Pandemia, Covid-19, modelos epidemiológicos, economía, recesión*

---

\* El contenido del presente documento es de responsabilidad del autor y no compromete la opinión del Banco Central de Bolivia.

\*\* Estudiante de Magister en Economía de la Universidad de Chile, [chuanto@fen.uchile.cl](mailto:chuanto@fen.uchile.cl)

# Dynamics and impact of Covid-19 on the Bolivian economy\*

Christian Mauricio Huanto Quispe\*\*

## ABSTRACT

This document analyzes the transition dynamics of the Covid-19 pandemic and its possible effects on the Bolivian economy. A two-step modeling is used: first, the dynamics of the pandemic is modeled in such a way that the dynamics of the pandemic be efficient, expanding the classic SIR model to simulate the trajectory of the pandemic; numerical methods and another novel methodology to recover the parameters of these models are used. Second, in order to study the possible effects of the pandemic on the Bolivian economy, the modeling of the previous step is linked with a general equilibrium model. It is found that the effects of the pandemic generate a large and persistent recession in the Bolivian economy, as well as the containment policies to control the pandemic help save lives but can further exacerbate the downturn in the economy.

**JEL Classification:** C0, E0, I1, H0

**Key Words:** *Pandemic, Covid-19, epidemiological models, economy, recession*

---

\* The conclusions, opinions and points of view expressed in this document do not necessarily represent those of the Central Bank of Bolivia or its authorities and are the sole responsibility of the author.

\*\* Contact: [chuanto@fen.uchile.cl](mailto:chuanto@fen.uchile.cl)

## I. Introducción

En diciembre de 2019, en Wuhan-China, surgió un virus denominado Covid-19. En un inicio, la Organización Mundial de la Salud (OMS) no lo consideró como pandemia pero, a medida que fue avanzando el tiempo, este virus se fue expandiendo a nivel mundial, produciendo alarma por el aumento exponencial de casos, originando varios muertos y varios infectados en todo el mundo. Hasta la fecha en que se redactó este documento, según datos de la *Johns Hopkins University*<sup>1</sup>, se reportaron 17.507.359 casos confirmados y 677.538 muertos en todo el mundo.

Ante esta pandemia declarada por la OMS, los países del mundo adoptaron diferentes medidas para intentar que la pandemia no se propague. Algunos utilizan el término ‘aplanar la curva’. Para entrar en contexto, en el caso boliviano, las autoridades optaron por una cuarentena total en todo el territorio nacional. Esta medida incluyó el cierre total de todas sus fronteras. En todo el territorio, no hubo circulación de vehículos, las personas solo podían salir un día a la semana y, en fines de semana, nadie podía salir. Se suspendieron las jornadas laborales tanto en el sector público como privado, todo con el fin de frenar los contagios a nivel nacional. En fecha 11 de mayo, las autoridades decidieron flexibilizar las medidas y optaron por una “cuarentena dinámica” debido al perjuicio económico que la cuarentena total estaba ocasionando. En esta medida “dinámica”, se mantuvieron: el cierre de fronteras, la suspensión de las clases escolares y los eventos públicos masivos, como los deportivos y religiosos.

Quiérase o no, estas medidas, a fin de cuentas, tienen cierto impacto en la sociedad. Uno de los más importantes recae en la economía. Como muchos expertos ya lo van señalando, esta pandemia tendrá un impacto negativo sobre la economía boliviana. Cabe mencionar que el Estado Plurinacional de Bolivia, entre los meses de octubre y diciembre de 2019, estuvo atravesando una crisis social debido a las elecciones presidenciales que se celebraron en octubre de ese año, lo que deterioró severamente su economía. Por ejemplo, el crecimiento del PIB pasó de 4,2% en 2018, a 2,2% en 2019. Esto se debió a que, prácticamente, la actividad económica se frenó en estas fechas y, además, hubo una ralentización de la economía mundial.

Si uno se pone a pensar en las medidas adoptadas por las autoridades del gobierno boliviano para hacer frente a la pandemia del Covid-19, estas, a futuro, tendrán un impacto en la economía boliviana y en la evolución de dicha pandemia, ya que como bien señala John Cochrane (2020) en su comentario “*Corona virus monetary policy*”, en su blog *The Grumpy Economist*, “*Shutting down the economy - and more importantly turning it back on again - is not*

1 Ver <https://coronavirus.jhu.edu/map.html>

*like shutting down and turning on a light bulb. It's more like shutting down and restarting a nuclear reactor. You need to do it carefully, and make sure the parts survive the shutdown intact*<sup>2</sup>. Por ello, es necesario ver los efectos de la pandemia en la economía, de alguna manera. Por lo tanto, uno puede plantearse la siguiente cuestión ¿cuál será el impacto del Covid-19 en la economía de Bolivia?

Si revisamos la reciente producción académica escrita en Bolivia con relación al Covid-19, gran parte de esta solo se enfoca en el análisis de datos económicos que se van observando. Otros investigadores están trabajando en documentos un poco más formales, pero hasta el momento no se vio un artículo que esté modelando el impacto de la enfermedad en la economía.

Por lo tanto, lo que se pretende hacer en este artículo es tratar de modelar, de una manera eficiente, el impacto del Covid-19, expandiendo el modelo epidemiológico clásico SIR (*Susceptible-Infected-Removed* por sus siglas en inglés) para simular la trayectoria de la pandemia. Para esta versión del documento se utiliza la metodología propuesta por Fernández-Villaverde y Jones (2020), que se basa en un modelo SIRD, descartando el modelo SEIRD (*Susceptible-Exposed-Infected-Recovered-Deceased* por sus siglas en inglés) generalizado que se utilizó en versiones anteriores. El motivo del cambio de metodología se debe a que, en Bolivia, se han realizado pocos test de diagnóstico, por lo que la cantidad de casos positivos podría ser mayor a la registrada y muy desconocida, lo cual puede sesgar nuestras estimaciones y resultados. Para estudiar la interacción entre las decisiones económicas y sus consecuencias económicas, utilizo algunos modelos sugeridos por Chumacero (2020), Eichenbaum et al. (2020). Estos modelos se describirán mejor en la sección correspondiente.

El documento se divide en 5 secciones: la sección II describe la literatura en cuestión utilizada; la sección III describe, de mejor manera, los modelos que se utilizan para modelar el comportamiento de la pandemia y su relación con la economía; la sección IV muestra los resultados de los ejercicios numéricos para el caso boliviano; y por último, se muestran las conclusiones finales.

## **II. Literatura económica utilizada**

Los economistas no estamos completamente involucrados con modelos epidemiológicos, pero usamos estos modelos para explicar el impacto de la evolución de la pandemia en la economía. Tenga en cuenta que este artículo es puramente un ejercicio de simulación numérica, por lo que me abstengo de sacar conclusiones precisas basadas en simulaciones o estimaciones de parámetros. Esto lo dejo a los expertos en epidemiología y medicina.

---

2 Ver <https://johnhcochrane.blogspot.com/2020/03/corona-virus-monetary-policy.html>

A continuación, resumiré algunos trabajos interesantes que pueden ayudar de mejor manera a comprender esta relación entre epidemiología y economía.

Uno de los documentos más vistos es el de Atkeson (2020). Este documento presenta a los economistas un modelo SIR simple de progresión de Covid-19 en los Estados Unidos. Su modelo permite hacer declaraciones cuantitativas sobre la compensación entre la gravedad y el momento de la supresión de la enfermedad a través de una medida de distanciamiento social y la progresión de la enfermedad en la población. Su mensaje principal para los economistas, derivado de las simulaciones de su modelo en los Estados Unidos, es que probablemente requerirá de medidas severas de distanciamiento social mantenidas durante un año entero, o incluso 18 meses para evitar graves consecuencias para la salud pública.

Otro documento interesante es de McKibbin y Fernando (2020). En él, los autores observan siete escenarios diferentes de cómo podría evolucionar la pandemia en el año y, además, examinan los impactos de los diferentes escenarios sobre los resultados macroeconómicos y los mercados financieros mediante un modelo híbrido global DSGE/CGE de equilibrio general. Sus resultados demuestran que, incluso, un brote contenido podría impactar significativamente en la economía global en el corto plazo. Además, señalan que estos se pueden evitar si se financia un buen sistema de salud.

Entre los documentos interesantes de cómo relacionar la epidemiología con economía, se encuentra el de Chumacero (2020), quien presenta un modelo estilizado para caracterizar la dinámica de la pandemia, sus consecuencias económicas y cómo, ambas características, se reflejan en el bienestar de las personas según lo establecido por las políticas de contención, las mismas que tienen consecuencias económicas en varias dimensiones. Él usa un modelo SIR para caracterizar la dinámica de la pandemia y ver el impacto en la economía. Considera un agente representativo, cuya utilidad depende de su consumo (aproximado por sus ingresos) y su estado de salud. Sus resultados de simulación con distintos parámetros señalan que, en un extremo, un bloqueo completo ralentizaría la propagación de Covid-19, pero podría tener consecuencias catastróficas en la economía y el bienestar de los individuos. En el otro extremo, ninguna acción para prevenir la propagación del virus podría, también, tener consecuencias devastadoras en términos de vidas humanas.

Otro documento que va en la misma línea que el de Chumacero (2020) es el de Eichenbaum et al. (2020). Ellos parten de un modelo canónico de epidemiología para estudiar la interacción entre decisiones económicas y pandemias. Para combinar epidemiología con economía, los autores utilizan un modelo llamado macro-SIR. Su modelo deja en claro que las decisiones de las personas para reducir el consumo y el trabajo reducen la gravedad de la

pandemia medida por las muertes totales. Estas mismas decisiones exacerbaban el tamaño de la recesión causada por la pandemia. Cabe mencionar que, en su modelo, una pandemia tiene efectos tanto en demanda agregada como en la oferta agregada.

Prácticamente, estos documentos analizados calibran los parámetros de los modelos epidemiológicos a partir de los datos observados. En una anterior versión del documento, como se verá en la siguiente sección, se intentó estimar los parámetros de los modelos epidemiológicos mediante un modelo SEIRD generalizado con los datos de infectados, recuperados y muertos. Pero la desventaja de hacer esto es que puede que estos resultados presenten algún error de medición debido a que, en Bolivia, se realizaron pocas pruebas de diagnóstico, por lo que la cantidad de casos positivos podría ser mayor a la registrada.

Una serie de datos menos ruidosa que se puede utilizar para intentar hacer algo razonable es la serie de datos de muertes registradas por Covid-19. Esta serie se puede utilizar para encontrar, al menos, parámetros que son importantes, como lo hacen Fernández-Villaverde y Jones (2020) en su documento, en el que utilizan datos sobre muertes en ciudades y estados de EE. UU., y también de varios países y regiones para estimar un modelo epidemiológico estándar de Covid-19. Lo interesante de esta metodología es que se puede recuperar un parámetro que es muy importante para estos modelos, a partir de los datos de las muertes, de una forma sencilla. Su metodología se describirá detalladamente en la próxima sección.

Por último, cabe aclarar que en adición a estos artículos, se utilizan otros, no menos importantes, que ayudan a entender la modelación de la epidemiología. Estos se describirán cuando sean necesarios.

### **III. Modelación**

La literatura en salud pública utiliza una amplia variedad de modelos epidemiológicos que modelan la evolución de una pandemia con el fin de generar escenarios posibles que luego se utilizan para guiar las decisiones y recomendar e imponer medidas de mitigación para aplanar la curva. Como esta investigación intenta simular los patrones de Covid-19 en Bolivia, utilizo una extensión de la conocida familia de modelos epidemiológicos SIR, propuesta por Kermack y McKendrick (1927).

Como se mencionó anteriormente, el propósito del trabajo es ver el efecto de la pandemia Covid-19 en la economía boliviana. Una forma de aproximar este efecto, es mediante el uso de modelos epidemiológicos y, a su vez, tratar de vincular estos modelos con la economía. En el contexto nacional actual,



existe una variedad de documentos escritos pero, desafortunadamente, no establecen la relación que se quiere evaluar para el estudio de caso. Por esta razón, en este trabajo se utiliza la metodología propuesta por Eichenbaum et al. (2020) y Chumacero (2020) dado que sus documentos proponen una forma práctica de modelar el efecto de la pandemia en la economía y el bienestar de las personas.

A diferencia de los trabajos citados en el párrafo anterior, que calibran el modelo llamado SIR-macro, del cual se infiere el valor de los parámetros de los datos observados, este artículo intentará estimar estos parámetros, o al menos encontrar una forma factible de recuperarlos y vincularlos con un modelo económico. Por lo tanto, para modelar el efecto de la pandemia en la economía y en el bienestar, de una forma que sea más entendible, dividiremos la modelación en dos pasos.

El primer paso consiste en modelar la pandemia con un modelo epidemiológico que intente capturar, de manera adecuada, la evolución de la pandemia del Covid-19 y estimar, o recuperar, los parámetros del modelo con una metodología adecuada. En una versión anterior del documento, se utilizó un modelo epidemiológico SEIRD generalizado que modelaba el comportamiento de la pandemia y no se limitaba a inferir los parámetros de los datos observados para la calibración. Pero esta metodología puede tener un pequeño problema debido a las pocas pruebas de Covid-19 realizadas en Bolivia que hacen que los datos de infectados no sean confiables. Por lo tanto, se plantea otra metodología realizada recientemente por Fernández-Villaverde y Jones (2020), mediante la cual se pueden recuperar algunos parámetros que son importantes en este tipo de modelos a partir de las muertes registradas.

