

Contagio en sistemas productivos y financieros: un enfoque interdisciplinario.

Autora

Deborah Noguera
IIPPYG, UNRN & CONICET
dmnoguera@unrn.edu.ar

Director

Gabriel Montes Rojas
IIEP-BAIRES-UBA & CONICET
gabriel.montes@economicas.uba.ar

Director asociado

Facundo Barrera Insua
LESET-IdIHCS-UNLP, CONICET & UNAJ
fbarrera@fahce.unlp.edu.ar

Tesis doctoral

Doctorado en Economía
Facultad de Ciencias Económicas
Universidad Nacional de La Plata

La Plata, Buenos Aires, Argentina
Noviembre de 2023

Resumen

En los sistemas sociales y económicos las interacciones entre agentes y también con el ambiente están presentes de manera generalizada, por lo que es posible abordar problemas económicos a través de herramientas de redes complejas. Si bien la literatura reconoce que la interconexión entre agentes puede ser beneficiosa –como por ejemplo, al compartir riesgos en las redes financieras– la crisis financiera de 2008, destacó el importante rol que juega dicha interconexión en la propagación de shocks. Nos referimos con esto, a los fenómenos de contagio en los sistemas económicos. En esta tesis, analizamos distintos aspectos del contagio y el riesgo en redes económicas, sus consecuencias y los procesos que rigen su dinámica. Específicamente, se abordan tres preguntas principales: i) ¿cómo es la dinámica de la propagación de los shocks sectoriales en redes productivas globales y su interacción con las características topológicas de la red?, ii) ¿qué forma adquiere el vínculo entre la topología de las redes financieras y la dinámica macroeconómica?, y iii) ¿cómo abordar la identificación de agentes económicos relevantes para el sistema financiero y su vínculo con las características topológicas del mercado? Abordamos cada uno de estos aspectos en los distintos capítulos de la tesis, basándonos en herramientas adecuadas para el análisis de sistemas complejos, como las redes complejas, la modelización basada en agentes y modelos de aprendizaje automático. El capítulo 1 estudia cómo un shock económico de impacto global se propaga y amplifica a través de la red que conecta a los diferentes sectores y países y analiza cuáles son los sectores y países con mayor capacidad de contagio o transmisión de shocks. Para este análisis, planteamos un modelo simple insumo-producto para representar las relaciones intersectoriales tanto a nivel local como global y simulamos dos tipos de shock para evaluar su efecto sobre las distintas economías. El capítulo 2 se centra en el rol que cumple el comportamiento de los bancos en el contagio de dificultades financieras en una red de crédito bancario, y analiza cómo las interconexiones pueden contribuir a amplificar el efecto de un shock y las fluctuaciones macroeconómicas. Para ello, proponemos un Modelo Basado en Agentes con dos tipos de agentes –firmas y bancos– y planteamos dos escenarios alternativos para representar diferentes comportamientos de las instituciones financieras respecto a la determinación de la oferta de crédito. Por último, el capítulo 3 analiza el rol que cumple la estructura de interconexiones entre instituciones financieras en el impulso del riesgo sistémico en el mercado interbancario argentino. Estimamos el riesgo sistémico de las entidades a través de índice *Differential DebtRank* y evaluamos los determinantes mediante tres modelos de aprendizaje automático basados en árboles de decisión. Los principales resultados pueden resumirse de la siguiente manera: (i) las características topológicas de las redes productivas, determinan en gran medida el alcance e impacto final de un shock asimétrico; (ii) en redes de crédito bancario, el comportamiento de los bancos puede contribuir a amplificar y/o acelerar los efectos del contagio, en particular cuando se incluyen mecanismos de racionamiento de crédito impulsados por la preferencia por la liquidez de las instituciones financieras; (iii) las características topológicas en una red interbancaria explican en gran medida la capacidad de una institución financiera de propagar pérdidas o dificultades financieras a lo largo y ancho del mercado.

Palabras clave: Modelos Basados en Agentes – Redes económicas complejas – Fragilidad financiera – Relaciones Insumo-Producto

Códigos JEL: E03 – E32 – G21 – H63

Noguera, Deborah (2023). Contagio en sistemas productivos y financieros: un enfoque interdisciplinario. Tesis doctoral. Doctorado en Economía, Facultad de Ciencias Económicas, Universidad Nacional de La Plata.

Índice

Introducción	1
Referencias	6
1 Los efectos directos e indirectos de un shock sectorial asimétrico a nivel global.	9
1.1 Introducción	9
1.2 Estructura del modelo global de relaciones intersectoriales	15
1.3 Estimación del modelo y especificación de los shocks	21
1.4 Resultados de la simulación	27
1.5 Comentarios finales	46
1.6 Anexo	48
Referencias	57
2 Un modelo minskyano con racionamiento de crédito en una economía de red.	64
2.1 Introducción	64
2.2 El modelo	68
2.3 Simulaciones: dinámica macroeconómica y topología de la red de crédito	77
2.4 Efectos de cambios en la regla de formación de expectativas de los bancos	86
2.5 Análisis de sensibilidad	89
2.6 Comentarios finales	92
2.7 Anexo	93
Referencias	96
3 Los determinantes del riesgo sistémico en el mercado interbancario argentino.	102
3.1 Introducción	102
3.2 Los determinantes del riesgo sistémico en mercados financieros: revisión de la literatura	109
3.3 Los mercados interbancarios argentinos	113
3.4 Datos y metodología	118
3.5 Resultados: los determinantes del riesgo sistémico en los mercados CALL y REPO	130
3.6 Comentarios finales	138
Referencias	141
Comentarios finales	147

Índice de figuras

1.1	Estructura de las relaciones intersectoriales a escala global y local	17
1.2	Evolución de la producción sectorial en los datos simulados y empíricos. Sectores seleccionados.	29
1.3	Comparación efecto directo e indirecto del shock sobre la oferta de trabajo, en términos de reducción de la producción sectorial global. En porcentajes.	32
1.4	Comparación efecto directo e indirecto del shock sobre la oferta de trabajo, en términos de reducción de la producción nacional. En porcentajes.	33
1.5	Evolución de la producción industrial en los datos simulados y empíricos. Países europeos incorporados en el estudio.	35
1.6	Participación de Rusia en las importaciones totales de gas natural. Año 2021. . .	37
1.7	Comparación efecto directo e indirecto del shock sobre la disponibilidad de energía, en términos de: Panel A) reducción de la producción sectorial global, Panel B) reducción de la producción nacional. En porcentajes.	39
1.8	Densidad de la red insumo-producto nacional y coeficiente de variación del tamaño del efecto cascada. Por países, considerando solo interacciones nacionales (izq.) e interacciones nacionales y globales (der.).	43
1.9	Tamaño del efecto cascada por país-sector y centralidad en la red internacional medida por el algoritmo HITS.	45
1.10	Evolución de la producción industrial en los datos empíricos y simulados bajo diferentes reglas de formación de expectativas de corto plazo.	53
1.11	Caída en el producto mensualizada, período 4 respecto del período 1, de acuerdo al valor de los parámetros. Shock tipo 1.	58
1.12	Caída en el producto mensualizada, período 4 respecto del período 1, de acuerdo al valor de los parámetros. Shock tipo 2.	59
1.13	Participación sectorial en la producción nacional. En porcentajes.	60
2.1	Producto y tasa de crecimiento. Escenarios 1 y 2. Períodos 200-1000.	81
2.2	Deuda y tasa de interés, escenarios 1 y 2. Períodos 200-1000.	82
2.3	Quiebra de bancos y firmas, escenarios 1 y 2. En porcentajes, períodos 200-1000.	84
2.4	Porcentaje promedio de bancos en quiebra según valor de λ , períodos 200-1000. Escenario base.	86
2.5	Error cuadrático medio en el pronóstico de crecimiento de los bancos. Expectativas adaptativas (EA), expectativas con reglas heterogéneas (EH) y modelo autorregresivo (AR).	88
2.6	Sensibilidad ante cambios en el valor de ϵ . Tasa de crecimiento, firmas en default y bancos en default.	91
2.7	Sensibilidad ante cambios en el valor de ϱ . Tasa de crecimiento, firmas en default y firmas restringidas.	91
3.1	Montos mensuales operados en los mercados CALL y REPO. Enero 2015-Diciembre 2018. Miles de millones de pesos constantes, a precios de diciembre de 2018. . . .	116
3.2	Tasas de interés interbancarias y tasa de política monetaria. Enero 2015 - Diciembre 2018.	116
3.3	Porcentaje de las operaciones respaldadas con cada tipo de colateral. 2015-2018.	117

3.4	Representación red interbancaria, mercados CALL (panel superior) y REPO (panel inferior), enero de 2015 (izq.) y enero de 2018 (der.).	120
3.5	Matriz de correlación entre los potenciales determinantes del riesgo sistémico. Mercados CALL (izq.) y REPO (der.).	122
3.6	Ejemplo de red interbancaria para ilustrar el funcionamiento del algoritmo DebtRank.	123
3.7	Impacto sistémico. Mercado CALL	125
3.8	Impacto sistémico. Mercado REPO	126
3.9	Mercado CALL. Importancia de las variables topológicas y financieras en la predicción del impacto sistémico.	133
3.10	Mercado CALL. Importancia de las variables topológicas y financieras en la predicción de la vulnerabilidad sistémica.	135
3.11	Mercado REPO. Importancia de las variables topológicas y financieras en la predicción del impacto sistémico.	137
3.12	Mercado REPO. Importancia de las variables topológicas y financieras en la predicción de la vulnerabilidad sistémica.	139

Índice de cuadros

1.1	Valores de los parámetros y otros elementos necesarios para la estimación del modelo, dos tipos de shock.	27
1.2	Descomposición del impacto del shock asimétrico a la oferta de trabajo sobre la producción, en efecto directo e indirecto. Sectores agregados.	33
1.3	Descomposición del impacto del shock asimétrico a la oferta de trabajo sobre la producción, en efecto directo, indirecto local e indirecto global. Países.	34
1.4	Descomposición del impacto del shock asimétrico a la disponibilidad de energía, en efecto directo e indirecto. Países.	40
1.5	Descomposición del impacto del shock asimétrico a la oferta de trabajo sobre la producción, en efecto directo e indirecto. Sectores agregados.	54
1.6	Descomposición del impacto del shock asimétrico a la oferta de trabajo sobre la producción, en efecto directo e indirecto. Sectores agregados.	54
2.1	Valores de los parámetros.	79
2.2	Resultados variables económicas, escenario base. Períodos 200-1000.	80
2.3	Resultados variables económicas, escenario con preferencia por la liquidez (bancos). Períodos 200-1000.	80
2.4	Valores medio, mínimo y máximo de α . Escenarios 1 y 2, períodos 200-1000. . .	85
2.5	Media de α para diferentes valores de λ . Escenarios 1 y 2, períodos 200-1000. . .	86
2.6	Media y desvío, resultados bajos diferentes reglas de formación de expectativas. Períodos 200-1000.	89
2.7	Vínculos iniciales, ejemplo numérico reducido.	94
2.8	Tasa de interés ofrecida, monto disponible para prestar por parte de los bancos y nivel de apalancamiento de las firmas.	94
2.9	Tasa de interés ofrecida, monto disponible para prestar por parte de los bancos y nivel de apalancamiento de las firmas. Post shock.	95
2.10	Análisis de robustez, escenario 1. Períodos 200-1000.	96
2.11	Análisis de robustez, escenario 2. Períodos 200-1000.	97
2.12	Comparación del output del modelo con variables observables de la economía argentina.	97
3.1	Potenciales determinantes del riesgo sistémico estudiados y sus valores medios para los mercados CALL y REPO.	131

Introducción

Los sistemas sociales y económicos se componen de espacios en los que los agentes interactúan y toman decisiones al tiempo que determinan sus dinámicas y propiedades emergentes (Delli Gatti *et al.*, 2008; Dawid y Delli Gatti, 2018). En otras palabras, la interconexión es una característica central de los sistemas económicos. En consecuencia, comprender el funcionamiento de dichos sistemas requiere no sólo analizar a los agentes que los componen, sino también cómo éstos interactúan entre sí y cómo el resultado agregado puede diferir de la suma de comportamientos individuales. Esta observación se ha vuelto más clara con la crisis financiera mundial de 2008 y el colapso productivo-comercial que la sucedió. Estos eventos subrayaron la importancia de analizar y modelizar a los agentes económicos no de forma aislada sino como componentes interconectados e interactivos de sistemas que evolucionan dinámicamente (Stiglitz, 2018; Arestis, 2019; Kirman, 2010).

Un elemento clave en la emergencia de los eventos mencionados fue el fenómeno de contagio. En un sentido general, contagio en sistemas económicos se refiere a la propagación de un evento económico o financiero negativo desde una parte de la economía hacia otras, lo que resulta en una cascada de efectos negativos (Schwarcz, 2008). En otras palabras, es un fenómeno complejo en el que una perturbación o crisis en un sector, mercado o región económica puede extenderse y afectar a otros sectores, mercados o regiones, incluso cuando originalmente no estaban relacionados de manera directa con el evento disruptivo. El contagio puede ocurrir debido a diferentes factores, entre los que se destaca el rol de las interconexiones económicas entre los agentes. Cuando diferentes sectores o regiones económicas están vinculados por relaciones comerciales, financieras o de inversión, un evento adverso en uno de ellos puede afectar a los demás. Por ejemplo, una recesión económica en un país puede reducir la demanda de productos de otros países, lo que afecta negativamente a sus exportaciones. Asimismo, más vinculado a los sistemas financieros, la percepción del riesgo o las expectativas, juegan un papel importante en la dinámica de contagio. Si inversores, consumidores o empresas perciben un riesgo económico en un área, pueden volverse más cautelosos y reducir sus actividades económicas en otras áreas, incluso si no hay una razón fundamental para hacerlo. Los eventos económicos globales, como crisis financieras internacionales, fluctuaciones en los precios de las materias primas o desastres naturales, también pueden tener efectos en cadena a través de las economías globales. Finalmente, las perturbaciones en un sector o región pueden tener efectos secundarios que afecten a otros; por ejemplo, una crisis en el sector financiero puede llevar a una contracción del crédito, lo que afecta a las empresas y consumidores, y, por lo tanto, a otros sectores.

En síntesis, el contagio económico puede manifestarse de diversas formas, como la contracción económica, la pérdida de empleos, la reducción de la inversión o la disminución del consumo. Este fenómeno puede tener un impacto significativo en la estabilidad económica y financiera y, en este sentido, su comprensión y gestión es relevante en términos de la formulación de políticas económicas. Los esfuerzos para prevenir y mitigar el contagio pueden incluir políticas fiscales y monetarias, regulaciones financieras, mecanismos de alerta temprana y esfuerzos para aumentar la resiliencia económica, entre otros.

Previo a la crisis de 2008/09, la convención respecto a la interconexión en los sistemas económicos iba de la mano con la visión expresada en el trabajo seminal de [Allen y Gale \(2000\)](#). Según este paradigma, los beneficios derivados de la diversificación del riesgo superan los problemas de contagio y, por lo tanto, los sistemas económicos más interconectados serían más resistentes. Sin embargo, el estallido de la burbuja de las hipotecas subprime en Estados Unidos en 2007 llevó –a través de una red de complejas conexiones financieras– al colapso de grandes bancos de alto riesgo, como Lehman Brothers en septiembre de 2008. Esta grave crisis bancaria se extendió rápidamente al sector real, y provocó –a través de las complejas interconexiones productivas y comerciales a nivel global– una recesión económica en la mayor parte del mundo. De esta crisis han surgido dos lecciones importantes: (i) los agentes económicos interactúan de manera no lineal de modo que los pequeños shocks se amplifican y pueden tener un gran impacto; y (ii) a través de interconexiones complejas, los shocks pueden llegar a cualquier parte del sistema económico.

En términos generales, la dinámica de cualquier proceso de contagio depende centralmente de la estructura o topología de la red de interacciones. En este contexto, la heterogeneidad entre los agentes que la componen se vuelve un elemento de suma importancia: algunos agentes (nodos) pueden ser “demasiado grandes” o estar “demasiado conectados” como para fallar. Análisis empíricos encuentran evidencia inequívoca de heterogeneidad en las redes económicas; como los trabajos realizados por [De Masi *et al.* \(2015\)](#) para redes de crédito y [Fagiolo *et al.* \(2009\)](#) para redes comerciales. Por lo tanto, es necesario abordar la heterogeneidad de red específica además de la heterogeneidad de los agentes en sí mismos para una mejor comprensión de qué agentes (sectores, empresas, instituciones) son sistemáticamente importantes.

En este contexto, el campo de los sistemas complejos ha sido objeto de renovado interés. Desde esta perspectiva, se asume a la economía como un sistema complejo; es decir, como un sistema compuesto por una gran cantidad de agentes interconectados, donde las interacciones pueden dar lugar a resultados no lineales e impredecibles. En un sentido general, los sistemas económicos están compuestos por agentes que persiguen intereses individuales al tiempo que establecen relaciones de transacción que son mutuamente beneficiosas. En este contexto, la complejidad emerge como consecuencia de la naturaleza heterogénea de los agentes interactuantes. Estos agentes no son todos iguales, sino que al contrario difieren, entre otras características, en sus preferencias, expectativas, grado de conectividad, posición jerárquica y capacidad para participar en interacciones exitosas. Asimismo, a medida que tiene lugar la interacción, los agentes aprenden,

se adaptan y mutan, lo que conduce a un proceso evolutivo sistemático en el que tanto los agentes individuales como toda la estructura socioeconómica están sujetos a un cambio constante. Bajo la interpretación de que las relaciones económicas tienen lugar en un sistema complejo, las dinámicas fuera del equilibrio son más bien la regla que la excepción (Gomes y Gubareva, 2021; Arthur, 2021).

El enfoque de sistemas complejos en economía es un campo de investigación relativamente nuevo (Gomes y Gubareva, 2021), pero ha tenido un impacto significativo en la forma en que se estudia los fenómenos económicos. En las últimas décadas, los/as economistas comenzaron a aplicar los principales pilares de este enfoque al estudio de los sistemas económicos y financieros para enfatizar, por ejemplo, cómo los ciclos de auge y caída, los puntos de inflexión y los fenómenos de contagio pueden emanar de la interacción entre agentes heterogéneos en redes complejas, así como de las reacciones endógenas a las que estas interacciones pueden dar lugar (Dosi y Roventini, 2019). Como resultado, ha surgido una literatura que aplica herramientas analíticas típicas de los sistemas complejos adaptativos al estudio de fenómenos económicos. En particular, de esta literatura surgieron dos líneas de investigación principales: (i) los Modelos Basados en Agentes (ABM, por sus siglas en inglés) y (ii) el análisis de redes complejas.

Respecto a la primera línea mencionada, los ABM representan herramientas analíticas y computacionales necesarias para explorar las propiedades de una economía entendida como un sistema complejo (Delli Gatti *et al.*, 2011). Son modelos en los que multitud de agentes económicos heterogéneos y adaptativos interactúan entre sí y con el entorno, siguiendo reglas de comportamiento autónomo (Delli Gatti *et al.*, 2018). El uso de técnicas computacionales permite la inclusión de una gran cantidad de agentes heterogéneos y la representación de una amplia gama de interacciones complejas. El resultado de estas interacciones da forma a las propiedades emergentes del sistema, las cuales pueden ser computadas numéricamente (Delli Gatti *et al.*, 2008; Caiani *et al.*, 2016) y, en algunos casos, de manera analítica (Di Guilmi *et al.*, 2020). Los ABM han encontrado una amplia aplicación para el estudio de fenómenos sociales, tanto en la literatura económica (Farmer y Foley, 2009; Dosi y Roventini, 2019; Dawid y Delli Gatti, 2018), como en instituciones relevantes para el diseño e implementación de medidas de política, como por ejemplo, los Bancos Centrales (Baptista *et al.*, 2016; Turrell, 2016; Hommes *et al.*, 2022).

La segunda línea de investigación desarrollada en el campo de los sistemas complejos se refiere al análisis de redes. El análisis de redes económicas aplica modelos de la ciencia de redes al análisis e interpretación de fenómenos económicos (Jackson y Watts, 2002; Schweitzer *et al.*, 2009). Las redes económicas son redes donde los nodos representan a los agentes económicos (individuos, empresas, consumidores, organizaciones, industrias, países, etc.) y los enlaces representan las interacciones del mercado. Buena parte de esta literatura se conforma del desarrollo de redes estilizadas cuya configuración puede estudiarse analíticamente, de manera que permite analizar los vínculos causales en las transmisiones de shocks e identificar el papel de la estructura de la red en diferentes fenómenos de interés, por ejemplo, en un proceso de contagio (ver, Cabrales *et*

al., 2017, para una revisión detallada). Asimismo, las herramientas que brinda la teoría de redes permiten analizar estructuras de red de sistemas económicos a partir de abordajes empíricos. Al igual que los ABM, el análisis de redes ha encontrado diversas aplicaciones en la literatura económica (Costa *et al.*, 2011; Emmert-Streib *et al.*, 2018) y en instituciones que diseñan y/o implementan medidas de política (Silva *et al.*, 2016; Cortes *et al.*, 2019; Forte, 2019; Elosegui y Montes-Rojas, 2020; Noguera y Montes-Rojas, 2023).

Esta tesis integra la literatura relativa a ambas líneas de investigación. El objetivo general es analizar distintos aspectos de la dinámica del contagio y el riesgo en redes económicas. Las redes están presentes de manera ubicua en la economía: mercados interbancarios (Allen y Gale, 2000; Elosegui *et al.*, 2022), redes crediticias bipartitas entre bancos y empresas (De Masi y Gallegati, 2012; Noguera y Montes-Rojas, 2022), redes de insumo-producto y de comercio internacional (Acemoglu *et al.*, 2016; Fagiolo *et al.*, 2009), entre otras. El tipo de nodo varía según la red –bancos en redes interbancarias, sectores en redes productivas, países en redes de comercio–, y también lo hace el tipo de enlace –préstamos en redes crediticias bipartitas, compras y/o ventas en redes comerciales–. En esta investigación, trabajamos con tres redes económicas –crediticia bipartita, interbancaria y productiva (a nivel sectorial y global)–. Abordamos el análisis a partir de las siguientes tres preguntas: i) ¿cómo es la dinámica de la propagación de los shocks sectoriales en redes productivas globales y su interacción con las características topológicas de la red?, ii) ¿qué forma adquiere el vínculo entre la topología de las redes financieras y la dinámica macroeconómica?, y iii) ¿cómo abordar la identificación de agentes económicos relevantes para el sistema financiero y su vínculo con las características topológicas del mercado? Cada uno de estos aspectos se aborda en los distintos capítulos de la tesis, como se resume a continuación.