El segundo paso consiste en modelar el efecto de la pandemia en la economía y su bienestar, por lo que, utilizando la metodología de los autores mencionados, y con el paso anterior, procederemos a la calibración y simulación de la economía. Esto ocurre con el fin de lograr nuestro propósito, es decir, ver los efectos de la pandemia en la economía boliviana.


Ahora, se desarrollan estos pasos de manera más amplia. Una vez hecho esto, procederemos a calibrar el modelo y simular el impacto del Covid-19 en la economía boliviana.

### ***III.1. Modelando la pandemia***

En la literatura epidemiológica existe una diversidad de modelos para caracterizar la dinámica de la enfermedad. Como se mencionó, en una versión anterior del documento, se utilizó un modelo SEIR generalizado para caracterizar la dinámica del Covid-19 en Bolivia. Como se puede ver en el

artículo de Godio et al. (2020), este muestra en detalle un modelo SEIR más general; su estructura se presenta en el siguiente diagrama:

**Diagrama 1: MODELO SEIR**



Fuente: Elaboración propia

El modelo SEIRD generalizado simula la serie temporal de un fenómeno epidémico. En su forma clásica, modela la interacción mutua y dinámica de las personas entre cuatro condiciones diferentes: la población susceptible (S), que es una fracción de la población total potencialmente vulnerable a la infección; el grupo expuesto de personas (E) que es una parte de la población que ha sido infectada pero que aún no muestra síntomas (para que aparezcan los síntomas, la enfermedad entra en una etapa de incubación); la población de infectados (I) representa la fracción de la población infectada, es decir, que ya presenta los síntomas después del período de maduración de la pandemia y es detectada mediante test o pruebas; los (R) recuperados son el grupo de personas que han podido superar la pandemia. En nuestro caso, también se maneja la variable (D) que representa la población que murió a causa de la pandemia. Algunos proponen una variable intermedia (Q) que significa el grupo de personas que dieron positivo para la enfermedad y se ponen en cuarentena para ver cómo evoluciona la misma. Este grupo de personas, al final, puede morir o recuperarse de la enfermedad. También podría existir una población (P) llamada no-susceptible, es decir, que no se contagiaría. Este grupo de personas siempre se mantendrá sana y no pasará por las etapas de la pandemia, ya sea por inmunidad u otros factores.

En la literatura epidemiológica existen diferentes métodos para estimar los parámetros de este modelo. En la versión anterior de este artículo, utilizamos la estimación por mínimos cuadrados no lineales (NLLS). Este método, estima los parámetros en función de los datos observados (Q, D, R). Como se sabe, este método usa algoritmos como el de Levenberg-Marquardt (LM) o Gauss-Newton, u otros algoritmos que necesitan una conjetura inicial para funcionar bien y resolver la optimización.

En consecuencia, para utilizar esta metodología, se considera una conjetura inicial de los parámetros para generar series artificiales de S, E, I, Q, R, D. También se tuvo en cuenta que las ecuaciones diferenciales de este modelo deben resolverse numéricamente por algún método. Martcheva (2015) y Godio et al. (2020) sugieren el método Runge-Kutta (RK). Este método es un conjunto de métodos genéricos iterativos, explícitos e implícitos, de resolución numérica de ecuaciones diferenciales de primer orden. Además, este método es muy efectivo para calcular soluciones numéricas de ecuaciones diferenciales con problemas de condiciones iniciales. Este método es de un solo paso, es decir, se basa en los datos anteriores. Y si hablamos de RK de cuarto orden, estamos hablando de un método en el que la función se evalúa cuatro veces antes de calcular el siguiente valor de la variable de interés<sup>3</sup>.

Si bien esta metodología logra replicar, en buena medida, los casos confirmados<sup>4</sup>, puede tener un problema y es que, en Bolivia, se han realizado pocas pruebas de diagnóstico de Covid-19, lo cual hace que los datos de infectados no sean confiables en cuanto podría haber muchos más infectados de los que se reportan. Una forma de subsanar esto es cambiar de metodología y usar datos que sean, por lo menos, más confiables o menos ruidosos. Uno de estos cambios sería usar solo las muertes registradas a causa del Covid-19. Recientemente, Fernández-Villaverde y Jones (2020) propusieron una metodología que nos permite, al menos, recuperar algunos parámetros que son los más importantes de estos modelos a partir de las muertes registradas de manera muy simple.

En su metodología, invierten un modelo epidemiológico estándar SIRD y usan la serie de muertes diarias para recuperar  $\beta_t$ , parámetro asociado al distanciamiento social con el fin de recuperar  $\mathcal{R}_{0t} = \beta_t / \gamma$  variable en el tiempo para capturar cambios en el comportamiento y la política que ocurren en diferentes momentos y con diferentes intensidades en diferentes lugares. En esencia, aplican un enfoque residual de Solow, asumiendo que el modelo se ajusta exactamente a los datos, y retiran los valores implícitos de  $\beta_t$  que así lo hacen.

En relación con el método anterior, esta formulación tiene la ventaja de poder capturar los efectos de reapertura que pueden aumentar los contactos y no usa la serie de infectados. A continuación, describo este método.

Se parte de una población total  $N_t$  que, a diferencia del modelo anterior, puede estar formada por cinco grupos de personas:  $S_t$ , el grupo de personas que son susceptibles a la enfermedad;  $I_t$ , el grupo de personas que son infecciosas a

3 Ver [https://es.wikipedia.org/wiki/M%C3%A9todo\\_de\\_Runge-Kutta](https://es.wikipedia.org/wiki/M%C3%A9todo_de_Runge-Kutta)


4 En el Apéndice, describo la dinámica de transición del modelo SEIRD usada en una versión anterior del documento y, además, los resultados de estimación del modelo.

causa de la enfermedad;  $R_t$  es el grupo de personas que está en recuperación de la enfermedad;  $D_t$  representa el grupo de personas que murieron a causa de la enfermedad; y  $C_t$  representa el grupo de personas que lograron vencer a la enfermedad. Es decir:

$$N = S_t + I_t + R_t + D_t + C_t$$

La estructura de este modelo SIRD presenta la siguiente estructura:

**Diagrama 2: MODELO SIRD**



Fuente: Elaboración Propia

Una persona susceptible puede contraer la enfermedad al entrar en contacto con una persona infecciosa, que se supone que ocurre a una velocidad  $\beta_t I_t/N$ , donde  $\beta_t$  es una variable que varía con el tiempo. Este parámetro representa la velocidad de contacto. El valor inicial de  $\beta_t$ ,  $\beta_0$ , refleja cómo progresaría la infección si los individuos se comportaran como lo hacían antes de que llegara esta enfermedad. Se piensa en  $\beta_0$  como un parámetro que captura características de la enfermedad, atributos fijos de la región como la densidad y costumbres básicas en la región.

Con el tiempo,  $\beta_t$  varía según cuán fuerte sea el distanciamiento social y las prácticas higiénicas que se adopten en diferentes ubicaciones, ya sea por política o simplemente por cambios voluntarios en el comportamiento individual.

Como se puede ver, esta estructura modela la interacción mutua y dinámica de las personas entre cinco condiciones diferentes. La población susceptible (S), como se mencionó, es la población potencialmente vulnerable a la infección, la misma que puede pasar a formar parte de (I) que es el grupo de personas que son infecciosas, dado que se contagiaron por la enfermedad. Este grupo de personas, después de hacerse las pruebas, entra en el grupo (R) que, en este caso, representa a las personas que se encuentran en un periodo de recuperación que, en el anterior modelo, figurarían como los casos puestos en cuarentena. Según cómo evoluciona esta enfermedad en su salud, en el estado

de recuperación, este grupo de personas al final puede morir o recuperarse de la enfermedad. (D) representa la población que murió a causa de la pandemia y (C) representa la población que logró vencerla.

Las leyes de movimiento relacionadas con el virus son dadas por

$$\Delta S_{t+1} = -\beta_t S_t \frac{I_t}{N_t} \quad (1)$$

$$\Delta I_{t+1} = \beta_t S_t \frac{I_t}{N_t} - \gamma I_t \quad (2)$$

$$\Delta R_{t+1} = \gamma I_t - \theta R_t \quad (3)$$

$$\Delta D_{t+1} = \delta \theta R_t \quad (4)$$

$$\Delta C_{t+1} = (1 - \delta) \theta R_t \quad (5)$$

En este caso,  $\delta$  representa la tasa de letalidad de la enfermedad,  $\gamma$  representa el período de tiempo promedio en el que una persona es infecciosa antes de pasar a la etapa de recuperación.

A continuación, se explica cómo podemos recuperar  $\beta_t$  de las muertes registradas de una forma muy sencilla, sin tener que recurrir a métodos muy complejos, como proponen Fernández-Villaverde y Jones (2020).

Partimos de  $D_{t+1}$  que, en este caso, representa las muertes acumuladas a causa del virus. Hasta la fecha  $t + 1$ ;  $\Delta D_{t+1} = d_{t+1}$  es el número de personas que murieron en la fecha  $t + 1$ , es decir, son las muertes diarias registradas a causa del virus.

De la ecuación (4), dinámica del grupo de fallecidos, despejamos  $R_t$ ,

$$R_t = \frac{1}{\delta \theta} \Delta D_{t+1}$$

y como mencionamos que  $\Delta D_{t+1} = d_{t+1}$ , esto queda como

$$R_t = \frac{1}{\delta \theta} d_{t+1} \quad (6)$$

Aplicando diferencias se llega a la siguiente expresión

$$\Delta R_{t+1} = \frac{1}{\delta \theta} \Delta d_{t+2} \quad (7)$$

Ahora, usando la ecuación (3), dinámica del grupo de personas en recuperación, y las ecuaciones anteriores, despejamos  $I_t$

$$\Delta R_{t+1} = \gamma I_t - \theta R_t I_t = \frac{1}{\gamma} (\Delta R_{t+1} + \theta R_t) \quad (8)$$

$$I_t = \frac{1}{\gamma} \left( \frac{1}{\delta \theta} \Delta d_{t+2} + \frac{1}{\delta} d_{t+1} \right) \quad (9)$$

$$I_t = \frac{1}{\gamma \delta} \left( \frac{\Delta d_{t+2}}{\theta} + d_{t+1} \right) \quad (10)$$

Aplicando diferencias a esta última ecuación

$$\Delta I_{t+1} = \frac{1}{\gamma \delta} \left( \frac{\Delta d_{t+3}}{\theta} - \frac{\Delta d_{t+2}}{\theta} + \Delta d_{t+2} \right) \quad (11)$$

$$\Delta I_{t+1} = \frac{1}{\gamma \delta} \left( \frac{\Delta \Delta d_{t+3}}{\theta} + \Delta d_{t+2} \right) \quad (12)$$

Tomando el ratio entre las ecuaciones (10) y (12)

$$\frac{\Delta I_{t+1}}{I_t} = \frac{\frac{1}{\theta} \Delta \Delta d_{t+3} + \Delta d_{t+2}}{\frac{1}{\theta} \Delta d_{t+2} + d_{t+1}} \quad (13)$$

Ahora volviendo al modelo SIRD de la ecuación (2) dinámica infectados, y dividiendo por  $I_t$ . Es decir:

$$\Delta I_{t+1} = \beta_t \frac{S_t}{N} I_t - \gamma I_t //: \frac{1}{I_t}$$

Despejando  $\beta_t$

$$\beta_t = \frac{N}{S_t} \left( \frac{\Delta I_{t+1}}{I_t} + \gamma \right)$$

Y reemplazando la ecuación (13) en esta expresión llegamos a:

$$\beta_t = \frac{N}{S_t} \left( \gamma + \frac{\frac{1}{\theta} \Delta \Delta d_{t+3} + \Delta d_{t+2}}{\frac{1}{\theta} \Delta d_{t+2} + d_{t+1}} \right) \quad (14)$$

Esta expresión es muy importante, ya que nos ayuda a recuperar el parámetro  $\beta_t$ , pero, si nos fijamos, esta depende de  $S_t$  y, por lo tanto, ahora podemos usar la ecuación (1) y además la ecuación (10) para así encontrar la secuencia de  $S_{t+1}$  y con eso  $\beta_t$ . Es decir:

$$\Delta S_{t+1} = -\frac{\beta_t}{\gamma\delta} \frac{S_t}{N} \left( \frac{\Delta d_{t+2}}{\theta} + d_{t+1} \right) \quad (15)$$

o

$$S_{t+1} = S_t \left( 1 - \frac{\beta_t}{\gamma\delta N} \left( \frac{1}{\theta} \Delta d_{t+2} + d_{t+1} \right) \right) \quad (16)$$

Resumiendo, al final tendríamos dos ecuaciones esenciales

$$\beta_t = \frac{N}{S_t} \left( \gamma + \frac{\frac{1}{\theta} \Delta \Delta d_{t+3} + \Delta d_{t+2}}{\frac{1}{\theta} \Delta d_{t+2} + d_{t+1}} \right)$$

$$S_{t+1} = S_t \left( 1 - \frac{\beta_t}{\gamma\delta N} \left( \frac{1}{\theta} \Delta d_{t+2} + d_{t+1} \right) \right)$$

Con estas dos ecuaciones, si tenemos las series de tiempo de  $d_t$  y una condición inicial para  $S_0/N \approx 1$ , se puede iterar hacia adelante en el tiempo y con eso obtener  $\beta_t$  y además la serie  $S_{t+1}$ .