El capítulo 1 estudia cómo un shock económico de impacto global se propaga y amplifica a través de la red que conecta a los diferentes sectores y países. Planteamos un enfoque computacional para el análisis de las relaciones intersectoriales tanto a nivel global como local, a partir del cual es posible evaluar el impacto económico y el alcance de un shock que interrumpa el normal funcionamiento en una unidad. En particular, analizamos dos tipos de shocks: (1) reducción en la oferta laboral de un conjunto de sectores en distintos países, como el impacto de la pandemia COVID-19; y (2) interrupción del suministro de un sector en un país hacia el resto del mundo, como el efecto de la guerra en Ucrania. Calibramos el modelo usando datos de la matriz insumo producto global y de la producción mensual de los distintos sectores productivos. Esta estrategia de modelado permite plantear preguntas sobre los efectos de resultados de políticas o eventos disruptivos de corto plazo, analizar eventos que pueden considerarse transitorios en los que no se modifican de manera permanente las decisiones de los agentes y tiene la ventaja poder ser estimado adecuadamente con información disponible. Los resultados encontrados destacan la necesidad de considerar en el análisis de la importancia sistémica de los distintos sectores, no solo sus características económicas –como su tamaño en términos de valor agregado, producción o empleo generado–, sino también a las interrelaciones entre ellos y la posición que ocupa cada uno en las redes productivas. Es importante tener en cuenta que las economías nacionales forman

parte de un mundo cada vez interconectado, por lo que también su posición e integración en el complejo entramado de relaciones insumo-producto a nivel global es una dimensión relevante.

El capítulo 2 estudia el contagio de dificultades financieras en una red de crédito de firmas y bancos. Nos basamos en la Hipótesis de Inestabilidad Financiera de Minsky y en la literatura de los Modelos Basados en Agentes para analizar un mercado de crédito bancario en el cual firmas y bancos heterogéneos interactúan en función de un conjunto de reglas de comportamiento. El objetivo es doble: (1) evaluar la influencia del comportamiento bancario en la formación de la red de crédito y la propagación de dificultades financieras en un modelo basado en agentes; y (2) analizar las propiedades de la red de crédito emergente y su influencia en el desempeño macroeconómico. El enfoque ABM tiene dos ventajas principales. La primera, es que permite incorporar la heterogeneidad entre los agentes a nivel individual –y no sólo por conjuntos o tipos de agentes–, tanto en términos de sus atributos como respecto a la toma de decisiones. La segunda, es que permite modelizar explícitamente las interacciones directas e indirectas entre agentes económicos y analizar la estructura de red que adquieren estas interrelaciones y su vínculo con los resultados macroeconómicos. Las simulaciones sugieren que la inestabilidad económica agregada puede surgir como resultado del comportamiento de preferencia por la liquidez de los bancos, que restringen el crédito al sector productivo cuando tienen expectativas pesimistas.

El capítulo 3 analiza los determinantes del riesgo sistémico en el mercado interbancario argentino. Como elementos explicativos, consideramos el rol que cumplen tanto las variables financieras de las instituciones participantes como la topología de la red de interacciones entre bancos. El riesgo sistémico lo calculamos a partir de la metodología *Differential DebtRank*, para lo que consideramos diferentes niveles de shock inicial. Para la evaluación de los determinantes del riesgo sistémico, aplicamos tres modelos de aprendizaje automático: Adaptive Boosting (AdaBoost), eXtreme Gradient Boosting (XGBoost) y Random Forest. Este tipo de modelos permite capturar relaciones no lineales entre diversas variables, lo que es importante para comprender mejor los determinantes del riesgo sistémico en mercados financieros inherentemente complejos. Encontramos que la relevancia de los distintos factores en el impulso del riesgo sistémico varía de acuerdo al tamaño del shock inicial y de si es el impacto o la vulnerabilidad sistémica la dimensión del riesgo bajo análisis. Las características topológicas son las más importantes para predecir el impacto sistémico, mientras que las variables financieras son las principales impulsoras de la vulnerabilidad sistémica. Finalmente, cabe mencionar que la estructura de interconexiones en el mercado interbancario es más relevante para explicar el riesgo sistémico –en sus dos dimensiones– en el mercado garantizado, respecto del no garantizado.

En síntesis, en el capítulo 1 se analiza la propagación de shocks económicos a través de redes productivas sectoriales y muestra cómo, a través de ellas, un shock de origen local puede trascender las fronteras nacionales. En el segundo capítulo pasamos a analizar específicamente el plano local y nos centramos en el papel del sector financiero como amplificador de eventos disruptivos que tienen lugar en el sector real de la economía, a través de los vínculos crediticios entre firmas y

bancos. Finalmente, en el capítulo 3 analizamos el fenómeno de contagio al interior del mismo sector financiero –en particular, el mercado interbancario–, lo cual tiene potenciales implicancias para la economía real, como se estudió en el capítulo previo.

Referencias

- Acemoglu, D., Akcigit, U., & Kerr, W. (2016). Networks and the macroeconomy: An empirical exploration. *Nber macroeconomics annual*, 30(1), 273-335.
- Allen, F., & Gale, D. (2000). Bubbles and crises. *Economic Journal*, 110(460), 236-255.
- Arestis, P. (2019). Critique of the New Consensus Macroeconomics and a Proposal for a More Keynesian Macroeconomic Model. En Arestis P., Sawyer M. (eds). *Frontiers of Heterodox Macroeconomics* (pp. 1-44). Springer.
- Arthur, W. B. (2021). Foundations of complexity economics. *Nature Reviews Physics*, 3(2), 136-145.
- Baptista, R., Farmer, J. D., Hinterschweiger, M., Low, K., Tang, D., & Uluc, A. (2016). *Macroprudential policy in an agent-based model of the UK housing market*.
- Cabrales, A., Gottardi, P., & Vega-Redondo, F. (2017). Risk sharing and contagion in networks. *The Review of Financial Studies*, 30(9), 3086-3127. <https://doi.org/10.1093/rfs/hhx077>
- Caiani, A., Godin, A., Caverzasi, E., Gallegati, M., Kinsella, S., & Stiglitz, J. E. (2016). Agent based-stock flow consistent macroeconomics: Towards a benchmark model. *Journal of Economic Dynamics and Control*, 69, 375-408.
- Cortes, G. S., Silva, T. C., & Doornik, B. F. N. V. (2019). *Credit Shock Propagation in Firm Networks: evidence from government bank credit expansions* (Working Papers Series 507). Central Bank of Brazil, Research Department. <https://www.bcb.gov.br/content/publicacoes/WorkingPaperSeries/wps507.pdf>
- Costa, L. da F., Oliveira Jr, O. N., Travieso, G., Rodrigues, F. A., Villas Boas, P. R., Antiqueira, L., Viana, M. P., & Correa Rocha, L. E. (2011). Analyzing and modeling real-world phenomena with complex networks: a survey of applications. *Advances in Physics*, 60(3), 329-412. <https://doi.org/10.1080/00018732.2011.572452>
- Dawid, H., & Delli Gatti, D. (2018). Agent-based macroeconomics. En *Handbook of computational economics* (Vol. 4, pp. 63-156). Elsevier.
- De Masi, G., Fujiwara, Y., Gallegati, M., Greenwald, B., & Stiglitz, J. E. (2015). An analysis of the Japanese credit network. *Evolutionary and Institutional Economics Review*, 7(2), 209-232.
- De Masi, G., & Gallegati, M. (2012). Bank–firms topology in Italy. *Empirical Economics*, 43(2), 851-866.
- Delli Gatti, D., Desiderio, S., Gaffeo, E., Cirillo, P., & Gallegati, M. (2011). *Macroeconomics from the Bottom-up* (Vol. 1). Springer Science & Business Media.
- Delli Gatti, D., Fagiolo, G., Gallegati, M., Richiardi, M., & Russo, A. (2018). *Agent-based models*

- in economics: a toolkit*. Cambridge University Press.
- Delli Gatti, D., Palestrini, A., Gaffeo, E., Giulioni, G., & Gallegati, M. (2008). *Emergent macroeconomics: An agent-based approach to business fluctuations*. Springer.
- Di Guilmi, C., Gallegati, M., Landini, S., & Stiglitz, J. (2020). An analytical solution for network models with heterogeneous and interacting agents. *Journal of Economic Behavior & Organization*, 171, 189-220.
- Dosi, G., & Roventini, A. (2019). More is different... and complex! The case for agent-based macroeconomics. *Journal of Evolutionary Economics*, 29(1), 1-37. <https://doi.org/10.1007/s00191-019-00609-y>
- Elosegui, P., Forte, F. D., & Montes-Rojas, G. (2022). Network structure and fragmentation of the Argentinean interbank markets. *Latin American Journal of Central Banking*, 3(3), 100066.
- Elosegui, P., & Montes-Rojas, G. (2020). Network effects in interbank markets of Call and Repo in Argentina. *Ensayos Económicos*, 1(75), 50-81.
- Emmert-Streib, F., Tripathi, S., Yli-Harja, O., & Dehmer, M. (2018). Understanding the world economy in terms of networks: a survey of data-based network science approaches on economic networks. *Frontiers in Applied Mathematics and Statistics*, 4, 37. <https://doi.org/10.3389/fams.2018.00037>
- Fagiolo, G., Reyes, J., & Schiavo, S. (2009). World-trade web: Topological properties, dynamics, and evolution. *Physical Review E*, 79(3), 036115.
- Farmer, J. D., & Foley, D. (2009). The economy needs agent-based modelling. *Nature*, 460(7256), 685-686.
- Forte, F. D. (2019). *Network Topology of the Argentine Interbank Money Market*. Economic Research Working Papers N 87, Banco Central de la República Argentina.
- Gomes, O., & Gubareva, M. (2021). Complex systems in economics and where to find them. *Journal of Systems Science and Complexity*, 34, 314-338.
- Hommes, C., He, M., Poledna, S., Siqueira, M., & Zhang, Y. (2022). *CANVAS: A Canadian behavioral agent-based model*. Bank of Canada. <https://doi.org/10.34989/swp-2022-51>
- Jackson, M. O., & Watts, A. (2002). The evolution of social and economic networks. *Journal of economic theory*, 106(2), 265-295. <https://doi.org/10.1006/jeth.2001.2903>
- Kirman, A. (2010). The economic crisis is a crisis for economic theory. *CESifo Economic Studies*, 56(4), 498-535.
- Noguera, D., & Montes-Rojas, G. (2022). Fluctuaciones con restricciones de crédito e incertidumbre en una economía de red. *Ensayos Económicos*, 80, 1-48.
- Noguera, D., & Montes-Rojas, G. (2023). *Los efectos directos e indirectos de un shock sectorial asimétrico a nivel global. Un análisis dinámico de las relaciones insumo-producto*. (111). Banco Central de la República Argentina.
- Schwarcz, S. L. (2008). Systemic risk. *Geo. Lj*, 97, 193.
- Schweitzer, F., Fagiolo, G., Sornette, D., Vega-Redondo, F., & White, D. R. (2009). Economic Networks: What do we know and what do we need to know? *Advances in Complex Systems*,

12(04n05), 407-422. <https://doi.org/10.1142/S0219525909002337>

Silva, T. C., Silva, M. A. da, & Tabak, B. M. (2016). *Modeling Financial Networks: a feedback approach* (Working Papers Series 438). Central Bank of Brazil, Research Department. <https://www.bcb.gov.br/content/publicacoes/WorkingPaperSeries/wps438.pdf>

Stiglitz, J. E. (2018). Where modern macroeconomics went wrong. *Oxford Review of Economic Policy*, 34(1-2), 70-106. <https://ideas.repec.org/a/oup/oxford/v34y2018i1-2p70-106..html>

Turrell, A. (2016). Agent-based models: understanding the economy from the bottom up. *Bank of England Quarterly Bulletin*, Q4.

1 Los efectos directos e indirectos de un shock sectorial asimétrico a nivel global.

1.1 Introducción

En este trabajo planteamos un enfoque computacional¹ para el análisis de las relaciones intersectoriales –considerando aquellas que tienen lugar tanto a nivel local como global–, a partir del cual es posible evaluar el impacto económico y el alcance de un shock que interrumpa el normal funcionamiento en una unidad (sector/país). Este trabajo tiene como objetivo modelizar distintos shocks en la cadena productiva global usando un modelo de insumo-producto con muchos sectores y países.

A partir de este análisis se busca simular dos eventos recientes de gran interés económico. El primer evento es un shock que afecta de manera diferencial a un conjunto de sectores en distintos países del mundo, para lo que tomamos como ejemplo motivador el caso de la pandemia de COVID-19. Modelizamos el shock como una restricción sobre la oferta disponible de mano de obra en algunos sectores, que se trasladará a la producción real y también a la demanda final. Tomamos el caso de las restricciones sectoriales en el marco de la pandemia por COVID-19 (ej. esenciales vs. no esenciales) para la selección de los sectores impactados en el escenario base, lo que nos permite calibrar el modelo en base a la evolución empírica de la producción sectorial. En el segundo tipo de evento, se busca modelizar una interrupción completa por parte de un país o conjunto de países en particular, para lo que tomamos como base el caso del conflicto entre Rusia y Ucrania. Este shock tiene la particularidad de cortar lazos comerciales entre países (ej. sanciones comerciales o interrupciones del flujo de gas natural) restringiendo las capacidades productivas del resto de los países. En ambos casos el objetivo es evaluar la transmisión del shock a través de la cadena productiva global.

La literatura económica ha demostrado que los vínculos comerciales en el sistema productivo juegan un papel importante en la transmisión de shocks (Acemoglu *et al.*, 2012; Battiston *et al.*, 2007). Específicamente, la estructura de las relaciones intersectoriales a lo largo de las

¹El enfoque computacional en el modelizado económico en general se refiere al uso o a la necesidad de utilizar un programa de computadora (código) para resolver modelos matemáticos que representan el comportamiento de la economía. En el caso específico del modelo que se desarrolla en este capítulo, es un modelo insumo-producto que, dada su dimensionalidad y complejidad, se resuelve mediante métodos de simulación numérica, ya que no es posible encontrar una solución analítica. Es decir, en lugar de resolver el modelo de manera analítica utilizamos un programa computacional para poder encontrar una solución.

cadenas de suministro es un elemento clave para analizar cómo factores como la dinámica de la productividad, el progreso tecnológico o el aumento/disminución de la demanda pueden afectar a un sistema económico (Cresti *et al.*, 2023). Esta transmisión opera tanto a nivel local como a nivel internacional, a través de los vínculos que conectan los sectores exportadores (importadores) de un país con las industrias importadoras (exportadoras) extranjeras. A partir de los procesos de fragmentación y deslocalización de la actividad productiva –con mayor énfasis en las últimas décadas–, que trajeron aparejado un incremento en la interconexión local e internacional de los sectores, estos factores se han vuelto más relevantes.

El alcance y la velocidad de la transmisión de un shock pueden ser heterogéneos entre países y también dentro de ellos. Un primer elemento a tener en cuenta es que un shock puede afectar a diferentes unidades y, por lo tanto, tener un origen diferente. Podría afectar a una industria específica en un país (como la sequía que enfrentó gran parte de Estados Unidos y afectó centralmente al sector agrícola), podría afectar a un conjunto de sectores en distintos países (como fue el caso de las medidas de aislamiento social que afectaron la mano de obra disponible en distintas economías para un mismo conjunto de sectores), o podría implicar que un país en su conjunto se vea impedido de participar en el comercio internacional (como ha sucedido, por ejemplo, en el reciente conflicto entre Ucrania y Rusia).

Al mismo tiempo, las industrias pueden ser más o menos centrales en las redes de producción. En este contexto, puede surgir un desajuste entre sectores que son centrales para la transmisión internacional de shocks y aquellos que son centrales para su propagación interna (Costa *et al.*, 2022). En otras palabras, un sector podría estar fuertemente conectado con otros sectores extranjeros, representando así un canal potencial de transmisión de shocks exógenos; sin embargo, si no es central dentro de la red de comercio nacional, su capacidad para transmitir perturbaciones a la economía nacional sería débil. Por el contrario, un sector con pocos o ningún vínculo de comercio exterior podría ser central dentro de la red de comercio nacional; en tal caso, un shock originado en ese sector podría propagarse amplia y rápidamente a través de la economía nacional pero con poco impacto en los mercados extranjeros. Por lo tanto, la posición que ocupan los sectores en la red de relaciones intersectoriales, es clave para determinar la magnitud total de un shock que lo afecta de manera directa.

La literatura económica –tanto teórica como empírica– ha estudiado ampliamente cómo los shocks se amplifican y propagan a través de las economías provocando fluctuaciones en el producto. Tradicionalmente, el tema ha sido abordado desde una perspectiva macroeconómica: entre otros, los shocks pueden originarse y transmitirse a través de efectos reales (inversiones, acumulación de capital, productividad, comercio, tecnología) o canales financieros (controles de capital, liquidez, sistema bancario, fricciones en el mercado crediticio), así como cambios en la política monetaria. Más recientemente, la literatura empírica ha demostrado que los ciclos económicos pueden tener su origen también en alteraciones microeconómicas (Acemoglu *et al.*, 2012; Baqaee y Farhi, 2019; Carvalho y Gabaix, 2013; Costa *et al.*, 2021; Di Giovanni *et al.*, 2014, 2018; Gabaix,

2011). En particular, se destaca que esto ocurriría en dos casos: (i) cuando las empresas son lo suficientemente grandes como para afectar significativamente la dinámica del PIB, el valor agregado o las exportaciones de un país (Gabaix, 2011); o (ii) cuando los vínculos entre los sectores económicos son tales que permiten que los posibles shocks que ocurren en una sola rama se extiendan al resto del sistema económico (Acemoglu *et al.*, 2012; Carvalho y Gabaix, 2013).

Desde una perspectiva sectorial –como la que adopta el presente capítulo–, un conjunto de contribuciones utilizó un enfoque insumo-producto para analizar el papel de las relaciones intersectoriales en la transmisión de shocks nacionales e internacionales dentro de los sistemas económicos. Esta literatura, destaca que la importancia de la transmisión internacional de shocks ha crecido gradualmente junto con la participación de empresas y países en las Cadenas Globales de Valor (CGV). Las relaciones comerciales entre sectores de diferentes países pueden conducir a la transmisión de eventos nacionales a través de las fronteras, lo que contribuye a los movimientos conjuntos de los ciclos económicos internacionales. La contribución pionera de Long y Plosser (1983) en el estudio de los comovimientos sectoriales a partir de un modelo de red, dio origen a una amplia literatura que se centró en estudiar la volatilidad agregada generada por shocks idiosincrásicos en sectores específicos. En líneas generales, se ha encontrado que estas perturbaciones tienen mayores efectos cuando los sectores se encuentran más interconectados y sus relaciones son fuertes (Acemoglu *et al.*, 2015a; Conley y Dupor, 2003).

Por mencionar algunos de los aportes más relacionados a este trabajo, Acemoglu *et al.* (2016) estudió la propagación de varios tipos de shocks a la economía de EE.UU. utilizando conjuntamente redes geográficas y matrices insumo-producto. Shea (2002) se centró en la misma economía y analizó la relevancia de las relaciones entre sectores en los comovimientos entre industrias en el país. Por su parte, Alatraste Contreras y Fagiolo (2014) estudiaron diferentes modelos de difusión de shocks entre las economías de la Unión Europea y encontraron que la extensión y heterogeneidad de los impactos dentro de las economías nacionales depende de si los shocks modifican o no la estructura de las interdependencias sectoriales y su capacidad productiva. Finalmente, Bems *et al.* (2010) utilizan un enfoque insumo-insumo producto a escala internacional para analizar la transmisión de la recesión global de 2008/09 y cómo la caída en la demanda agregada de un conjunto de países puede explicar el colapso del comercio mundial.

De esta manera, las matrices insumo-producto representan una herramienta de larga data para comprender la topología de las interdependencias entre industrias y sus repercusiones en las economías. Las características topológicas de la matriz se han estudiado para responder preguntas como la identificación de sectores sistémicamente importantes en una economía nacional (Giuliani, 2013) y regional (DePaolis *et al.*, 2022); y también para analizar posiciones de poder de los agentes económicos en los mercados locales (Barrera Insua y Noguera, 2023) y globales (Iliopoulos *et al.*, 2022). En lo que hace a la evaluación del impacto económico de shocks y su transmisión a través de una red o matriz de relaciones intersectoriales, los enfoques más utilizados son los modelos insumo-producto y los de Equilibrio General Computable. Si bien los

modelos de equilibrio general permiten mayor flexibilidad en la especificación de las funciones de producción y consumo y admiten la sustitución de factores en respuesta a cambios en los precios relativos, pueden ser difíciles de calibrar y pueden no ser generalizables a economías complejas. La estimación y calibración de los modelos de equilibrio general son exigentes, incluso si todos los datos centrales, como las matrices de contabilidad social interregional y todas las elasticidades requeridas, estuvieran disponibles (Koks *et al.*, 2019; Oosterhaven y Bouwmeester, 2016). En situaciones en las que los formuladores de políticas deben actuar con prontitud, puede ser útil tener resultados para un modelo de insumo-producto para dar al menos un extremo superior de la pérdida total o efectos totales.

Asimismo, generalmente se plantean preguntas sobre efectos de shocks o resultados de política económica que se refieren al corto a mediano plazo, como fue el caso de la imposición de las medidas que restringieron la circulación de personas (y, por lo tanto, la producción) en el marco de la pandemia por COVID-19. O también como lo fue evaluar el efecto que tendría en el corto plazo para los países europeos (y el resto del mundo) la decisión por parte de Rusia de suspender completamente el suministro de gas. Los modelos de equilibrio general son considerados más adecuados para la estimación de impactos a largo plazo (Okuyama, 2007) y usualmente se utilizan versiones adaptadas de estos modelos para dar cuenta de los impactos a corto plazo. En particular, el supuesto de coeficientes técnicos fijos que mantienen los modelos insumo producto son aceptables en el contexto de análisis de corto plazo: se requiere de elasticidades de sustitución cercanas a cero, lo que disminuye la ventaja potencial de un marco de equilibrio general. En esta línea, Barrot y Sauvagnat (2016) encuentran que las estimaciones empíricas de fenómenos de contagio se ajustan mejor cuando la elasticidad de sustitución entre insumos intermedios es cercana a 0 (es decir, cercana al caso de Leontief).

Finalmente, cabe mencionar que los modelos insumo-producto computacionales tienen mayor aplicación en el análisis de eventos que pueden ser considerados como transitorios, en los que resulta poco probable que una empresa decida modificar sustancialmente su proceso de producción y terminar con las relaciones comerciales consolidadas con proveedores (tanto locales como extranjeros). Esto sería en comparación con el caso de una situación que implique un daño físico a la capacidad productiva de las unidades afectadas, como puede ser un desastre natural o la pérdida de infraestructura que implica el contexto de conflicto armado entre Rusia y Ucrania.