Como todo método, este puede tener una desventaja y es que, básicamente, esta metodología utiliza muertes futuras de los siguientes 3 días para informarnos sobre  $\beta_t$  hoy. Esto significa que las estimaciones se retrasarán tres días, pero aún con esta desventaja se puede generar una estimación informativa de  $\beta_t$ .

Además, hay muchos ejercicios que se pueden realizar con la  $\beta_t$  recuperada. Por ejemplo, podemos simular el modelo hacia adelante utilizando el valor más reciente de  $\beta_t$  y pronosticar el comportamiento de la infección bajo el comportamiento actual. Asimismo, podemos correlacionar después  $\beta_t$  con otros observables para evaluar la efectividad de ciertas políticas de un gobierno tales como cierres obligatorios. [Fernández-Villaverde y Jones, 2020, p. 9].

Además, con el  $\beta_t$ , Fernández-Villaverde y Jones (2020) determinan esta tasa de reproducción básica,  $\mathcal{R}_{0t} = \beta_t * 1/\gamma$  bajo el distanciamiento social actual y las prácticas de higiene. La forma de calcular este parámetro o tasa varía ampliamente en la literatura de acuerdo al modelo epidemiológico que se use.

También se debe tener cuidado de distinguir este número de reproducción básica del número de reproducción efectiva (es decir, el número promedio de nuevas infecciones causadas por un solo individuo infectado en el momento  $t$ ) que se denota por  $\mathcal{R}_{et}$ ; este último considera la fracción de la población que aún es susceptible, ya que:

$$\mathcal{R}_{et} = \frac{S_t \mathcal{R}_{0t}}{N}$$

En este caso, Fernández y Jones (2020) estarían cometiendo un error ya que están usando un modelo SIRD y la tasa de reproducción que proponen pertenece a un modelo SIR lo cual puede afectar la estimación de  $\mathcal{R}_{0t}$ . Revisando la literatura epidemiológica, el  $\mathcal{R}_{0t}$  que podemos usar para este tipo de modelos, según Chowell y Hyman (2016) y, además, el que usa Eichenbaum et al. (2020) es:

$$\mathcal{R}_{0t} = \frac{\beta_t}{\theta + \delta}$$

Como se puede notar, el procedimiento de Fernández-Villaverde y Jones (2020) también puede recuperar el número de reproducción efectivo. Lo interesante de esto es que no se lo trata como una constante como en otros documentos, sino que varía en el tiempo y, lo mencionado, nos permite capturar los cambios en el comportamiento de la sociedad y la política que ocurren en diferentes momentos y con diferentes intensidades.

### ***III.2. Modelando la economía con pandemia***

Hasta ahora, solo he hablado sobre cómo modelar la evolución de la pandemia de Covid-19. Por lo tanto, ahora tenemos que encontrar una manera eficiente de unir la parte económica y epidemiológica.

La crisis de la pandemia de Covid-19 ha motivado a muchos investigadores a encontrar formas de modelar el impacto de la pandemia de Covid-19 en la economía y el bienestar de la población, ya que es de vital importancia tener una idea del impacto que esto puede causar. Para este propósito y continuando con el modelado, nos basaremos en los trabajos de Eichenbaum et al. (2020) y Chumacero (2020). Como se mencionó anteriormente, estos autores proponen una forma muy práctica de modelar la pandemia en la economía.

Una pandemia en la economía tiene, por un lado, efectos en la demanda agregada y, por otro lado, efectos en la oferta agregada. Primero comenzaremos describiendo los hogares. Estos maximizan su función de utilidad que está sujeta a su nivel de consumo y horas trabajadas. En caso de



ausencia de pandemia, los hogares generalmente enfrentarían el siguiente problema:

$$\text{Max } U = \sum_{t=0}^{\infty} \beta^t u(c_t, n_t)$$

$$\text{s.a. } (1+\mu_t) c_t = w_t n_t + \Gamma_t$$

donde:

$\beta$  = Factor de Descuento

$c_t$  = Consumo de los hogares

$n_t$  = Horas trabajadas

$w_t$  = Tasa de salario real

$\mu_t$  = Impuesto al consumo también sirve como un instrumento de reducción para las interacciones sociales.

$\Gamma_t$  = Representan transferencias a los hogares por parte del gobierno.

A partir de ello, se obtienen las condiciones de primer orden del problema que enfrentan los hogares, asumiendo la siguiente función de utilidad  $u_t(c_t, n_t) = \ln c_t - \frac{\theta}{2} n_t^2$ :

$$\frac{\partial U_t}{\partial c_t} = \frac{\beta}{c_t} - (1+\mu) \lambda_t = 0$$

$$\frac{\partial U_t}{\partial n_t} = \beta \theta n_t + w_t \lambda_t = 0$$

$$c_t^{-1} w_t = \theta n_t (1+\mu_t)$$

Por otro lado, en la economía hay empresas competitivas que producen un solo bien para consumo  $C_t$ , lo que realizan en las horas trabajadas  $N_t$  con cierta tecnología  $A$ :

$$C_t = Y_t = AN_t$$

Por lo tanto, las empresas eligen la cantidad de horas de trabajo necesarias para maximizar sus ganancias  $\pi_t$ .

$$\pi_t = AN_t - w_t N_t$$

Finalmente, en esta economía con ausencia de pandemia, la restricción presupuestaria que enfrenta el gobierno está dada por:

$$\mu_t c_t = \Gamma_t$$

Para que la pandemia sea parte de esta economía, se caracterizaron las decisiones de las personas en tres grupos del paso anterior, que son las más relevantes para este modelo: los Susceptibles ( $S_t$ ), Recuperados ( $R_t$ )<sup>5</sup> y los Infectados ( $I_t$ ). La forma en que estos grupos interactúan en la economía caracteriza la forma en que se propaga el virus y cómo pueden afectar su bienestar, ya que cuando las personas buscan sus bienes de consumo o cuando tienen que trabajar, pueden tener contacto directo con las personas en uno de estos grupos. Es decir, la probabilidad de que una persona susceptible ( $S_t$ ) pueda infectar o infectarse ( $I_t$ ) dependerá de las actividades de consumo o trabajo. Por lo tanto, ahora describiré las funciones de utilidad de cada uno de los agentes o tipo de la economía actual.

Asumiremos que los tipos de agentes que están presentes en la economía conocen el número inicial de personas y también entienden cómo evoluciona la dinámica de la pandemia en su salud. En este caso, la restricción presupuestaria de cada agente depende del grupo al que pertenece en el período  $t$ , que viene dado por:

$$(1 + \mu_t) c_t^j = w_t \phi^j n_t^j + \Gamma_t$$

donde

$j = s, i, r$  que es el tipo de agente en la economía

$\phi^j =$  Productividad laboral, donde  $\phi^s = \phi^r = 1$  y  $\phi^i < 1$

### ***Personas Susceptibles***

En este grupo, las personas enfrentan la siguiente función objetivo de por vida

$$U_t^s = u(c_t^s, n_t^s) + \beta [(1 - \tau_t) U_{t+1}^s + \tau_t U_{t+1}^I]$$

donde la probabilidad de que una persona susceptible ( $S_t$ ) pueda infectarse está dada por  $\tau_t$ .

$$\tau_t = \pi_1 c_t^s (I_t C_t^I) + \pi_2 n_t^s (I_t N_t^I) + \pi_3 I_t$$

5 Para evitar confusiones de nomenclatura, en esta sección utilizo la letra ( $R_t$ ) para recuperados que en el modelo epidemiológico se caracterizaba por ( $C_t$ ).

En este caso,  $(I_t C_t^I)$  representa los gastos de consumo total de personas infectadas,  $(I_t N_t^I)$  representa el total de horas trabajadas por personas infectadas,  $\pi_1$  refleja tanto la cantidad de tiempo dedicado a las compras como la probabilidad de infectarse como resultado de esa actividad,  $\pi_2$  refleja la probabilidad de infectarse como resultado de interacciones laborales,  $\pi_3$  es el parámetro de velocidad de contacto, es decir,  $\pi_3 = \beta_t$  del modelo SIRD.

Las condiciones de primer orden son dadas por:

$$\frac{\partial U_t^s}{\partial c_t^s} = u^{(c_t^s, n_t^s)} - (1-\mu) \lambda_{bt}^s + \lambda_{rt} \pi_1 (I_t C_t^I) = 0$$

$$\frac{\partial U_t^s}{\partial n_t^s} = u'(c_t^s, n_t^s) + w_t \lambda_{bt}^s + \lambda_{rt} \pi_2 (I_t N_t^I) = 0$$

$$\frac{\partial U_t^s}{\partial \tau_t} = \beta (U_{t+1}^s + U_{t+1}^i) - \lambda_{rt} = 0$$

### ***Personas Infectadas***

Las personas que forman este grupo, en un momento determinado, enfrentarán la siguiente función de utilidad de por vida:

$$U_t^i = u(c_t^i, n_t^i) + \beta [(1 - \pi_r - \pi_d) U_{t+1}^i + \pi_r U_{t+1}^r]$$

donde  $\pi_r$  es la velocidad a la que las personas se recuperan, lo cual, bajo el modelo SIRD es  $\pi_r = \theta$ , y  $\pi_d$  representa la tasa de mortalidad, es decir  $\pi_d = \delta$ .

Y sus condiciones de primer orden son:

$$\frac{\partial U_t^i}{\partial c_t^i} = u'(c_t^i, n_t^i) - (1+\mu) \lambda_{bt}^i = 0$$

$$\frac{\partial U_t^i}{\partial n_t^i} = u'(c_t^i, n_t^i) + \phi^i w_t \lambda_{bt}^i = 0$$

### ***Personas Recuperadas***

Finalmente, las personas que van a pasar la infección y se recuperarán adquieren cierta inmunidad, ya que las características del modelo epidémico bajo el modelo generalizado SEIRD o SIRD nos permiten asumir esto. Por lo tanto, las personas recuperadas enfrentarán la siguiente función de utilidad:

$$U_t^r = u(c_t^r, n_t^r) + \beta U_{t+1}^r$$

donde las condiciones de primer orden son:

$$\frac{\partial U_t^r}{\partial c_t^r} = u'(c_t^r, n_t^r) - (1+\mu) \lambda_{bt}^r = 0$$

$$\frac{\partial U_t^r}{\partial n_t^r} = u'(c_t^r, n_t^r) + w_t \lambda_{bt}^r = 0$$

Finalmente, la restricción presupuestaria del gobierno, bajo esta economía con pandemia, ahora se describe de la siguiente manera:

$$\mu_t (S_t C_t^s + I_t C_t^i + R_t C_t^r) = \Gamma_t (S_t + I_t + R_t)$$

En equilibrio, cada persona o tipo de persona, resuelve su problema de maximización, logrando el cumplimiento de la restricción anterior, y el mercado de bienes y trabajo se vacía. Es decir:

$$S_t C_t^s + I_t C_t^i + R_t C_t^r = AN_t$$

$$S_t N_t^s + I_t N_t^i \phi^i + R_t N_t^r = N_t$$

#### IV. Estimación y resultados

Para la simulación y estimación de los pasos anteriores de modelación, primero debemos hacer una calibración acorde a algunos parámetros. Como muchas investigaciones sugieren, algunos de los parámetros son principalmente biológicos y, por lo tanto, fijos en el tiempo. Estos se pueden extraer de los reportes epidemiológicos u otros informes.

##### *Para el caso boliviano:*

$\theta$  representa el período de tiempo promedio que toma para que un caso pueda resolverse, después de terminado el período infeccioso. Según la *WHO* (2020) a partir de datos de China, aproximadamente a los pacientes de Covid-19 les lleva, en promedio, dos semanas recuperarse de la enfermedad. Esto también es consistente en el caso boliviano, ya que según doctores que atienden esta enfermedad en Bolivia, algunos casos llevan aproximadamente 5 días si la persona se encuentra en un estado adecuado de salud (mayormente jóvenes), y de 30 a 45 días si la persona padece de alguna enfermedad o es de edad avanzada. Por lo tanto, tomaremos 20 días como el promedio de recuperación, por lo que  $\theta = 0,05$


$\gamma$ , representa el período de tiempo promedio en el que una persona es infecciosa, antes de pasar a la etapa de recuperación. Según el Ministerio de Salud de Bolivia (2020), este periodo de tiempo es de aproximadamente 7 días, por lo que  $\gamma = 0,15$ . Este valor es consistente con datos e informes de otros países.

$\delta$ , representa la tasa de letalidad debido al Covid-19. A la fecha en que se escribe el documento, la tasa de letalidad ha disminuido en países de América

del Sur. Según el Ministerio de Salud de Bolivia hay, en promedio, 50 fallecidos por día, lo que muestra una tasa de letalidad por día de 4,2% a nivel nacional, por lo que  $\delta = 0,042$  para nuestro caso<sup>6</sup>.

Para la estimación del parámetro  $\beta_t$ , como se mencionó antes, necesitamos la serie de las muertes diarias. Para el caso boliviano, estos datos fueron recopilados de los informes y reportes diarios del Ministerio de Salud de Bolivia. Para trabajar con esta serie, se realizó un suavizado con un filtro HP ( $\alpha = 200$ ) como señalan Fernández-Villaverde y Jones (2020). Esto se hace debido al ruido que presenta la serie original (ver Gráfico 1).

**Gráfico 1: MUERTES DIARIAS POR COVID-19 BOLIVIA**




Fuente: Elaboración propia en base a los reportes diarios del Ministerio de Salud de Bolivia

Con esta serie de datos, más una condición inicial de  $S_t/N = 1$  y el valor de los parámetros, procedimos a estimar la evolución de la pandemia<sup>7</sup> y rescatamos los valores de  $\mathcal{R}_{0t}$  y  $\mathcal{R}_{et}$ , véase el Gráfico 2.

6 Algunos sugieren que los datos de fallecidos pueden estar sub-reportados. En el Apéndice C se hace un ejercicio de simulación considerando esta posibilidad.

7 Véase el Apéndice B para los demás gráficos.

## Gráfico 2: TASA DE REPRODUCCIÓN

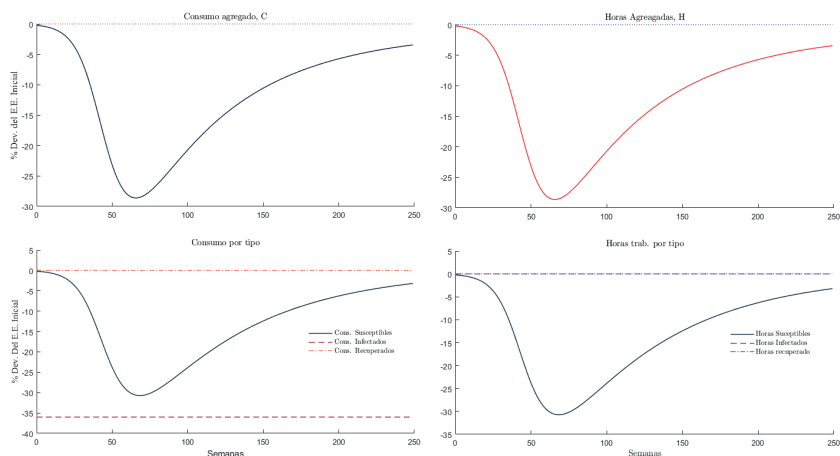


Fuente: Elaboración propia en base a los resultados e información disponible

Para el modelo económico, dado que ya contamos con algunos parámetros, solo nos queda aclarar algunos parámetros que juegan un papel inicial. Como  $\beta$ , es una serie, para el modelo procedimos a sacar un promedio de la serie y usar ese valor como parámetro que refleja la tasa de contagio de la enfermedad. Para los demás parámetros  $\pi_1$  y  $\pi_2$  utilizamos la metodología de Eichenbaum et al. (2020). Ellos señalan que, en el caso de una influenza, el 30% de las transmisiones ocurren en el hogar, el 33% en la comunidad general y el 37% ocurre en las escuelas y los lugares de trabajo. Los parámetros  $\pi_1$  y  $\pi_2$  se determinan tomando en cuenta que el parámetro  $\pi_3 = \beta$ . Además, para la productividad de las personas, utilizamos un valor de 0,80 como la mayoría de los autores sugieren para este tipo de modelos, dado que la productividad de una persona infectada cae. El factor de descuento de los hogares  $\beta$  para la economía boliviana se encuentra en torno a 0,98<sup>8</sup>. La población inicial se normaliza a uno; se considera que el número de personas que están inicialmente infectadas es de 0,00005 (considerando una población de 11 millones). Para las simulaciones se toma que, en promedio, las horas trabajadas en una semana son 48 con un ingreso semanal de 69,30 dólares semanales, según datos del Instituto Nacional de Estadística (INE) y del Banco Mundial (BM). Se realizaron simulaciones para un periodo de 250 semanas. Los resultados se muestran en el siguiente gráfico.

8 Puede que en tiempos de pandemia este valor tienda a disminuir debido a que los agentes tienden a des-acumular sus ahorros para sobrevivir, pero también en tiempos de alta incertidumbre las personas tienden a ahorrar más valorando el futuro.

### Gráfico 3: IMPACTO DEL COVID-19 EN LA ECONOMÍA BOLIVIANA



Fuente: Elaboración propia

El Gráfico 3 muestra que la pandemia induce una recesión: el consumo agregado de la economía boliviana caería en consonancia con estas observaciones; la recesión es mucho más grave; el consumo agregado, en promedio, en el primer año de la pandemia, cae alrededor de 7,27 por ciento y la recuperación de la economía empieza, aproximadamente, a partir de la semana 64 pero, como se puede ver, la recuperación es lenta en el tiempo. Se puede considerar que los resultados encontrados son, de alguna manera, consistentes con lo que muchos analistas prevén para este año y, además, con lo que señalan los autores en estos temas. Es decir, en economías que tienden a usar políticas de confinamiento, el efecto es muy negativo en su economía y su recuperación es lenta en el tiempo. A cambio, sin embargo, se logra disminuir la letalidad de la enfermedad. Por razones similares, la dinámica y la magnitud de la caída en horas de trabajo son similares: las horas trabajadas disminuyen suavemente.

También se procedió a hacer las mismas simulaciones con los parámetros de un modelo SEIRD-G y un caso de sub-registro de fallecidos. Los resultados son similares para el caso de sub-registros. En el caso del modelo SEIRD, pese a que replica de buena manera el comportamiento de los casos confirmados, en el modelo económico nos entrega resultados nada creíbles ni lógicos. Se invita al lector revisar el apéndice del documento.

## V. Conclusiones

Se utiliza un modelo SIRD para estudiar las interacciones de los diferentes grupos dentro de una enfermedad. A partir de este modelo pudimos recuperar un parámetro de gran interés con la metodología de Fernández-Villaverde y Jones (2020). Bajo esta metodología los resultados muestran una estimación confiable respecto al comportamiento de la enfermedad.

La pandemia, dentro del modelo de equilibrio general utilizado, genera efectos tanto en oferta como en demanda de la actividad económica. Estos efectos trabajan en conjunto para generar una recesión grande y persistente.

El mensaje es claro e irrefutable: las decisiones de las autoridades del gobierno durante la gestión 2020 tuvieron un impacto negativo en la economía, ocasionando una posible caída de 7,27% del consumo agregado para el primer año. Pero es necesario aclarar que estas medidas también lograron disminuir la letalidad de la enfermedad, ya que es evidente que el sistema de salud en Bolivia aún no estaba preparado para esta pandemia. La recuperación de la economía, como se puede evidenciar, será lenta debido a los efectos del distanciamiento social.

Como bien se sabe, existe un inevitable *trade-off* entre la gravedad de la recesión a corto plazo causada por la pandemia y las consecuencias para la salud de la misma. Hacer frente a este *trade-off* es un desafío clave al que se enfrentan los responsables de la formulación de políticas. Por consiguiente, se les recomienda actuar de una manera inteligente para hacer frente a esta pandemia y evaluar estrategias eficientes para la reactivación de la economía boliviana a mediano plazo con el fin de disminuir los efectos negativos que se generen tanto en lo económico como en la salud.



## Referencias bibliográficas:

ATKESON, A. (2020). "What Will Be the Economic Impact of Covid-19 in the US? Rough Estimates of Disease Scenarios" National Bureau of Economic Research, Working Paper No. 26867, March

CHEYNET, E. (2020). "Generalized SEIR Epidemic Model (fitting and computation)". Available at <https://www.github.com/ECheynet/SEIR>, GitHub. Retrieved on May 11, 2020

CHOWELL, G. and J. M. HYMAN (2016). *Mathematical and Statistical Modeling for Emerging and Re-emerging Infectious Diseases*, Springer International Publishing, Switzerland

CHUMACERO, R. A. (2020). "Dealing with the Coronavirus: Some Back of the Envelope Calculations" Universidad de Chile, manuscript, March

COCHRANE, J. (2020). "Corona virus monetary policy" in *The Grumpy Economist* blog, Tuesday, March 3. Available at <https://johnhcochrane.blogspot.com/2020/03/corona-virus-monetary-policy.html>

EICHENBAUM, M. S., S. REBELO, M. TRABANDT (2020). "The macroeconomics of epidemics" National Bureau of Economic Research, Working Paper No. 26882, March

FERNÁNDEZ-VILLAVERDE, J. and C. I. JONES (2020). "Estimating and Simulating a SIRD Model of Covid-19 for Many Countries, States, and Cities" Stanford Institute for Economic Policy Research, Working Paper No. 20-027, June

GODIO, A., F. PACE, A. VERGNANO (2020). "SEIR Modeling of the Italian Epidemic of SARS-CoV-2 Using Computational Swarm Intelligence" *International Journal of Environmental Research and Public Health*, 17 (10), 3535, May

KERMACK, W. O. and A. G. MCKENDRICK (1927). "A contribution to the mathematical theory of epidemics" *Proceedings of the Royal Society A – Mathematical, Physical and Engineering Sciences*, 115 (772), pp. 700 - 721

MARTCHEVA, M. (2015). *An Introduction to Mathematical Epidemiology*, Springer Science+Business Media LLC, New York

McKIBBIN, W. and R. FERNANDO (2020). "The Global Macroeconomic Impacts of Covid-19: Seven Scenarios" Australian National University, Centre for Applied Macroeconomic Analysis, Working Paper 19/2020, February

MINISTERIO DE SALUD DE BOLIVIA (2020). “Guía y lineamientos de manejo Covid-19”, Serie Documentos técnicos normativos, abril

PENG, L., W. YANG, D. ZHANG, C. ZHUGE, L. HONG (2020). “Epidemic analysis of Covid-19 in China by dynamical modeling Epidemiology” arXiv preprint, arXiv:2002.06563

WORLD HEALTH ORGANIZATION - WHO (2020). “Report of the WHO-China Joint Mission on Coronavirus Disease 2019 (COVID-19)”. Available at <https://www.who.int/docs/default-source/coronaviruse/who-china-joint-mission-on-covid-19-final-report.pdf>

## APÉNDICES

### Apéndice A: Modelo SEIRD Generalizado

El modelo presenta los siguientes parámetros:  $\beta$  (tasa de infección) que controla la velocidad con la que las personas pasan de ser susceptibles a la exposición;  $\gamma$  (tasa de incubación) es la tasa a la que pasan las personas que estaban en el grupo expuesto, después de cierto tiempo, al grupo de personas infectadas donde los síntomas son más notables. Otro parámetro,  $\delta$ , controla la rapidez con que las personas se recuperan de la infección.

La razón por la que se pensó en un modelo SEIRD contra un modelo SIR, se debe a las características reportadas del virus Covid-19. Primero, una persona que es susceptible al virus puede contraer la enfermedad, pero esto no lo sabe. Por lo tanto, se convierte en parte de la población expuesta. Según los informes de la OMS<sup>9</sup>, el período de incubación del virus dura 5 días en promedio. Una vez que aparecen los síntomas, un individuo pasa al grupo de infectados. En este punto, según su estado de enfermedad, el individuo se convierte en parte del grupo en cuarentena y, finalmente, dependiendo de cómo evoluciona, el paciente puede recuperarse o morir. Por lo tanto, como se observó, trabajar con este tipo de modelo nos permite capturar mejor la realidad de las etapas del Covid-19.

Habiendo dicho todo lo anterior, trabajar en un modelo SEIRD generalizado puede ser un poco más complejo, pero genera mejores estimaciones ya que funciona con más parámetros que los modelos SEIR y SIR clásico, según Godio et al. (2020). Los parámetros que son indeterminados, en un modelo SEIRD generalizado, representan las siguientes medidas:

- $\beta$  es la tasa de infección.
- $\gamma$  es el inverso del tiempo latente promedio.
- $\delta$  es el inverso del tiempo de cuarentena promedio.
- $\lambda_0$  y  $\lambda_1$  son coeficientes utilizados en la tasa de recuperación dependiente del tiempo.
- $\kappa_0$  y  $\kappa_1$  son coeficientes utilizados en la tasa de mortalidad dependiente del tiempo.

9 <https://www.who.int/es>

Tenga en cuenta que  $\lambda$  y  $\kappa$ , la tasa de curación y la tasa de mortalidad, respectivamente, se consideran dependientes del tiempo para mejorar la capacidad del modelo y seguir la evolución del brote.

Según los resultados observados en el artículo de Peng et al. (2020), estos sugieren una evolución exponencial de los dos parámetros. Para el presente documento se utiliza una tendencia exponencial para la tasa de mortalidad  $\kappa(t)$  modelándola como:

$$\kappa(t) = \kappa_0 \exp(-\kappa_1 t)$$

La tasa de recuperación  $\lambda(t)$  es modelada como:

$$\lambda(t) = \frac{\lambda_0}{1 + \exp(-\lambda(t-\tau))} \text{ o como } \lambda(t) = \lambda_0 + \exp(-\lambda_1(t+\tau))$$

La idea detrás de estas funciones es que la tasa de mortalidad debe acercarse a cero a medida que aumenta el tiempo, mientras que la tasa de recuperación converge hacia un valor constante  $\lambda_0$ .

El parámetro  $\lambda_0$  representa el valor inicial de la tasa de recuperación, que es la tasa a la que un individuo infeccioso promedio puede recuperarse. Si lo analizamos, este parámetro está relacionado con la capacidad inicial del sistema de salud para hacer frente a la infección y también depende de otros factores, como la buena salud que pueda tener la población.  $\lambda_1$  mide cómo la tasa ha cambiado con el tiempo. Dadas las propiedades de la función lambda, si  $\lambda_1$  resulta positivo, la tasa de recuperación mejorará con el tiempo y cuanto mayor sea, mejor será la recuperación para los pacientes infectados en cuarentena.