En la literatura reciente, los modelos computacionales de matrices insumo-producto están siendo ampliamente utilizados para evaluar el impacto de distintos eventos disruptivos². Un modelo insumo producto es una técnica analítica para explicar el sistema económico (Leontief, 1936; Christ, 1955; Miller y Blair, 2009). En su forma más simple, es un sistema lineal de ecuaciones, en el que se explican los flujos de producto de cada uno de los sectores (como productor/vendedor) al resto de los sectores de la economía (como consumidor/comprador). En este trabajo, partimos

²Galbusera y Giannopoulos (2018) proveen una revisión completa y reciente de estas contribuciones aplicadas al caso de desastres naturales.

de un enfoque basado en el modelo insumo-producto tradicional, con el objetivo de construir una herramienta intuitiva que proporcione evaluaciones preliminares de los impactos sectoriales y globales de shocks que pueden afectar el normal funcionamiento de los sectores productivos de manera asimétrica. Específicamente, aplicamos un enfoque computacional para analizar el impacto económico (local y global) de un shock exógeno que interrumpa el normal funcionamiento en un sector/país, a partir de la red de relaciones intersectoriales. Se consideran shocks con dos orígenes diferenciados. En el primer caso, se modelizan como shocks en la oferta laboral, mientras que en el segundo caso, se modeliza como una interrupción en los flujos de comercio del sector energético de un país en particular (Rusia) hacia el resto de los países. De esta manera es posible evaluar la propagación del impacto desde una perspectiva interregional e interindustrial.

Hay un importante número de contribuciones que comparten una metodología similar. Por un lado, ha sido recientemente aplicada para evaluar los efectos de las medidas implementadas durante la pandemia por COVID-19. Por ejemplo, [Pichler *et al.* \(2022\)](#) utilizan un enfoque insumo-producto computacional para estimar los efectos de las medidas de aislamiento social en el Reino Unido considerando shocks de oferta y de demanda, y analizan varios escenarios posibles para las reaperturas. En una línea similar, [Reissl *et al.* \(2022\)](#) estiman un modelo computacional de las relaciones intersectoriales e interregionales en Italia, para evaluar el efecto de las dos etapas de confinamiento en dicho país. Finalmente, [Delli Gatti y Reissl \(2022\)](#) emplean un modelo basado en agentes macroepidemiológico para evaluar el *trade-off* entre “salud y economía”, discusión que estuvo presente durante los momentos más restrictivos en todo el mundo a la circulación de personas en el contexto del COVID-19. Por otro lado, hay un conjunto de contribuciones que utilizan un enfoque computacional insumo-producto, para evaluar los efectos de la interrupción del suministro de gas por parte de Rusia en las economías europeas. Por ejemplo, [Bouwmeester y Oosterhaven \(2017\)](#) utilizan un modelo insumo-producto dinámico, no lineal, para predecir el impacto regional de una interrupción del flujo de gas natural. Más recientemente, [Perdana *et al.* \(2022\)](#) a través de un modelo de equilibrio general computable que incorpora las relaciones insumo-producto a escala global, simulan distintos escenarios de embargo de la Unión Europea sobre la energía rusa.

El presente trabajo difiere de los anteriores en dos puntos principales. En primer lugar, el alcance geográfico al no concentrarse únicamente en un país en particular, sino hacerlo a nivel global y considerar a las economías nacionales no como unidades aisladas sino como elementos interconectados a un sistema económico global; y, por otro lado, el tipo de shocks que se analizan y el enfoque particular para descomponer la transmisión del mismo a través de las interconexiones sectoriales a nivel nacional y global. Finalmente, se buscó trabajar con un modelo simple e intuitivo, tanto en lo que hace a los supuestos de comportamiento de los agentes como en los requerimientos de información para su estimación.

En síntesis, se propone un modelo insumo-producto para analizar los efectos económicos de la transmisión de un shock específico, desde una perspectiva sectorial y de alcance local y

global. Se parte de la base del modelo Insumo-Producto global (ver, por ejemplo, Duchin, 1983), conjuntamente con el marco desarrollado por Reissl *et al.* (2022), quienes se basan el *Sequential Inter-Industry Model* (SIM) propuesto por Romanoff y Levine (1986). Si bien este último se desarrolla pensando en economías locales y los vínculos regionales en su interior, tiene como objetivo introducir explícitamente el tiempo en el modelizado de las relaciones insumo-producto y describir los procesos de ajuste que siguen a los shocks en la demanda final o en la capacidad productiva, por lo que resulta adecuado par los objetivos de este trabajo. Asimismo, puede ser adaptado para el estudio de los vínculos en la economía global.

El modelo predice una caída en la producción global del 32.1% para el caso del shock que afecta diferencialmente a la oferta de trabajo disponible para cada sector, y del 7.6% en el caso de una interrupción en el suministro del sector de energía y gas por parte de Rusia a los sectores-países europeos. Si bien la magnitud del efecto total sobre el producto global es mucho mayor en el primer caso en términos absolutos, si lo consideramos en términos relativos a la magnitud del evento desencadenante, el impacto sobre la producción global en el segundo tipo de shock es considerable. Este resultado se explica por la importancia sistémica que tiene el sector de energía y gas de Rusia en la economía mundial. Es posible observar esto de dos maneras. En primer lugar, si consideramos las participaciones de los efectos directo e indirecto, en el primer caso son del 62% y 38%, respectivamente, mientras que en el segundo caso, esto se revierte y el efecto indirecto pasa a ser la principal fuente de explicación para el cambio total de la producción desencadenado por el shock inicial: 55.2%. Asimismo, un análisis de la propagación del shock da cuenta de la relevancia del sector energético, ya que el mismo surge como aquel con la capacidad para desencadenar grandes efectos cascada en un número considerable de países (ver sección 1.4.3 para más detalles).

En líneas generales, los resultados encontrados ponen de relieve la importancia que tienen las interconexiones sectoriales y la posición de cada sector-país en la economía tanto nacional como global. Por lo tanto, analizar la importancia de los mismos requiere no sólo considerar sus características económicas (como tamaño en términos de valor agregado, producción o empleo generado), sino también la dimensión relacional. En este sentido, no debe perderse de vista que las economías nacionales forman parte de un mundo interconectado, por lo que su posición e integración en el complejo entramado de relaciones insumo-producto a nivel global es una dimensión relevante del análisis económico y social.

Este capítulo está organizado de la siguiente manera. En la sección 1.2 se describe la estructura del modelo y la forma que adquieren las relaciones intersectoriales. Luego, en la sección 1.3, se presenta la estrategia de estimación del modelo y la información utilizada. En las secciones 1.3.1 y 1.3.2 se especifican los tipos de shock implementados. Los resultados y análisis de las simulaciones se describen en la sección 1.4. Finalmente, la sección 1.5 concluye.

1.2 Estructura del modelo global de relaciones intersectoriales

La estructura de producción es similar a un modelo insumo-producto estándar, en el que se incorpora una dimensión espacial que distingue entre diferentes economías nacionales en el mundo, y una dimensión temporal para identificar el shock y su transmisión a lo largo de la cadena de suministro. Cada sector en cada país produce un bien homogéneo, con una tecnología de rendimientos constantes a escala, donde todos los insumos se usan en proporciones fijas. Si bien en el mundo real existe cierto grado de sustituibilidad, en este modelo nos interesa describir una perspectiva de corto plazo, para evaluar el alcance en la transmisión de un shock, por lo que resulta un supuesto aceptable en este contexto. Siguiendo a [Sraffa \(1960\)](#) podemos pensar que estamos describiendo una economía para una escala dada, pero no necesariamente sería la misma si la escala se altera en forma significativa³. Los bienes se utilizan para satisfacer tanto la demanda final como la demanda de insumos de otros sectores, tanto en la economía local como global. Para simplificar, suponemos que todos los precios están fijos (ver, por ejemplo, [Koks et al., 2019](#), para una discusión acerca de este supuesto en este tipo de modelos). En el anexo a este capítulo (sección 1.6.1) se presenta un ejemplo numérico simplificado para ilustrar la lógica del modelo.

1.2.1 Secuencia de eventos

En el modelo toman lugar los siguientes eventos y decisiones por parte de los agentes económicos representados.

1. Se determinan los shocks sobre la oferta de trabajo disponible o sobre la disponibilidad de insumos de otros sectores-países.
2. Se forman las expectativas sobre la demanda de corto y largo plazo en cada sector.
3. Se determina la producción factible, dada la cantidad de trabajadores y otros factores productivos disponibles.
4. Toman lugar las órdenes de insumos domésticos e importados en función de las expectativas de corto y largo plazo.
5. Se computa la demanda para cada sector-país y se determina el nivel de producción.
6. Se entregan los pedidos y los insumos consumidos en el proceso productivo se reponen con los bienes entregados, determinando la capacidad productiva en términos de insumos disponibles para el siguiente período.

Esta secuencia se repite en cada período t del modelo, donde cada unidad t corresponde a una semana calendario. A continuación se describen los principales aspectos del modelo.

³Respecto a la estimación del modelo, tiene dos ventajas principales: (1) evita la necesidad de realizar supuestos arbitrarios sobre el grado de sustituibilidad entre insumos intermedios (locales y de diferentes países) y de la velocidad a la que tales sustituciones pueden tener lugar; y (2) lo simplifica, ya que reduce el espacio de parámetros.

1.2.2 Producción y estructura general

Siguiendo la notación estándar en los modelos insumo producto presentes en la literatura, notamos \mathbf{Z} a la matriz de intercambios interindustriales o de consumo intermedio, que incluye las dimensiones geográfica (o sea, nacional) y sectorial que mencionamos previamente. Formalmente, la matriz \mathbf{Z} se puede representar como⁴:

$$\mathbf{Z}_{\mathbf{nk} \times \mathbf{nk}} = \begin{matrix} & \begin{matrix} [\mathbf{z}_1^1]^{\mathbf{C}} & & [\mathbf{z}_j^s]^{\mathbf{C}} & & [\mathbf{z}_k^n]^{\mathbf{C}} \end{matrix} \\ \begin{matrix} [\mathbf{z}_1^1]^{\mathbf{F}} \\ \vdots \\ [\mathbf{z}_j^s]^{\mathbf{F}} \\ \vdots \\ [\mathbf{z}_k^n]^{\mathbf{F}} \end{matrix} & \begin{pmatrix} z_{1,1}^{1,1} & \cdots & z_{1,j}^{1,j} & \cdots & z_{1,k}^{1,n} \\ \vdots & \ddots & \vdots & & \vdots \\ z_{i,1}^{r,1} & \cdots & z_{j,j}^{s,s} & \cdots & z_{j,k}^{s,n} \\ \vdots & & \vdots & \ddots & \vdots \\ z_{k,1}^{n,1} & \cdots & z_{k,j}^{n,s} & \cdots & z_{k,k}^{n,n} \end{pmatrix} \end{matrix} \quad (1.1)$$

Notar que \mathbf{Z} es una matriz cuadrada de dimensiones $\mathbf{nk} \times \mathbf{nk}$, donde n es el número de países y k es el número de sectores productivos. Cada fila y columna de la matriz \mathbf{Z} refiere a una rama específica localizada en un país en particular. Los supraíndices indexan países, mientras que los subíndices indican sectores productivos⁵. Como es usual en la literatura, las columnas de \mathbf{Z} , identificadas por los vectores columna $\mathbf{z}^{\mathbf{C}}$, indican los insumos necesarios para la producción de un sector en una localización particular, es decir, los requerimientos de bienes y servicios para su producción. Por su parte, las filas de \mathbf{Z} , identificadas por los vectores fila $\mathbf{z}^{\mathbf{F}}$, indican la asignación de la producción de un sector específico al resto de los sectores y localizaciones geográficas.