Por lo tanto, habiendo dicho todo esto, la descripción matemática del modelo SEIRD generalizado del diagrama ya visto es la siguiente:

$$\frac{dS(t)}{dt} = -\beta S(t) \frac{I(t)}{N} - \alpha S(t)$$

$$\frac{dE(t)}{dt} = \beta \frac{S(t)I(t)}{N} - \gamma E(t)$$

$$\frac{dI(t)}{dt} = \gamma E(t) - \delta I(t)$$

$$\frac{dQ(t)}{dt} = \delta I(t) - \lambda(t) Q(t) - \kappa(t) Q(t)$$

$$\frac{dR(t)}{dt} = \lambda(t)Q(t)$$

$$\frac{dD(t)}{dt} = \kappa(t)Q(t)$$


$$\frac{dP(t)}{dt} = \alpha S(t)$$

donde los principales resultados del modelo son los siguientes datos:

- S: Serie de tiempo de casos susceptibles,
- E: Serie de tiempo de los casos expuestos,
- I: Serie de tiempo de casos infecciosos,
- Q: Serie de tiempo de los casos en cuarentena,
- R: Serie de tiempo de los casos recuperados,
- D: Serie de tiempo de los casos de muerte,
- P: Serie de tiempo de los casos susceptibles.

Por lo tanto, los parámetros  $\alpha$ ,  $\beta$ ,  $\gamma$ ,  $\delta$ ,  $\lambda$  y  $\kappa$  son las incógnitas del modelo SEIRD. Por lo tanto, lo que se pretende, en primera instancia, es obtener los parámetros de una manera óptima. Los resultados de esta estimación se muestran a continuación en el Gráfico A.1, donde cada línea representa una simulación por cada día que se actualizan los datos de infectados, siendo la línea azul la simulación de la infección con los parámetros estimados con datos de infectos hasta el 31 de julio,

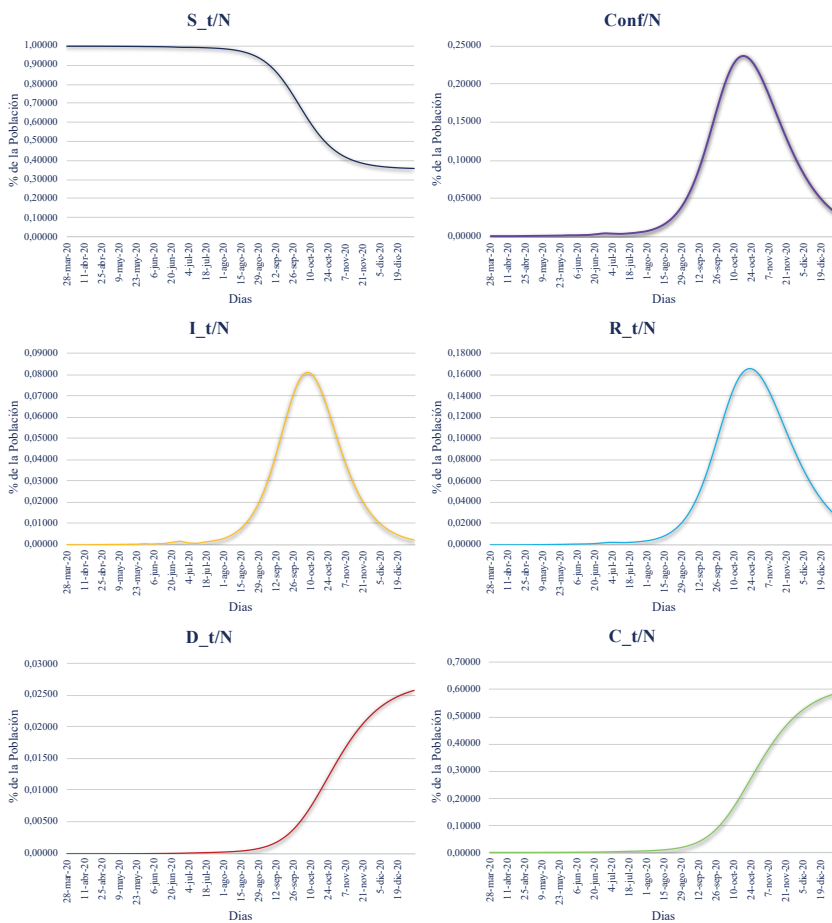
### Gráfico A.1: EVOLUCIÓN DEL COVID-19 BOLIVIA-SEIRD G



Fuente: Elaboración propia

## Apéndice B: Evolución de la pandemia Modelo SIRD

### Gráfico B.1: EVOLUCIÓN DE LA PANDEMIA



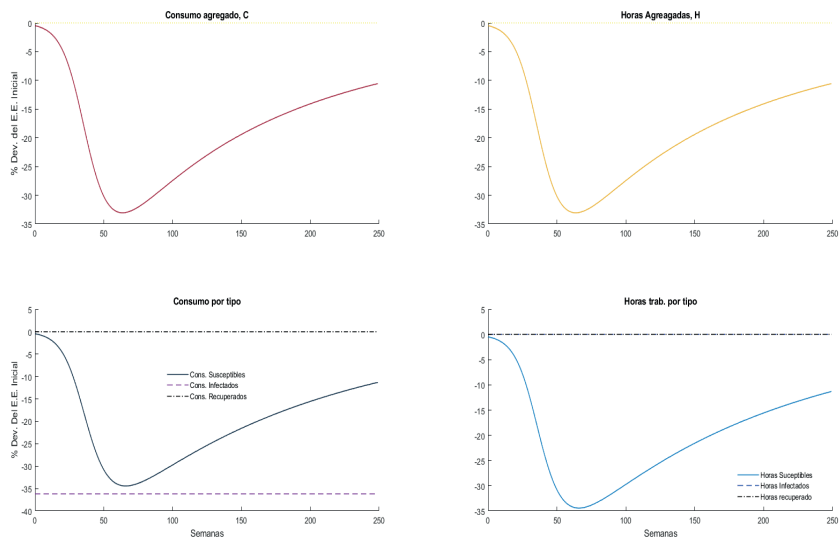
Fuente: Elaboración propia

## Apéndice C: Caso de subregistro de datos de fallecidos

Se tuvo que elaborar un caso ante los posibles sub-registros de los datos de fallecidos, dado que muchas familias tienden a ocultar la información o prefieren atenderse en casa, o morir, ante un colapso de hospitales y, posiblemente, puede que existan fallecidos que no hayan sido registrados. Ante este hecho, se procedió a trabajar con una tasa de letalidad del doble de la que se tiene. Es decir, en vez de usar una tasa del 4,2% utilizamos una de 8,4%. Los resultados fueron los siguientes:

### Gráfico C.1: IMPACTO DEL COVID-19 EN LA ECONOMÍA BOLIVIANA

La evolución de COVID-19 en Bolivia  
Casos sub-reportados



Fuente: Elaboración propia

Bajo este posible caso, la pandemia induce a una recesión mucho más fuerte y profunda que la que se presenta con los datos. En este caso, el consumo agregado, en promedio, en el primer año de la pandemia, caería alrededor de 11,66 por ciento y la recuperación de la economía empezaría a partir de la semana 66, aproximadamente. Pero, como se puede evidenciar en este caso, la recuperación es mucho más lenta que en el caso anterior y ni siquiera 250 semanas alcanzan para que la economía vuelva a su estado inicial.



# **Modelos de *Machine Learning* para el análisis y pronóstico de la situación financiera de bancos – Caso boliviano**

**Jonnathan R. Cáceres Santos**

## **Resumen**

Con el objeto de analizar y pronosticar el comportamiento financiero de los principales bancos de Bolivia (período enero 2001 a febrero 2020), se estimaron modelos de *machine learning*: redes neuronales supervisadas, redes neuronales no supervisadas y máquinas de vectores de soporte. Los resultados obtenidos destacan la precisión del 99% alcanzada por el modelo de redes neuronales supervisadas y la coincidente clasificación del modelo de redes neuronales no supervisadas. El modelo de máquinas de vectores de soporte alcanzó una precisión de 85,1%. Los modelos propuestos se constituyen en herramientas robustas para el análisis y pronóstico de riesgos financieros, puesto que tienen la capacidad de abstraer patrones recurrentes y generalizar información no observada. Asimismo, evidencian su importancia para el diseño, propuesta y la evaluación de políticas macroprudenciales orientadas a preservar la estabilidad financiera.

**Clasificación JEL:** C45, C53

**Palabras clave:** Predicción, redes neuronales

# Modelos de *Machine Learning* para el análisis y pronóstico de la situación financiera de bancos – Caso boliviano\*

Jonnathan R. Cáceres Santos\*\*

## RESUMEN

Con el objeto de analizar y pronosticar el comportamiento financiero de los principales bancos de Bolivia (período enero 2001 a febrero 2020), se estimaron modelos de *machine learning*: redes neuronales supervisadas, redes neuronales no supervisadas y máquinas de vectores de soporte. Los resultados obtenidos destacan la precisión del 99% alcanzada por el modelo de redes neuronales supervisadas y la coincidente clasificación del modelo de redes neuronales no supervisadas. El modelo de máquinas de vectores de soporte alcanzó una precisión de 85,1%. Los modelos propuestos se constituyen en herramientas robustas para el análisis y pronóstico de riesgos financieros, puesto que tienen la capacidad de abstraer patrones recurrentes y generalizar información no observada. Asimismo, evidencian su importancia para el diseño, propuesta y la evaluación de políticas macroprudenciales orientadas a preservar la estabilidad financiera.

**Clasificación JEL:** C45, C53

**Palabras clave:** Predicción, redes neuronales

---

\* El contenido del presente documento es de responsabilidad del autor y no compromete la opinión del Banco Central de Bolivia.

\*\* Correos electrónicos del autor: jcaceres@bcb.gob.bo, jonnathan.caceres@gmail.com.

# Machine Learning models for the analysis and forecast of the financial situation of banks - Bolivian Case\*

Jonnathan R. Cáceres Santos\*\*

## ABSTRACT

In order to analyze and forecast the financial behavior of the major banks in Bolivia (period January 2001 to February 2020), machine learning models were estimated: supervised neural networks, unsupervised neural networks and support vector machines. Obtained results highlight the 99% precision achieved by the supervised neural network model and the coincident classification of the unsupervised neural network model. The support vector machine model achieved an accuracy of 85.1%. The proposed models are robust tools for financial risk analysis and forecasting since they have the ability to abstract recurring patterns and generalize unobserved information. Likewise, they highlight their importance for the design, proposal and evaluation of macroprudential policies aimed at preserving financial stability.

**JEL Classification:** C45, C53

**Keywords:** Prediction, neural networks

---

\* The conclusions, opinions and points of view expressed in this document do not necessarily represent those of the Central Bank of Bolivia or its authorities and are the sole responsibility of the author.

\*\* Contact: [jcaceres@bcb.gob.bo](mailto:jcaceres@bcb.gob.bo), [jonnathan.caceres@gmail.com](mailto:jonnathan.caceres@gmail.com).

## I. Introducción

La estabilidad financiera es una situación en la que el sistema financiero canaliza eficientemente ahorros desde oferentes de recursos hacia emprendedores e inversionistas y donde el sistema de pagos nacional opera de forma segura y eficiente (Banco Central de Bolivia, 2020).

En este contexto, la actividad de intermediación financiera resulta vital para promover el desarrollo financiero y el crecimiento de largo plazo de las economías (Minsky, 1992; Levine et al., 2000). Asimismo, existe un consenso generalizado sobre los efectos negativos que conllevan las fragilidades financieras de las entidades bancarias sobre la estabilidad macroeconómica (Tymoigne, 2011).

Por su parte, los sistemas de pago de alto valor cumplen un papel importante en la fluidez y asignación de recursos líquidos en los sistemas financieros. La constante y heterogénea interacción de los bancos en estas infraestructuras crea una serie de interdependencias que repercuten sobre sus posiciones de liquidez (Cáceres y Aldazosa, 2013).

Los orígenes complejos y consecuencias ampliadas de la última crisis financiera han motivado la implementación de técnicas cuantitativas basadas en la identificación de patrones con el objeto de pronosticar deterioros y quiebras de entidades bancarias (Devi y Radhika, 2018). El volumen de información generado en los mercados financieros y las técnicas de inteligencia artificial incorporadas en *Machine Learning* (ML) ofrecen oportunidades concretas para el análisis de fenómenos financieros desde nuevas perspectivas.

En Bolivia, los bancos registraron un crecimiento sostenido en los períodos recientes, lo cual se tradujo en una expansión del ahorro y crédito. Asimismo, la cobertura geográfica fue ampliándose conforme las disposiciones del marco regulatorio vigente. En este sentido, la evidencia empírica señala una relación positiva y moderada entre variables que miden el desarrollo del sistema financiero y el crecimiento económico en Bolivia (Díaz y Rocabado, 2016) (Humérez y Yáñez, 2011).

Coherente con el desempeño del sistema financiero boliviano, el sistema de pagos también tuvo cambios importantes producto de su modernización. Prueba de ello es la interconexión de la totalidad de las entidades financieras reguladas, lo que representó un cambio en la dinámica de las transferencias de dinero y servicios de pago.

Los estudios científicos orientados a analizar (modelar) formalmente las condiciones y/o el desempeño financiero de las entidades bancarias en Bolivia

son escasos. Este aspecto, además de los citados anteriormente, se suma como elemento de motivación para la realización del presente documento.

El objetivo de este estudio es analizar y pronosticar el comportamiento financiero de los cuatro principales bancos de Bolivia a través de técnicas de ML para el período comprendido entre enero de 2001 y febrero de 2020.