Expresado de otra forma, \mathbf{Z} es una matriz por bloques de dimensiones $\mathbf{n} \times \mathbf{n}$, donde cada elemento de la misma es una matriz cuadrada, de dimensiones $\mathbf{k} \times \mathbf{k}$. De esta manera, los elementos de la diagonal principal de la matriz denotan las transacciones entre sectores en una economía nacional, mientras que por fuera de la diagonal principal se identifica el intercambio internacional de cada sector y país en particular, tal como se representa en la Figura 1.

Cada elemento $z_{i,j}^{r,s}$ indica el flujo de bienes y servicios producidos por la industria i en el país r hacia la industria compradora j localizada en el país s . Cada elemento de la diagonal principal de la matriz, $z^{r,r}$, contiene a la matriz insumo-producto nacional, mientras que los elementos $z^{r,s \neq r}$ y $z^{s \neq r,r}$ contienen información sobre el comercio bilateral entre los países r y $s \neq r$.

⁴Utilizamos la tipología negrita y en mayúscula para denotar los objetos matrices, la negrita minúscula para vectores y la normal cursiva para denotar escalares. También utilizamos un tilde superior (i.e. \tilde{a}), para denotar a las variables, vectores, matrices o escalares que fueron obtenidos de la información empírica; es decir, de las tablas insumo-producto entre países publicadas por la OECD (ver sección 1.3).

⁵Ver, por ejemplo, Arto *et al.* (2019) y Durán Lima y Banacloche (2021). De esta manera, el par ordenado (fila, columna) de la matriz $\mathbf{nk} \times \mathbf{nk}$ se obtendría a partir del par ordenado supraíndice x subíndice. Por ejemplo, el elemento $z_{i,j}^{r,s}$ sería el elemento $(r(k-1) + i, s(k-1) + j)$, es decir, fila $r(k-1) + i$ y columna $s(k-1) + j$.

Figura 1.1: Estructura de las relaciones intersectoriales a escala global y local

Transacciones intermedias a nivel global					Transacciones intermedias a nivel nacional				
		País 1		País j		País n			
		Sector 1 ... Sector k		Sector 1 ... Sector k		Sector 1 ... Sector k			
\mathbf{Z} $nk \times nk$	País 1	Sector 1	$Z^{1,1}$...	$Z^{1,n}$				
	:	:	:	:	:				
	Sector k	:	:	:	:	:			
:	:	:	:	:	:				
:	:	:	:	:	:				
País n	Sector 1	$Z^{n,1}$...	$Z^{n,n}$					
:	:	:	:	:					
Sector k	:	:	:	:					

		Sector 1 ... Sector j ... Sector k			
Sector 1	$Z_{1,1}^{r,r}$...	$Z_{1,j}^{r,r}$...	$Z_{1,k}^{r,r}$
:	:	:	:	:	:
Sector j	$Z_{j,1}^{r,r}$...	$Z_{j,j}^{r,r}$...	$Z_{j,k}^{r,r}$
:	:	:	:	:	:
Sector k	$Z_{k,1}^{r,r}$...	$Z_{k,j}^{r,r}$...	$Z_{k,k}^{r,r}$

Todos los componentes de la demanda final total, incluyendo tanto la local como externa, se encuentran contenidos en un vector columna \mathbf{y} de longitud nk , que indica la demanda final de cada uno de los sectores k localizados en los n países. Al igual que en el modelo insumo-producto estándar, la producción bruta de cada sector se obtiene de adicionar a su demanda final, la suma de los elementos de la fila correspondiente de \mathbf{Z} .

La matriz \mathbf{A} de insumos se puede obtener dividiendo las compras sectoriales de insumos por los productos sectoriales, ambos extraídos de la matriz insumo producto entre países observada empíricamente (ver sección 1.3). Formalmente, esto se expresa como:

$$\mathbf{A}_{nk \times nk} = \begin{pmatrix} a_{1,1}^{1,1} & \cdots & a_{1,j}^{1,s} & \cdots & a_{1,k}^{1,n} \\ \vdots & \ddots & \vdots & & \vdots \\ a_{j,1}^{s,1} & \cdots & a_{j,j}^{s,s} & \cdots & a_{j,k}^{s,n} \\ \vdots & & \vdots & \ddots & \vdots \\ a_{k,1}^{n,1} & \cdots & a_{k,j}^{n,s} & \cdots & a_{k,k}^{n,n} \end{pmatrix} = \begin{pmatrix} \frac{\tilde{z}_{1,1}^{1,1}}{\tilde{x}_1^1} & \cdots & \frac{\tilde{z}_{1,j}^{1,s}}{\tilde{x}_j^s} & \cdots & \frac{\tilde{z}_{1,k}^{1,n}}{\tilde{x}_k^n} \\ \vdots & \ddots & \vdots & & \vdots \\ \frac{\tilde{z}_{j,1}^{s,1}}{\tilde{x}_1^1} & \cdots & \frac{\tilde{z}_{j,j}^{s,s}}{\tilde{x}_j^s} & \cdots & \frac{\tilde{z}_{j,k}^{s,n}}{\tilde{x}_k^n} \\ \vdots & & \vdots & \ddots & \vdots \\ \frac{\tilde{z}_{k,1}^{n,1}}{\tilde{x}_1^1} & \cdots & \frac{\tilde{z}_{k,j}^{n,s}}{\tilde{x}_j^s} & \cdots & \frac{\tilde{z}_{k,k}^{n,n}}{\tilde{x}_k^n} \end{pmatrix} \quad (1.2)$$

Definimos al vector \mathbf{l} de dimensión $nk \times 1$ que indica la cantidad de trabajadores disponibles para la producción en cada país y para cada sector. La cantidad inicial de mano de obra disponible ($\tilde{\mathbf{I}}$) se establece igual a 100 por simplicidad. A partir de aquí, definimos un vector de coeficientes técnicos para la mano de obra, dividiendo $\tilde{\mathbf{I}}$ por el vector de la producción bruta inicial sectorial $\tilde{\mathbf{x}}$: $\mathbf{a}^1 = \text{diag}^{-1}(\tilde{\mathbf{x}})\tilde{\mathbf{I}}$.

Para llevar a cabo la producción, los distintos sectores emplean mano de obra junto con el stock de insumos que acumularon en el pasado (esto incluye al sector energético), que transforman de acuerdo a una función de producción de coeficientes fijos, es decir, de Leontief. Esto quiere decir que la producción máxima que cada sector puede producir está dada por:

$$\mathbf{x}_t^{\max} = \min \left[\text{diag}^{-1}(\mathbf{a}^1)\mathbf{l}_t, \text{colmin} \left(\mathbf{Z}_{t-1}^{\text{inv}} \circledast \mathbf{A} \right) \right], \quad (1.3)$$

donde \otimes indica división elemento por elemento y \mathbf{Z}^{inv} es una matriz que contiene el stock de inventarios de insumos acumulados por los sectores a lo largo del tiempo. Como lo expresa esta función, el nivel de producción sectorial está limitado por el menor de dos valores: la capacidad de producción limitada por la mano de obra ($\text{diag}^{-1}(\mathbf{a}^1)\mathbf{l}_t$) y la capacidad de producción limitada por insumos intermedios ($\text{colmin}(\mathbf{Z}_{t-1}^{\text{inv}} \otimes \mathbf{A})$). Como se mencionó previamente, esta función de producción excluye la posibilidad de sustitución entre productos de diferentes sectores y entre productos de los mismos sectores pero de diferentes países. Consideramos que esta modelización representa una aproximación válida en un análisis a corto plazo, ya que es probable que lleve tiempo encontrar nuevos proveedores para un bien si un insumo proveniente de un país en particular deja de estar disponible repentinamente (Fernandez-Stark y Gereffi, 2019; Baqaee y Farhi, 2020).

1.2.3 Demanda intermedia y expectativas

La demanda de bienes recibida por cada sector, indicada por \mathbf{x}^{d} , está compuesta por la demanda final (\mathbf{y}) y la demanda para los insumos recibidos de otros sectores productivos, \mathbf{Z}^{d} . La cantidad de insumos que cada sector demanda, así como también la fuerza de trabajo necesaria son determinadas por sus expectativas de demanda/ventas. Distinguimos entre dos tipos de demanda esperada: de corto y de largo plazo.

Las expectativas a corto plazo $\mathbf{x}_t^{\text{e,CP}}$ expresan la demanda que los sectores en los distintos países esperan recibir en el período actual. En ausencia de shocks, determinan (1) la cantidad de mano de obra adicional (si la hay), (2) qué sectores desean contratar, y (3) la cantidad de insumos que demandan de otros sectores/países para reemplazar los que esperan utilizar en la producción del período actual. Los agentes igualan la respectiva demanda recibida en el período anterior, pero se asume que luego de que un shock toma lugar, los sectores conocen la consecuente reducción de la capacidad productiva de sus clientes y ajustan en consecuencia sus expectativas de ventas a corto plazo. Esto se encuentra en línea con la existencia de relaciones comerciales estables y asociaciones entre empresas *upstream* y *downstream* a lo largo de las cadenas de suministro (Fernandez-Stark y Gereffi, 2019). Por lo tanto, las expectativas a corto plazo se obtienen como⁶:

$$\mathbf{x}_t^{\text{e,CP}} = \mathbf{x}_{t-1}^{\text{d}} + \mathbf{A} \left[\text{diag}^{-1}(\mathbf{a}^{\text{m}}) \Delta \mathbf{m}_{t,t-1} \right], \quad (1.4)$$

donde \mathbf{m} se define de función del tipo de evento: en el caso de un shock sobre la oferta laboral en un conjunto de sectores $\mathbf{m} = \mathbf{l}$; mientras que si el evento disruptivo tiene lugar en las ventas de un sector localizado en un país específico, lo que se ve afectado es $\mathbf{a}^{\text{m}} = \mathbf{a}_i^{\text{r}}$, con \mathbf{r}, \mathbf{i} iguales al país-sector que ya no realiza envíos externos. La variación entre el período previo al shock y

⁶En el anexo (sección 1.6.2) se presenta un análisis de robustez de los resultados principales ante cambios en la forma de modelizar las expectativas.

aquel en el que el mismo tiene lugar está dada por $\Delta \mathbf{m}_{t,t-1} = \Delta \mathbf{a}_{i,t,t-1}^r$. Por lo tanto, para cada tipo de shock las expectativas de corto plazo quedan determinadas por:

$$\mathbf{x}_t^{e,CP,1} = \mathbf{x}_{t-1}^d + \mathbf{A} \left[\text{diag}^{-1}(\mathbf{a}^l) \Delta \mathbf{l}_{t,t-1} \right], \quad (1.5)$$

$$\mathbf{x}_t^{e,CP,2} = \mathbf{x}_{t-1}^d + \mathbf{A} \left[\text{diag}^{-1}(\mathbf{a}_i^r) \Delta \mathbf{a}_{i,t,t-1}^r \right]. \quad (1.6)$$

Luego, cada sector j calcula la cantidad de insumos que necesita para la producción en función de estas expectativas a corto plazo, limitado por la cantidad de trabajadores actualmente disponibles que determina la cantidad que realmente pueden emplear. Por lo tanto, realizan pedidos de insumos (nacionales y extranjeros) para fines de producción a corto plazo de acuerdo con

$$[\mathbf{z}_{jt}^{d,CP}]^C = [\mathbf{a}_j]^C \min \left(x_{jt}^{e,CP}, \frac{l_{jt}}{a_j} \right). \quad (1.7)$$

Las expectativas a largo plazo, $\mathbf{x}_t^{e,LP}$, se modelan como un promedio simple de la demanda pasada durante un total de períodos $\gamma \in \mathbb{Z}^+$, con γ uniforme en todos los sectores:

$$\mathbf{x}_t^{e,LP} = \frac{\sum_{i=1}^{\gamma} \mathbf{x}_{t-i}^d}{\gamma}. \quad (1.8)$$

Estas expectativas impulsan un nivel objetivo de inventarios de insumos que los sectores desean mantener para sostener la producción al nivel esperado a largo plazo durante un horizonte de planificación específico del sector. A partir de ellas, los sectores determinan un nivel objetivo de inventarios, que está dado por $\beta_j \in \mathbb{Z}^+$ veces la cantidad de insumos intermedios necesarios para producir $\mathbf{x}_t^{e,LP}$, lo que implica el supuesto de que todos los insumos utilizados son almacenables/inventariables. Siguiendo a [Reissl et al. \(2022\)](#) cada sector tiene una velocidad de ajuste de sus inventarios específica, dada por $\frac{1}{\beta_j}$, lo que implica que todos los sectores convergen asintóticamente a sus objetivos, pero el ajuste será rápido para los sectores con horizontes de planificación cortos y lento para los sectores con horizontes largos. Formalmente, la demanda del sector j de los insumos –nacionales y extranjeros– necesarios para la planificación de la producción a largo plazo está dada por:

$$[\mathbf{z}_{jt}^{d,LP}]^C = \frac{1}{\beta_j} \left(\beta_j \mathbf{a}_j^C x_{jt}^{e,LP} - [\mathbf{z}_{jt}^{inv}]^C \right). \quad (1.9)$$

La producción en t se realiza con existencias de insumos materiales que vienen de $t-1$ y la mano de obra disponible en t (en ausencia de shocks dada por $\mathbf{x}_t^{e,CP}$). La producción máxima para cada sector en t está determinada por \mathbf{x}_t^{\max} , mientras que la producción bruta está dada por el mínimo entre \mathbf{x}_t^{\max} y la demanda total de los productos de cada sector \mathbf{x}_t^d . Por lo tanto, la

producción puede ser inferior a la demanda ante una restricción a la mano de obra o en otros insumos.

1.2.4 Demanda final

La demanda final (\mathbf{y}_t) se define como la suma entre el consumo (\mathbf{c}_t) y la inversión (\mathbf{i}_t). La inversión se define como una función lineal de la desviación del producto total \mathbf{x}_{t-1} de su nivel de referencia $\tilde{\mathbf{x}}$ (producción obtenida directamente de la tabla insumo producto entre países empírica). La demanda de inversión se determina de acuerdo con

$$\mathbf{i}_t = \tilde{\mathbf{i}} + \delta \frac{\tilde{\mathbf{i}}}{\eta' \tilde{\mathbf{i}}} (\eta' \mathbf{x}_{t-1} - \eta' \tilde{\mathbf{x}}), \quad (1.10)$$

donde $\tilde{\mathbf{i}}$ es el vector de demanda de inversión sectorial tomado de la tabla insumo producto entre países empírica, δ es un parámetro que determina la magnitud de la reacción de la demanda de inversión a los cambios en la producción, y η es un vector suma con todos los elementos iguales a uno. De esta manera, los cambios en la demanda de inversión agregada, dados por $\delta (\eta' \mathbf{x}_{t-1} - \eta' \tilde{\mathbf{x}})$, se distribuyen entre los sectores productivos de acuerdo con las participaciones sectoriales en la demanda de inversión tomadas de la matriz insumo producto observada.

El consumo se compone de una parte endógena (\mathbf{c}_t^1) y otra exógena (\mathbf{c}_t^2). La parte endógena corresponde al consumo inducido por la remuneración a los trabajadores, mientras que el componente exógeno se calcula como un remanente para asegurar que $\mathbf{c}_t^1 + \mathbf{c}_t^2 = \tilde{\mathbf{c}}$ y, por lo tanto, $\mathbf{x}_t = \tilde{\mathbf{x}}$. Formalmente, el componente endógeno se calcula a partir de una matriz \mathbf{H} que vincula el vector de producto \mathbf{x}_{t-1} con el componente endógeno del consumo. Formalmente:

$$\begin{aligned} \mathbf{c}_t^1 &= \mathbf{H} \mathbf{x}_{t-1} \\ \mathbf{c}_t^2 &= \tilde{\mathbf{c}} - \mathbf{H} \tilde{\mathbf{x}} \end{aligned} \quad (1.11)$$

con $\tilde{\mathbf{c}}$ el consumo total sectorial obtenido de los valores empíricos observados en la tabla insumo producto entre países.

Dado un país s , cada unidad de su producción bruta puede consumirse como un bien final o usarse como un bien intermedio en el país o en el extranjero:

$$\mathbf{x}^s = \sum_r^n (\mathbf{A}^{sr} \mathbf{x}^r + \mathbf{y}^{sr}) \quad (1.12)$$

donde \mathbf{y}^{sr} es la demanda de bienes finales que producidos en s y destinados al país r . El país r puede ser el mismo s o cualquier país importador. Entonces, la relación básica entre la producción bruta y la demanda final viene dada por:

$$\mathbf{x} = (\mathbf{I} - \mathbf{A})^{-1} \mathbf{y}, \quad (1.13)$$

lo que se encuentra en línea con el modelo estándar insumo-producto de [Leontief \(1986\)](#), donde $(\mathbf{I} - \mathbf{A})^{-1}$ es la inversa de Leontief “global” de dimensión $nk \times nk$ que mide las unidades totales de producción bruta en los países-sectores de origen necesarias para producir una determinada unidad de bienes/servicios finales. Representa toda la producción bruta producida en todas las rondas de producción, como $(\mathbf{I} - \mathbf{A})^{-1} \simeq \mathbf{I} + \mathbf{A} + \mathbf{A}^2 + \mathbf{A}^3 + \dots$, siendo esta su aproximación en serie de potencias de Leontief. La respuesta de un sistema estándar de Leontief ante un cambio en la demanda final puede ser aproximado mediante:

$$\Delta \mathbf{x} = (\mathbf{I} - \mathbf{A})^{-1} \Delta \mathbf{y} \simeq (\mathbf{I} + \mathbf{A} + \mathbf{A}^2 + \mathbf{A}^3 + \dots) \Delta \mathbf{y} = \Delta \mathbf{y} + \mathbf{A}^2 \Delta \mathbf{y} + \mathbf{A}^3 \Delta \mathbf{y} + \dots \quad (1.14)$$

donde \mathbf{x} es el vector de producción sectorial e \mathbf{y} es el vector de demanda final. La interpretación económica de esta formulación es que cada término sucesivo en la aproximación en serie de potencias representa la magnitud del impacto, ronda por ronda, de un cambio en la demanda final sobre la producción sectorial. El primer término indica que la producción se adapta a los niveles de demanda, mientras que el segundo término captura el efecto indirecto de primer orden. Esto es, dado que la producción sectorial cambió, la demanda de insumos también cambia, induciendo un mayor ajuste en la producción de los sectores y así sucesivamente. El efecto total sobre la producción bruta eventualmente converge a la solución analítica del modelo de Leontief.

1.3 Estimación del modelo y especificación de los shocks

Para la estimación y análisis de simulación del modelo, se utilizan las matrices insumo-producto entre países de la OECD (ICIO, por sus siglas en inglés, *Intercountry Input-Output table*)⁷. La base de datos posee información de las transacciones sectoriales a nivel nacional e internacional para 71 países y 45 sectores. Dadas las limitaciones de la calibración empírica respecto a la información disponible para algunos países, trabajamos con 36 países y agrupamos el resto en “resto del mundo”⁸. Por lo tanto, en nuestro análisis tenemos $k = 44$ ⁹ y $n = 37$. La desagregación

⁷Remitimos al lector interesado a [Guilhoto et al. \(2022\)](#) para mayores detalles acerca de la construcción y utilización de esta base de datos.

⁸En el resto del mundo se agrupan o agregan los países que están disponibles en la tabla ICIO empírica pero para los que no se cuenta con información acerca de la evolución mensual de la producción, serie necesaria para la calibración del modelo. Los mismos se adicionan al “resto del mundo” que ya tiene presente la tabla ICIO empírica en sí. Luego, en el modelo, el resto del mundo se incorpora como un país más, con la misma desagregación sectorial que el resto de los países.

⁹Excluimos del análisis al sector “Actividades de hogares privados como empleadores y actividades no diferenciadas de hogares privados como productores”, ya que no se cuenta con información completa para todos los países y representa una porción marginal del producto a nivel nacional en gran parte de los países incluidos en el estudio.

sectorial es *ad-hoc*, pero tiene su correspondencia con el Clasificador Internacional Industrial Uniforme (CIIU) Rev. 4 a dos dígitos. Utilizamos la versión más reciente (noviembre de 2021) que abarca los años 1995 a 2018.

Para la estimación de la matriz \mathbf{H} que permite estimar el consumo endógeno en nuestro modelo (ver ecuación (1.11)), utilizamos esta misma base de datos, en conjunto con la información sobre la remuneración a los trabajadores por sector y el número total de empleados por sector que brinda la OECD. Seguimos una adaptación del enfoque propuesto por Miyazawa (1968), dado que no contamos con la información completa para aplicarlo plenamente. Como primer paso estimamos la remuneración sectorial bruta de los trabajadores por unidad de producción, y luego descontamos los impuestos netos de subsidios calculados también por unidad de producto. Finalmente, multiplicamos estos valores por la propensión al consumo media de cada sector-país específico, calculadas a partir de los datos de la matriz ICIO. Como resultado, obtuvimos la matriz \mathbf{H} , que al multiplicarla por \mathbf{x} nos da un vector que representa la demanda de consumo inducida por la remuneración de los trabajadores que recibe cada sector.

En líneas generales, seguimos el procedimiento de estimación de Reissl *et al.* (2022) y realizamos algunas simplificaciones para reducir la dimensionalidad del espacio e identificar los parámetros (Grazzini y Richiardi, 2015). Como se mencionó previamente, el sector j utiliza el parámetro específico del sector $\beta_j \in \mathbb{Z}^+$ para determinar su stock objetivo de inventarios de insumos intermedios en términos de períodos de producción futura, al momento de realizar sus pedidos para la acumulación de inventario de insumos en función de las expectativas a largo plazo. En la estimación, restringimos a β_j para que sea uniforme en todos los sectores que forman parte de los siguientes grupos (1) agricultura (sectores 1 y 2), (2) minería (sectores 3 a 5) (3) industria manufacturera (sectores 6 a 22), (4) energía y agua (sectores 23 y 24), (5) construcción (sector 25) y (6) servicios (sectores 26 a 44). Los parámetros restantes son δ , que da el grado en que la inversión reacciona a los cambios en la producción, y γ , que identifica el número de observaciones pasadas incluidas en las expectativas de demanda a largo plazo, lo que da un total de ocho parámetros a estimar.