Después de esta introducción, en la segunda parte de este documento, se desarrolla una revisión teórica y, posteriormente, una descripción de la información empleada. En la cuarta parte, se presenta la metodología y descripción formal de los modelos ML utilizados en este estudio. En la quinta parte, se presentan los principales resultados. Finalmente, se plantean las conclusiones y consideraciones de cierre.

## II. Revisión teórica

La creciente complejidad de los sistemas financieros exige el uso de técnicas cuantitativas robustas para el análisis de riesgos y la consecuente toma de decisiones por parte de las autoridades encargadas de preservar la estabilidad financiera.

Los métodos de ML<sup>1</sup> han ido ganando preponderancia en el estudio de fenómenos económicos y financieros debido a las grandes cantidades de información que se generan en los mercados. En este sentido, el estudio de riesgos con implicaciones sistémicas, a los cuales están expuestos los sistemas financieros, es apoyado por métodos de ML con el objeto de obtener una mejor comprensión de los fenómenos presentes en este ámbito (Kou et al., 2019).

Entre los métodos de ML, utilizados frecuentemente para estudios de predicción de situaciones de bancarrota de entidades bancarias, destacan las Redes Neuronales Artificiales (*Artificial Neural Networks*, ANN) y las Máquinas de Vectores de Soporte (*Support Vector Machine*, SVM).

Por ejemplo, Devi y Radhika (2018) efectúan una revisión de un conjunto de técnicas ML para el pronóstico de quiebra financiera. Asimismo, concluyen que estas técnicas proporcionan una mayor precisión de predicción que las técnicas estadísticas tradicionales.

En la misma línea, López y Pastor (2015) emplearon un modelo híbrido de ANN (mapas auto-organizados y perceptrón multicapa) para estimar la probabilidad de bancarrota de 52 entidades bancarias en Estados Unidos en el contexto de

---

<sup>1</sup> Según Shalev-Shwartz y Ben-David (2014) el término *Machine Learning* está asociado a la detección automática y precisa de patrones de comportamiento provenientes de un conjunto de datos.

la última crisis financiera. Este modelo mostró una capacidad predictiva, para un horizonte de un año, de 96%.

En 2013, Papadimitriou et al. propusieron un modelo de pronóstico de SVM aplicado a 300 bancos de Estados Unidos. A través de un procedimiento para la optimización de selección de muestra, consideraron 37 variables financieras y 4 períodos de rezago. Los resultados del pronóstico mostraron una precisión cercana al 92%.

Por su parte, Li et al. (2013) también propusieron un modelo de SVM para predecir los niveles de riesgo sistémico del sistema bancario chino. Para ello, emplearon información de frecuencia trimestral desde 2004 a 2008. Asimismo, concluyeron que la técnica propuesta tiene una mayor precisión que los modelos de ANN supervisado, análisis múltiple discriminante y regresión logística.

Una técnica híbrida de componentes principales y ANN fue propuesta por Vasu y Ravi (2011) para validar la situación de bancarota de 166 bancos de Turquía, España y Reino Unido. Para el caso de los bancos españoles, la precisión alcanzada es de 100%; para los bancos ingleses, de 90%.

Pineda y Piñeros (2009) proponen un indicador financiero que resume, evalúa y organiza jerárquicamente el desempeño de los establecimientos de crédito para Colombia, y establecen un sistema de alertas tempranas de crisis financiera.

Para el caso boliviano, Cáceres y Palacios (2011) proponen un indicador global de desempeño financiero, con base en un modelo de ANN supervisado (perceptrón multicapa) que, a diferencia de los estudios antes citados, trata de estimar la condición financiera de las entidades financieras. Los resultados hallados muestran una alta coherencia con los diferentes episodios del contexto económico.

### **III. Datos**

La información proviene de los estados financieros de los cuatro principales bancos de Bolivia (publicados por la Autoridad de Supervisión del Sistema Financiero) y de la base de datos del Banco Central de Bolivia. Los parámetros analizados comprenden: calidad de activos, eficiencia administrativa, cobertura de depósitos, solvencia y rentabilidad. Asimismo, se incorporó un parámetro de liquidez vinculado a la participación de los bancos en el sistema de pagos de alto valor a través del ratio financiero (excedente de encaje legal / encaje legal constituido).

Las observaciones son de frecuencia mensual y el período de tiempo considerado es de enero de 2001 a febrero de 2020 (231 observaciones). A continuación, se presentan los parámetros considerados, los ratios financieros (variables) y sus respectivos estadísticos:

**Cuadro 1: DESCRIPCIÓN DE VARIABLES Y MEDIDAS ESTADÍSTICAS**

Área de evaluación Ratio financiero	Mín. / Máx.	Promedio	Mediana	Desviación estándar	Coefficiente de variación	Curtosis	Asimetría
<b>Calidad de activos</b> R1=(Cartera en mora + Cartera reprogramada vigente / Cartera bruta)	0,03 / 0,43	0,12	0,07	0,12	0,93	0,60	1,30
<b>Eficiencia administrativa</b> R2= (Gastos administrativos / Margen financiero)	0,66 / 1,13	0,85	0,86	0,11	0,13	2,80	0,43
<b>Cobertura de depósitos</b> R3= (Disponibilidades + Inversiones temporarias / Obligaciones con el público)	0,28 / 0,65	0,43	0,44	0,09	0,20	-0,53	0,40
<b>Solvencia</b> R4= (Cartera en mora - Previsiones / Patrimonio)	-0,10 / 0,53	0,05	-0,06	0,19	3,95	2,89	1,31
<b>Liquidez (sistema de pagos)</b> R5= (Excedente de encaje legal / Encaje legal constituido)	-0,08 / 0,93	0,50	0,52	0,18	0,36	0,61	-0,15
<b>Rentabilidad</b> R6 = (Utilidad Neta / Patrimonio)	-0,06 / 0,26	0,11	0,12	0,07	0,63	-2,67	-0,26

Fuente: Elaboración propia con datos de ASFI y BCB

Mediante el coeficiente de correlación de Pearson, se estableció el grado de asociación lineal entre variables. Esta medida estadística es presentada en el siguiente cuadro y la visualización gráfica en el Apéndice A:

**Cuadro 2: MATRIZ DE CORRELACIÓN DE VARIABLES**

	R1	R2	R3	R4	R5	R6
R1	1,0000	0,1383	-0,2421	0,5889	-0,4554	-0,2840
R2	0,1383	1,0000	0,5644	-0,3935	0,2076	0,2165
R3	-0,2421	0,5644	1,0000	-0,7517	0,4492	0,7888
R4	0,5889	-0,3935	-0,7517	1,0000	-0,5805	-0,7432
R5	-0,4554	0,2076	0,4492	-0,5805	1,0000	0,3400
R6	-0,2840	0,2165	0,7888	-0,7432	0,3400	1,0000

Fuente: Elaboración propia con datos de ASFI y BCB

#### IV. Metodología

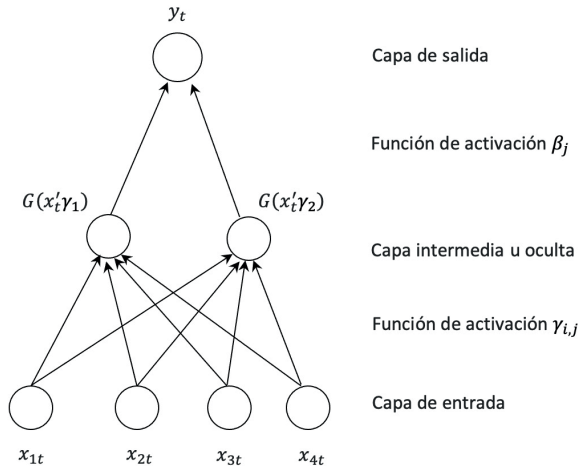
##### Modelo ANN de aprendizaje supervisado – *Backpropagation*

Los modelos de ANN forman parte de la inteligencia artificial. Son una simulación de las propiedades observadas en los sistemas neuronales biológicos y recreados a través de modelos matemáticos y mecanismos artificiales.

Un modelo de ANN puede ser interpretado como una regresión no lineal, de tipo entrada – salida (*input – target*) y cuya construcción se basa en combinaciones de funciones no lineales básicas a través de una estructura multicapa (Kuan y Liu, 1995). Estos elementos posibilitan el modelado de relaciones no lineales y efectos asimétricos entre una variable dependiente (*target*)  $y_i$ , y un vector de variables independientes (*inputs*)  $x_i'$ , donde  $x_i'$  es un vector conformado por  $(x_{1i}, x_{2i}, \dots, x_{ii})$  que se encuentra en la capa de entrada. Este vector es multiplicado por  $\gamma_{ij}$  (*connection strengths*). Los resultados obtenidos (unidades ocultas) son componentes de la capa oculta y son sometidos a una función de activación no lineal  $G$ . En la capa oculta, las combinaciones lineales de  $x_i' \gamma_{ij}$  se forman y asumen valores según el rango de  $G$ . Finalmente, son multiplicados por los ponderadores  $\beta_j$  para producir  $y_i$  a través de la capa de salida. Este tipo de ANN es denominado *single hidden layer feedforward network model*, ya que contiene una sola capa oculta y la información fluye hacia adelante, desde  $x_i$  hasta  $y_i$  (Diagrama 1).



### Diagrama 1: RED NEURONAL ARTIFICIAL DE APRENDIZAJE SUPERVISADO



Fuente: Franses and Van Dijk (2003)

Matemáticamente, un modelo ANN está definido como:

$$\begin{aligned}
 y_t &= F(X_t; \Theta) = x'_t \phi + \sum_{j=1}^q \beta_j G(x'_t, \gamma_j) \\
 &= \phi_1 y_{t-1} + \phi_2 y_{t-2} + \phi_p y_{t-p} + \phi_1 z_{1,t-1} + \phi_2 z_{2,t-2} + \dots + \phi_p z_{m,t-p} \\
 &\quad + \sum_{j=1}^q \beta_j G(\gamma_{1,j} \gamma_{t-1} + \gamma_{2,j} \gamma_{t-2} + \dots + \gamma_{p,j} \gamma_{t-p}) \quad (1)
 \end{aligned}$$

El término  $(x'_t \phi)$  representa la parte lineal de la relación entre  $y_t$  y  $x_t$ ; mientras que los componentes logísticos corresponden a la parte no lineal<sup>2</sup>. El vector  $x'_t$  está conformado por los rezagos  $i = 1, \dots, n$  de la variable dependiente  $y_{t-i}$  y un conjunto de variables independientes  $z_m$  para  $j = 1, \dots, m$  y sus respectivos rezagos  $z_{m-p}$ ,  $p = 1, \dots, n$ .

El aprendizaje del modelo ANN se da por ajustes graduales de los parámetros  $\Theta = (\phi, \beta, \gamma)$  con base en observaciones de experiencias previas. El conocimiento en  $(t+1)$ , depende del conocimiento en el momento  $(t)$  más un incremento del conocimiento,  $\Delta$ , con lo cual  $\Theta_{t+1} = \Theta_t + \Delta_t$ .

2 La contribución conjunta de los componentes no lineales está dada por:  $\sum_{j=1}^q \beta_j G(x'_t, \gamma_j)$  y las contribuciones individuales de cada unidad de la capa oculta  $\beta_1 G(x'_t, \gamma_1)$ ,  $\beta_2 G(x'_t, \gamma_2)$ , ...,  $\beta_q G(x'_t, \gamma_q)$ .

El objetivo del aprendizaje es hallar los parámetros que minimicen el error. Este error está dado por la sumatoria de cuadrados de la siguiente función:

$$S(\Theta) = \sum_{i=1}^T (y_i - F(X_i; \Theta))^2 \quad (2)$$

donde:

$$F(X_i; \Theta) = x_i' \phi + \sum_{j=1}^q \beta_j G(x_i', \gamma_j) \quad (3)$$

El proceso de aprendizaje de la ANN es de carácter secuencial (Kuan y White, 1994) y puede ser enfocado como un problema de optimización no restringida (Misas et al., 2003). El objetivo radica en estimar el vector de parámetros  $\hat{\Theta}$ , que minimice la suma de residuos al cuadrado  $Q_n(\hat{\Theta}_n^{(r)})$  y la gradiente asociada  $\nabla Q_n(\hat{\Theta}_n^{(r)})$ .<sup>3</sup>

### Modelo ANN de aprendizaje no supervisado – redes de Kohonen

Las redes de Kohonen (1982) son un tipo de red neuronal de aprendizaje no supervisado y frecuentemente utilizado en el ámbito de ML. Este tipo de modelo estructura sus resultados a través de Mapas Auto-organizados<sup>4</sup> (SOM, por sus siglas en inglés) con base en un proceso de identificación de rasgos comunes, regularidades, correlaciones o categorías en datos de entrada que son incorporados en su estructura interna de conexión.


Las redes de Kohonen (RK) permiten obtener una transformación de un patrón de señal entrante, de dimensión arbitraria (generalmente grande) en un mapa discreto de menor dimensión a través de un proceso adaptativo de orden topológico (Gorunescu, 2011).

La arquitectura de RK está constituida por las capas de entrada,  $x_i$ ; de dimensión  $N$  y de salida  $y_i$  de dimensión  $M$ , donde cada par de elementos  $(x_{it}, y_{it})$  está ligado por un vector de pesos de la neurona  $w_j$ .

3 La gradiente asociada está dada por la siguiente identidad:

$$\nabla Q_n(\hat{\Theta}_n^{(r)}) = \frac{\partial \nabla Q_n(\hat{\Theta}_n^{(r)})}{\partial \Theta}$$

4 La auto-organización es un proceso espontáneo que agrupa o auto-organiza elementos de un sistema a través de fluctuaciones aleatorias que son amplificadas por una retroalimentación.

**Diagrama 2: REDES DE KOHONEN**

Fuente: Kubat (2017)

En la fase de entrenamiento, las neuronas de la segunda capa compiten para establecer cuál es la más cercana al patrón seleccionado  $\min \|X_i - \mu_j\|^5$ . En esta fase también se establece la influencia de las neuronas vecinas (vecindad). La función de vecindad permite, a su vez, preservar las propiedades topológicas del espacio de entrada.

El aprendizaje de la red está formalmente definido por:

$$\Delta w_j = \alpha(t) h_i(t) (x'_i - w_j) \quad (4)$$

donde  $\alpha$  es la tasa de aprendizaje,  $t$ , el índice de iteración y  $h_i$ , la función de vecindad.<sup>6</sup>

La activación de la neurona  $i$ -ésima es posible solo si:

$$y_{ii} = \begin{cases} 1 & \min \|X_i - w_j\| \\ 0 & e.o.c. \end{cases} \quad (5)$$

Los  $w_j$  de la neurona ganadora se actualizarán con el propósito de que se asemeje al vector de entrada para lograr una clasificación óptima. Este

5 Se asume la distancia euclidiana:  $d_{ij} = \sqrt{\sum_{i=1}^N (X_i - \mu_j)^2}$ .

6 Donde  $\alpha(t) = \alpha_0 \left( \frac{\alpha_f}{\alpha_0} \right)^{\frac{t}{t_{max}}}$   $\alpha_0$  y  $\alpha_f$  son las tasas de aprendizaje inicial y final y  $t_{max}$  es el número máximo de iteraciones;  $h_i^0 = e^{-\frac{d(i,j)^2}{2\sigma(t)^2}}$   $d$  es la distancia euclidiana; el rango de vecindad está dado por  $\sigma$ .

procedimiento garantiza una mejor generalización para datos nuevos fuera de la muestra.

### Modelos SVM de clasificación

Los modelos SVM se fundamentan en la teoría de aprendizaje estadístico y tienen por objeto la clasificación de un conjunto de observaciones en espacios mediante la selección de hiperplanos y clasificadores de margen máximo.

Propuestos por Cortes y Vapnik (1995), inicialmente, los SVM fueron empleados para resolver problemas de clasificación binaria. Posteriormente, su aplicación se extendió a la resolución de problemas de mayor complejidad como la multi-clasificación y regresión.

Sea  $\phi: X \rightarrow F$  una función de correspondencia entre un punto del vector de entrada  $x$  con un punto en el espacio de características  $F$ . El objetivo es encontrar el hiperplano de separación en un nuevo  $F$ , el cual se transforma en una función no lineal que separa  $x$  en  $F$  original, donde  $\phi(x) = \langle \phi_1(x), \dots, \phi_m(x) \rangle$  y  $\phi_i(x)$  es una función no lineal con  $i = 1, \dots, m$ .

La frontera de decisión lineal obtenida en  $F$  se transformará en una frontera de decisión no lineal en el espacio original de entradas.

La función de decisión en  $F$  es:  $D(x) = (w_1 \phi_1(x) + \dots + w_m \phi_m(x)) = \langle w, \phi(x) \rangle$ .

En su forma dual,  $F$  se obtiene transformando la expresión de la frontera de decisión en:

$$D(x) = \sum_{i=1}^n \alpha_i^* y_i \langle \phi(x), \phi(x_i) \rangle \quad (6)$$

El producto escalar  $\langle \phi(x), \phi(x_i) \rangle$  es posible de calcularse con la función de Kernel<sup>7</sup> (Diagrama 3) que asigna a cada par de elementos de  $X$  un valor correspondiente al producto escalar en un nuevo  $F$ :

$$K(x, x') = \langle \phi(x), \phi(x') \rangle = (\phi_1(x) \phi_1(x') + \dots + \phi_m(x) \phi_m(x')) \quad (7)$$

Sustituyendo la función de Kernel en el producto escalar se tiene:

$$D(x) = \sum_{i=1}^n \alpha_i^* y_i K(x, x_i) \quad (8)$$

7 Algunas funciones de Kernel son: Lineal  $K_L(x, x') = \langle x, x' \rangle$ ; Polinómico de grado  $p$   $K_P(x, x') = [\gamma \langle x, x' \rangle + \tau]^p, \gamma > 0$ ; Gaussiano  $K_G(x, x') = \exp(-\gamma \|x - x'\|^2) \gamma > 0$ ; Sigmoidal  $K_S(x, x') = \tanh[\gamma \langle x, x' \rangle + \tau]$  donde  $p, \gamma, \tau$ , representan los parámetros.


El problema a resolver es:

$$\max \sum_{i=1}^n \alpha_i - \frac{1}{2} \alpha_i \alpha_j y_i y_j K \langle x_i, x_j \rangle \quad (9)$$

sujeto a:

$$\sum_{i=1}^n \alpha_i y_i = 0 ; 0 \leq \alpha_i \leq C, i = 1, \dots, n \quad (10)$$

Diagrama 3. FUNCIÓN DE KERNEL



Fuente: Elaboración propia.

## V. Resultados

A continuación, se presentan los principales resultados de los modelos y algoritmos expuestos en la anterior sección, los mismos que fueron estimados con el *software* especializado Matlab R2017.<sup>8</sup>

De acuerdo con los métodos propuestos por Pineda y Piñeros (2009) y Cáceres y Palacios (2011), se consideraron las condiciones que pueden adoptar las entidades bancarias de acuerdo con un rango de escala (0,1) de una función logística<sup>9</sup>:

De 0 a 0,25	Crítica
mayor a 0,25 hasta 0,50	Vulnerable
mayor a 0,5 hasta 0,75	Estable
mayor a 0,75 hasta 1	Solvente


8 Los códigos utilizados en este estudio pueden ser solicitados a través del correo del autor: jonnathan.caceres@gmail.com

9 Corresponde a la forma:  $C_n = 1/[1 + Ke^{-\frac{x_i}{CO}}]$  donde K es un parámetro de la función y  $x_i$  los valores observados de ROE (rendimiento de capital) ajustado por costo de oportunidad (CO). El término CO comprende: el costo medio ponderado de capital y la inflación.

Los resultados del modelo ANN supervisado evidenciaron que la condición de los bancos registró una transición continua: comenzaron en la fase vulnerable (enero de 2001) y se situaron en la condición crítica en febrero de 2003 y junio de 2004. Esto fue coincidente con una etapa de crisis económica, política y social en Bolivia que incidió negativamente sobre los niveles de liquidez y solvencia de las entidades bancarias.<sup>10</sup>

A partir de marzo de 2005, coherente con la dinámica de la economía, los bancos registraron una evolución financiera positiva, lo que les permitió ubicarse en la condición solvente en noviembre de 2006 hasta diciembre de 2012. En períodos posteriores, las entidades bancarias se ubicaron con mayor frecuencia en la fase estable. Finalmente, se observó un cambio de tendencia negativa a partir del primer trimestre de 2016 que prevaleció hasta los últimos períodos del estudio.

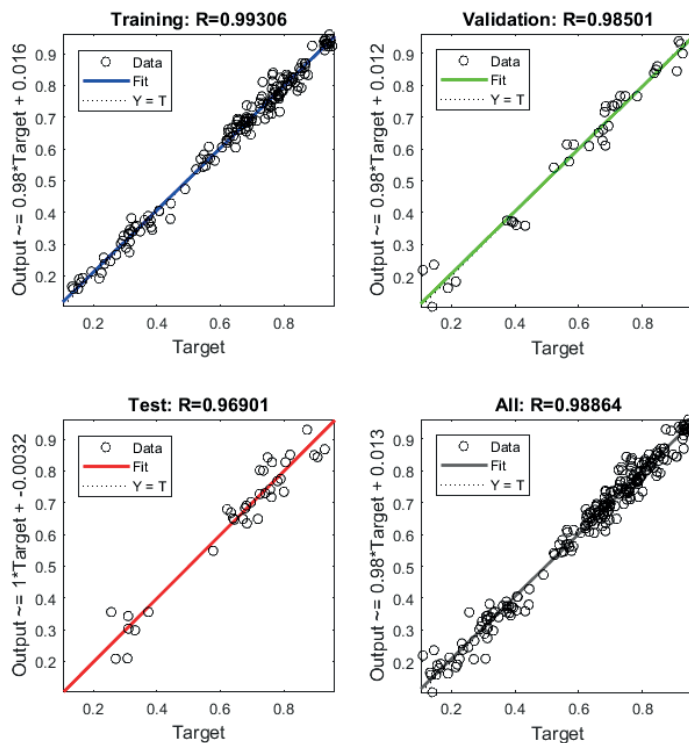
**Gráfico 1: MODELO ANN SUPERVISADO - RESULTADOS**



Fuente: Elaboración propia

La evaluación efectuada a los segmentos de datos (*training* = 70%; *validation* = 15% y *test* = 15%) muestra que el modelo de ANN supervisado alcanzó un nivel de precisión cercano a 99% (Gráfico 2). Asimismo, la distribución de los errores de pronóstico se concentró en torno a 0 (Apéndice B).

<sup>10</sup> Este contexto generó un ambiente de incertidumbre social y reducción de la actividad económica que produjo retiros masivos de depósitos bancarios e incumplimiento de pagos de créditos.

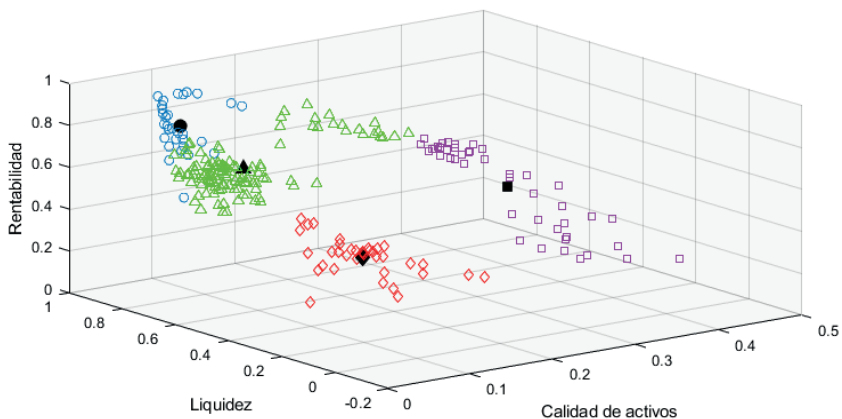
**Gráfico 2: MODELO ANN SUPERVISADO - DISPERSIÓN DE ERRORES**

Fuente: Elaboración propia

El Gráfico 2 muestra los resultados del modelo no supervisado a través de la visualización de un mapa auto-organizado. Las observaciones fueron clasificadas en cuatro grupos, número similar al de los estados asumidos por los bancos en el modelo anterior. Asimismo, se presentan los centroides (C1, C2, C3 y C4) que se constituyen en puntos referenciales.

El mapa también muestra los cambios y la trayectoria de los estados que asumieron los bancos de acuerdo con el orden numeral de los centroides. El primer y segundo grupo corresponden a estados donde las condiciones financieras de los bancos registraban debilidades financieras. De forma análoga al anterior modelo, estos estados se clasifican en crítico y vulnerable, respectivamente. El tercer grupo representa un estado solvente y el cuarto, una situación estable.

**Gráfico 3: MODELO ANN NO SUPERVISADO - RESULTADOS**




Fuente: Elaboración propia

El mapa muestra que las observaciones de los últimos períodos (como los puntos dentro del círculo segmentado) tienden a aproximarse a los estados vulnerable y crítico.

Con el objeto de cuantificar la proximidad de estas observaciones y los grupos de riesgo, se calcularon las distancias euclidianas de las observaciones del período de enero de 2017 a febrero de 2020 con relación a C2 y C1. En el Gráfico 4, se observa que después de un continuo descenso de la distancia registrada, desde diciembre de 2017 hasta octubre de 2018, las magnitudes son casi constantes para los períodos posteriores.



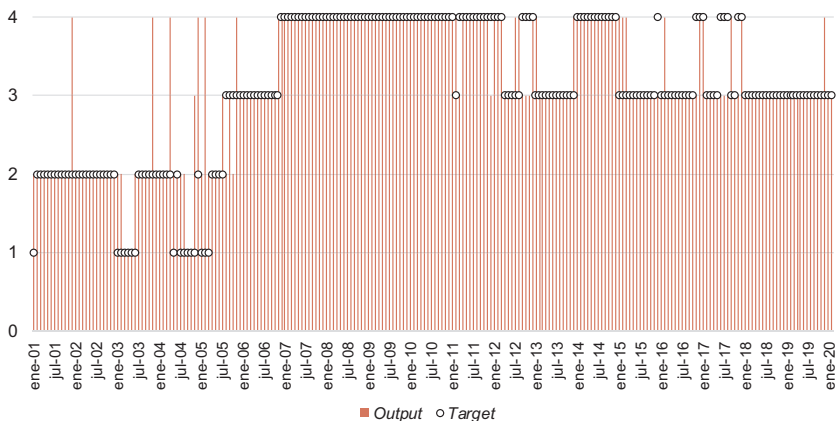
**Gráfico 4: MODELO ANN NO SUPERVISADO - DISTANCIA EUCLIDIANA DE OBSERVACIONES CON RESPECTO A C1 Y C2**



Fuente: Elaboración propia

Los resultados del modelo SVM (Gaussiano) para la clasificación de los bancos en los estados definidos registró una precisión de 85,1%. Los resultados estimados a través de este método permiten apreciar los aciertos y errores de pronóstico puntuales; sin embargo, no es posible observar cambios graduales de tendencia.

**Gráfico 5: MODELO SVM - RESULTADOS**



Fuente: Elaboración propia

Las matrices de confusión muestran que las observaciones de los estados: vulnerable, estable y solvente fueron clasificadas con un nivel de error no mayor a 15%, en tanto que las correspondientes al estado crítico sobrepasaron esta magnitud y tienden a ser clasificadas como el estado más próximo (vulnerable).

**Cuadro 2. MODELO SVM – MATRICES DE CONFUSIÓN**

Observado	Predicción				Observado	Predicción					
	Crítica	Vulnerable	Estable	Solvente		Crítica	Vulnerable	Estable	Solvente	Verdadero Positivo	Falso Negativo
	5	9	1	1		31%	56%	6%	6%	31%	69%
		33	1	5			85%	3%	13%	85%	15%
		2	75	10			2%	86%	11%	86%	14%
			12	76				14%	86%	86%	14%

Fuente: Elaboración propia

El cálculo periódico de los resultados permitió observar la tendencia y trayectoria gradual de la evolución de la condición financiera de las entidades bancarias, aspectos que son deseables para el diseño, implementación y evaluación de respuestas de políticas financieras de carácter macroprudencial.

## VI. Conclusiones

La actividad de intermediación financiera resulta vital para promover el desarrollo financiero y el crecimiento de largo plazo de las economías. Asimismo, existe un consenso generalizado de que las fragilidades bancarias afectan negativamente a la estabilidad macroeconómica. El sistema financiero boliviano ha registrado cambios importantes en los últimos años. Los bancos, al igual que el sistema de pagos de alto valor, atravesaron por procesos de expansión y modernización. En un contexto de mayor complejidad financiera en el cual los riesgos pueden tener sus orígenes en factores desconocidos, la implementación de modelos basados en técnicas de ML se constituye en una alternativa para identificar y gestionar los riesgos financieros.

Los métodos de ML utilizados con mayor frecuencia en estudios de predicción de situaciones de bancarrota de bancos son ANN (supervisadas y no supervisadas) y SVM. Con base en este elemento, el presente documento emplea dichas técnicas para analizar y pronosticar el comportamiento financiero de los principales bancos de Bolivia.

Con una precisión del 99%, los resultados del modelo ANN supervisado mostraron que los bancos estuvieron en una condición vulnerable en enero de 2001 y crítica en febrero de 2003 debido a una situación de crisis política, social y económica. A partir de marzo de 2005, en línea con el dinamismo de la actividad económica, los bancos registraron una evolución financiera favorable hasta situarse en noviembre de 2006 en una fase solvente. A partir de abril de 2011 hasta febrero de 2020, las entidades bancarias se situaron, con mayor frecuencia, en una condición estable. A partir del primer trimestre de 2016, se observó un cambio de tendencia negativo que prevaleció hasta los últimos períodos.

Los resultados del modelo ANN no supervisado se tradujeron en un mapa auto-organizado. Este mapa permitió apreciar los cambios de los estados de las entidades bancarias. De manera coincidente con el modelo ANN supervisado, los dos primeros grupos de la clasificación corresponden a estados donde las condiciones financieras de los bancos registraban debilidades financieras (fases crítica y vulnerable), en tanto que el tercer grupo representa un estado solvente y el cuarto, una situación estable.

Los resultados del modelo SVM para la clasificación de los bancos, registró una precisión de 85,1%. Las observaciones de los estados: vulnerable, estable y solvente fueron clasificadas con un nivel de error no mayor a 15%, en tanto que las correspondientes al estado crítico sobrepasaron esta magnitud y tendieron a ser clasificadas como vulnerable.

Dada la capacidad de abstraer patrones recurrentes y generalizar información no observada, los modelos ML permiten efectuar análisis y pronósticos precisos sobre el desempeño financiero de las entidades bancarias. Estos elementos son importantes para el diseño, propuesta y evaluación de políticas macroprudenciales orientadas a preservar la estabilidad financiera. Una agenda futura de investigaciones para dar continuidad al presente documento podría emplear técnicas adicionales de ML e información de mayor frecuencia temporal.

## Referencias bibliográficas

- BANCO CENTRAL DE BOLIVIA (2020). *Informe de Estabilidad Financiera*, enero
- BEALE, M. H., M. T. HAGAN, H. B. DEMUTH (2015). *Neural Network Toolbox™ User's Guide, Matlab R2015b*, The MathWorks, Inc., Unites States of America
- BIRON, M. y V. MEDINA (2018). “Comparación de algoritmos de clasificación para el incumplimiento crediticio. Aplicación al sistema bancario chileno” Superintendencia de Bancos e Instituciones Financieras, Chile, Nota Técnica N.º 03/18, diciembre
- CÁCERES, J. y R. ALDAZOSA (2013). “Analizando el riesgo sistémico en Bolivia: Una aplicación de modelos de topología de redes y simulación al funcionamiento del Sistema de Pagos de Alto Valor”, Banco Central de Bolivia, *Revista de Análisis*, 17 - 18, pp. 45-80
- CÁCERES, J. y L. PALACIOS (2011). “Un indicador global de desempeño financiero como mecanismo de alerta temprana: una aplicación de redes neuronales artificiales” Banco Central de Bolivia, Documento de trabajo interno
- CORTES, C. and V. VAPNIK (1995). “Support-Vector Networks” *Machine Learning*, 20, pp. 273 - 297
- DEVI, S. S. and Y. RADHIKA (2018). “A Survey on Machine Learning and Statistical Techniques in Bankruptcy Prediction” *International Journal of Machine Learning and Computing*, 8 (2), pp. 133 - 139 April 2018
- DÍAZ, O. y T. ROCABADO (2016). “En búsqueda de una relación de largo plazo entre crecimiento económico y desarrollo del sistema financiero” Banco Central de Bolivia, *Revista de Análisis*, 25, pp. 191 - 219
- EUROPEAN COMMISSION (2017). “Sector bancario y estabilidad financiera” Fichas temáticas del semestre europeo, octubre
- FRANSES, P. H. and D. VAN DIJK (2000). *Nonlinear Time Series Models in Empirical Finance*, Cambridge University Press, United States of America
- GORUNESCU, F. (2011). *Data Mining: Concepts, models and techniques*, Springer-Verlag, Germany
- HUMÉREZ, J. y E. YÁÑEZ (2011). “Desarrollo del sistema financiero y crecimiento económico. Una aproximación a partir del caso boliviano: 2000-2009” Banco Central de Bolivia, *Revista de Análisis*, 14, pp. 41 - 77

KOHONEN, T. "A Simple Paradigm for the Self-Organized Formation of Structured Feature Maps" in AMARI, S. and M. A. ARBIB (Eds) (1982) *Competition and Cooperation in Neural Nets. Proceedings, Kyoto 1982*, Lecture Notes in Biomathematics, 45, Springer-Verlag, Germany, pp. 248 - 266

KOU, G., X. CHAO, Y. PENG, F. E. ALSAADI, E. HERRERA-VIDEIRA (2019). "Machine learning methods for systemic risk analysis in financial sectors" *Technological and Economic Development of Economy*, 25 (5), pp. 716 – 742

KUAN, C. - M. and T. LIU (1995). "Forecasting Exchange Rates Using Feedforward and Recurrent Neural Networks" *Journal of Applied Econometrics*, 10 (4), pp. 347 - 364

KUAN, C. - M. and H. WHITE (1994). "Artificial neural networks: an econometric perspective" *Econometric Reviews*, 13 (1), pp. 1 - 91

KUBAT, M. (2017). *An Introduction to Machine Learning*, second edition, Springer International Publishing, Switzerland

LEVINE, R., N. LOAYZA, T. BECK (2000). "Financial intermediation and growth: Causality and causes" *Journal of Monetary Economics*, 46 (1), pp. 31 - 77

LI, S., M. WANG, J. HE (2013). "Prediction of Banking Systemic Risk Based on Support Vector Machine", *Mathematical Problems in Engineering*, 2013, pp. 1 - 5

LÓPEZ, F. J. and I. PASTOR (2015). "Bankruptcy visualization and prediction using neural networks: A study of U.S. commercial banks" *Expert Systems with Applications*, 42 (6), pp. 2857 - 2869

MINSKY, H. "Schumpeter and Finance" in M. SALVATI (Ed.) (1992) *Market and Institutions in Economic Development: Essays in Honour of Paolo Sylos Labini*, Palgrave Macmillan, United Kingdom, pp. 103 - 115

MISAS, M. A., E. LOPEZ, C. A. ARANGO, J. N. HERNANDEZ (2003). "La demanda de efectivo en Colombia: Una caja negra a la luz de las redes neuronales" Banco de la República de Colombia, Borrador de Economía No 268, noviembre

PAPADIMITRIOU, T., P. GOGAS, V. PLAKANDARAS, J. C. MOURMOURIS (2013). "Forecasting the insolvency of US banks using Support Vector Machines (SVMs) based on local learning feature selection" *International Journal of Computational Economics and Econometrics*, 3 (1/2), pp. 83 - 90

PINEDA, F. y J. H. PIÑEROS (2009). “El indicador financiero único como mecanismo de alerta temprana: una nueva versión” Banco de la República de Colombia, Reporte de Estabilidad Financiera, marzo

SHALEV-SHWARTZ, S. and S. BEN-DAVID (2014). *Understanding machine learning: From theory to algorithms*, Cambridge University Press, United States of America

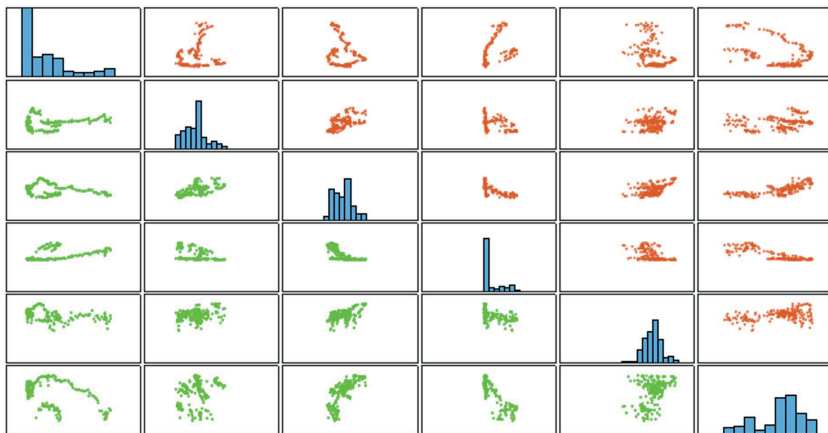
TYMOIGNE, É. (2011). “Measuring Macroprudential Risk: Financial Fragility Indexes” Levy Economics Institute of Bard College, Working Paper No. 654, March

VASU, M. and V. RAVI (2011). “Bankruptcy Prediction in Banks by Principal Component Analysis Threshold Accepting trained Wavelet Neural Network Hybrid” paper submitted to the 7<sup>th</sup> International Conference on Data Mining 2011, DMIN’11 ([www.dmin--2011.com](http://www.dmin--2011.com)), July 18 - 21, 2011, Monte Carlo Resort, Las Vegas, Nevada, USA.

## APÉNDICES

### APÉNDICE A

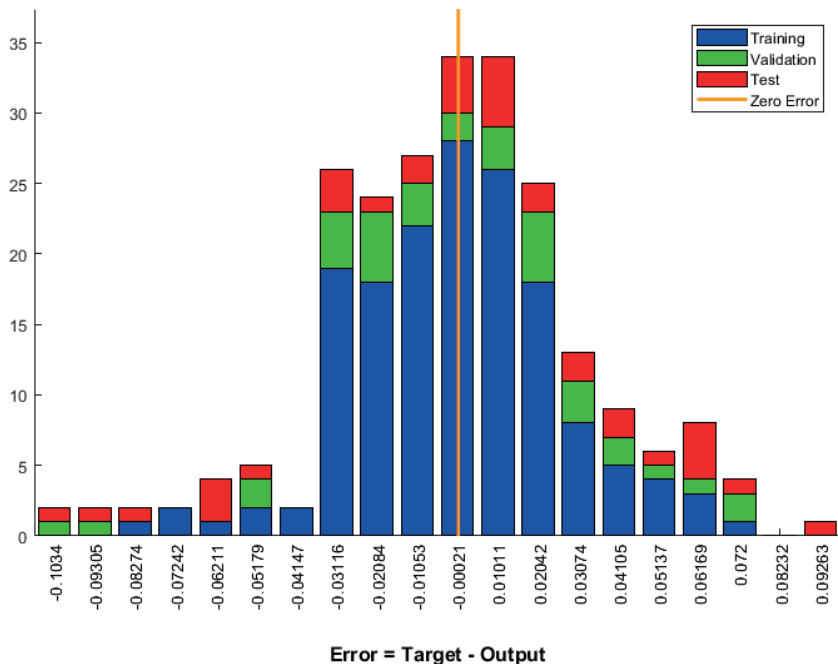
#### Correlación de variables



Fuente: Elaboración propia

## APÉNDICE B

**Modelo ANN supervisado – Distribución de errores de pronóstico**



Fuente: Elaboración propia