Para determinar los valores de estos parámetros utilizamos un algoritmo inspirado en el método de momentos simulados (MMS) (Gilli y Winker, 2003). El objetivo es encontrar un vector de parámetros tal que se minimice la distancia (ponderada) entre un conjunto de momentos elegidos para las estadísticas calculadas a partir de datos empíricos y simulados. Es decir, se busca la combinación de parámetros para la cual un modelo dado es capaz de reproducir las características generales de una o más series de tiempo empíricas en términos de sus momentos, como la desviación estándar o estructuras de autocorrelación. La selección de estadísticas en este trabajo, fue elaborada para resumir algunas características relevantes de la crisis por la pandemia de COVID-19 y aquella derivada por el conflicto entre Rusia y Ucrania que se manifiestan de manera heterogénea a nivel sectorial. De esta manera, el modelo podría constituir una herramienta útil para evaluar, por ejemplo, los posibles efectos futuros en términos de pérdida de producción

sectorial de medidas similares a las de aislamiento social obligatorio o a la decisión de no adquirir más bienes de un determinado país.

Utilizamos índices mensuales de producción sectorial, agrupados de la manera en la que se describió previamente para el caso del parámetro β , desagregación que se encuentra presente en las estadísticas disponibles. Las fuentes de información fueron las siguientes:

1. La base de datos de Eurostat para los grupos de sectores (2) a (6) para 31 de los 36 países modelizados. Índices de producción mensual.
2. Para el caso del sector agrícola se recurrió a las bases de datos de la FAO, que proveen información cuatrimestral, para 26 de los 36 países estudiados.
3. Finalmente, se recurrió a las estadísticas nacionales para los casos de Canadá, Japón, Estados Unidos, China y Rusia; obteniendo índices cuatrimestrales de producción para los sectores (3), (4) y (6).

Estos datos nos permiten calcular los índices de producción durante el período considerado para los sectores representados en el modelo. Las series temporales empíricas se utilizan luego para calcular las siguientes estadísticas, que se emplean como momentos en el procedimiento de estimación: (1) la caída máxima en cada uno de los índices mensuales de producción; y (2) estadísticas calculadas aplicando el algoritmo GSL-div desarrollado por [Lamperti \(2018\)](#) –que da una medida de la similitud de la forma de dos series de tiempo– a las series de tiempo empíricas para la producción industrial y sus contrapartes simuladas. El primer elemento captura la profundidad de la recesión para cada sector (de manera agregada, de acuerdo a los datos disponibles), mientras que el segundo proporciona una evaluación cuantitativa sintética de la similitud general entre las series temporales empíricas y simuladas para la producción mensual, por lo que evalúa la capacidad del modelo para igualar la velocidad de la caída y la recuperación posterior al shock.

Dado que no es posible aplicar las teorías asintóticas existentes para MMS al procedimiento de estimación, por la naturaleza y extensión de las series temporales utilizadas, adoptamos una matriz de ponderación pre-especificada en lugar de la matriz “óptima/eficiente” ([Reissl et al., 2022](#)). En particular, hacemos uso de una matriz de ponderación que emplea la participación de la producción sectorial en la producción total como una medida simple de la importancia de los diferentes sectores y ponderar las estadísticas correspondientes en consecuencia. Al respecto, [Cochrane \(2009, p. 210-215\)](#) señala que la matriz de ponderación óptima puede otorgar “*mucho peso a aspectos mal estimados, económicamente poco interesantes o no robustos de la data*”, cuando al contrario lo que se busca es “*forzar la estimación y evaluación para prestar atención a los momentos económicamente interesantes*”. En este sentido, destaca que el uso de una matriz predefinida “*permite enfatizar resultados económicamente interesantes*”, al tiempo que se obtienen estimaciones “*consistentes y pueden ser más robustas a problemas estadísticos y económicos*”. Esta información se obtiene directamente de la matriz insumo producto observada empíricamente (tabla ICIO-OECD).

A continuación se describe la especificación de los dos tipos de shocks considerados.

1.3.1 Interrupción del normal funcionamiento de sectores productivos

En primer lugar, modelizamos un shock que afecta a un conjunto de sectores en distintos países del mundo. Modelizamos el shock como una restricción sobre la oferta disponible de mano de obra, que se trasladará a la producción real y también a la demanda final. Tomamos como ejemplo el caso de las restricciones sectoriales en el marco de la pandemia por COVID-19 para la selección de los sectores impactados en el escenario base, lo que nos permite calibrar el modelo en base a la evolución empírica de la producción sectorial.

Dado que la fuerza laboral inicial \mathbf{l} de cada sector se normaliza en 100, los shocks sobre la oferta laboral se definen como desviaciones porcentuales de ese nivel de referencia. Por ejemplo, un shock negativo del 10% para un sector implica una reducción absoluta de 10 unidades laborales. El empleo del sector se mantiene constante en 90 unidades durante el evento disruptivo y luego vuelve a su valor normalizado. Específicamente, definimos el shock sobre la mano de obra para el período que abarca entre $t = 14$ y $t = 18$; esto corresponde a 5 semanas calendario o un mes¹⁰.

Formalmente, sea $\tilde{\mathbf{l}}_t$ la cantidad de mano de obra disponible para cada sector en cada economía en el período t , y ϵ_t el shock a la oferta laboral que ocurre en ese período, expresado como una desviación porcentual de $\tilde{\mathbf{l}}$. Los shocks toman lugar de manera inmediata en el período en que están definidos, por lo que si alcanza al sector j la oferta de trabajo se encontrará por debajo del nivel inicial $\tilde{\mathbf{l}}$, es decir $\mathbf{l}_{jt-1} + \tilde{\mathbf{l}} \frac{\epsilon_{jt}}{100} < \tilde{l}_j$. Por lo tanto, \mathbf{l}_t estará dado por:

$$\mathbf{l}_t = \left(\mathbf{l}_{t-1} + \tilde{\mathbf{l}} \circ \frac{\epsilon_t}{100} \right), \quad (1.15)$$

donde \circ indica multiplicación elemento por elemento¹¹.

La caída en los pedidos de insumos (demanda intermedia) que enfrenta un sector del resto de los sectores productivos puede obtenerse pre-multiplicando la matriz de insumos \mathbf{A} por cuánto se ve afectada la disponibilidad de mano de obra de los distintos sectores, lo cual está dado por $\text{diag}^{-1}(\mathbf{a}^1) \Delta \mathbf{l}_{t,t-1}$. Esto se incorpora en las expectativas de corto plazo, como lo establece la ecuación (1.5).

Para determinar la magnitud de los shocks, en primer lugar construimos una medida de la participación de la mano de obra que deja de estar disponible, para cada uno de los 44 sectores y 36 países, considerando inicialmente los sectores específicos sobre los que hubo cierres obligatorios

¹⁰La extensión en el tiempo y momento en el que el shock toma lugar, fue seleccionado de acuerdo al período donde coincidieron las mayores restricciones sobre los sectores productivos (centralmente industriales). Para más detalles sobre cómo fueron los pasos en el caso de la pandemia por COVID-19, se puede consultar del [Rio-Chanona et al. \(2020\)](#), quienes toman el modelo italiano, o las estadísticas sobre la pandemia de la OECD. Aquí intentamos representarlo solo de modo general.

¹¹Para el caso de los sectores que no son alcanzados por el shock la oferta laboral en las simulaciones se determina como $\max(\tilde{\mathbf{l}}, \mathbf{x}_t^{\text{e,CP}} \circ \mathbf{a}^1)$.

durante la pandemia de COVID-19. Para ello, utilizamos las estimaciones provistas por [del Rio-Chanona et al. \(2020\)](#), y las asignamos a los sectores productivos en los distintos países que forman parte del modelo¹². Esta estimación fue realizada para poder estimar y calibrar el modelo en este escenario.

Finalmente, respecto al período de las series empíricas para la estimación/calibración del modelo bajo este tipo de shock, tomamos aquel que abarca desde enero de 2020 a diciembre de 2020, lo que da un período de un año (es decir, 12 meses o 53 semanas).

1.3.2 Interrupción en el suministro internacional en un país

En el segundo tipo de evento, modelizamos una interrupción completa del suministro de los bienes de un sector localizado en un país en particular. Este shock lo modelizamos como una restricción al comercio internacional para el sector energético de un país específico. Tomamos como base, el caso de la escalada del conflicto entre Rusia y Ucrania que tuvo su estallido hacia fines de febrero de 2022, y que fue el puntapié inicial para la toma de medidas a modo de sanciones económicas por parte de diferentes países, centralmente, de la Unión Europea¹³. Al igual que con el caso de la interrupción en el normal funcionamiento de determinados sectores productivos, basarnos en este hecho histórico nos permite calibrar el modelo en base a la evolución empírica real de la producción y comercio sectoriales.

Este shock está modelizado como una caída en la disponibilidad de energía. Es decir, se remueven los links que conectan al sector energético en Rusia con los distintos sectores europeos. Esto hace que para la producción en general tengan menor disponibilidad de este bien, el cual requieren en una proporción determinada (recordar que la función de producción es de coeficientes fijos). El shock implica una pérdida de este insumo de la proporción que representa Rusia en lo que le demanda cada sector a dicho país. Dado que la energía es un bien básico en todo proceso productivo –especialmente industrial– y que el modelo no admite su sustitución en el corto plazo (aunque sí, la acumulación de inventarios), esto hace caer la producción en los sectores anteriormente conectados ante la imposibilidad de sustitución inmediata y se refleja en la demanda intermedia del modelo. Éste análisis se desarrolla en línea con el proceso de “eliminación de links” (ver [Bellingeri et al., 2020](#), por ejemplo).

Si bien usualmente las estrategias de remoción de vínculos se aplican para evaluar la robustez de la red e identificar los links más relevantes para la estabilidad de la misma, en este caso procederemos a eliminarlos de manera direccionada. Específicamente, planteamos un escenario en el que se ven interrumpidas las exportaciones de energía de Rusia a los países Europeos, similar al escenario más disruptivo planteado por [Bouwmeester y Oosterhaven \(2017\)](#).

¹²del [Rio-Chanona et al. \(2020\)](#) estiman la proporción de trabajadores en cada industria que se vieron afectados por las restricciones de movilidad, considerando la definición de sectores esenciales y no esenciales de países de Europa Occidental y el Índice de Trabajo Remoto.

¹³Para más detalles sobre este conflicto ver, por ejemplo [D’Anieri \(2023\)](#), o [Mottaleb et al. \(2022\)](#) y [Umar et al. \(2022\)](#) para exploraciones empíricas sobre sus consecuencias económicas.

Formalmente, esta estrategia implica igualar a cero los elementos de la matriz \mathbf{Z} que indican la existencia de un vínculo entre el sector energético ruso y los países europeos, como lo indica la ecuación (1.16). Asimismo, se iguala a cero la demanda final de los bienes de este sector-país por parte de las economías europeas.

$$\sum_j^{r,s \in EU} z_{ij}^{rs} + y_i^{rs} = 0, \text{ para } i \in \{23\text{-Electricidad y gas natural; } 03\text{-Minas-energéticos}\}, \quad (1.16)$$

donde EU indica el conjunto de países pertenecientes a Europa. Los índices r y s indican país de origen (es decir, Rusia) y destino, respectivamente. Por último, el índice j refiere al sector de destino (demandante de energía rusa).

Finalmente, respecto al período de las series empíricas para la estimación/calibración del modelo bajo este tipo de shock, tomamos aquel que abarca desde diciembre de 2021 a noviembre de 2022.

1.3.3 Descripción general de la configuración del modelo

El Cuadro 1.1 muestra una descripción general de los elementos del modelo. Para modelizar ambos tipos de shock mantuvimos una economía compuesta por 37 países y 44 sectores, como se especificó previamente. La secuencia de eventos descrita en la sección 1.2.1 se repite a lo largo de 53 períodos, cuya unidad temporal es de una semana.

En ambos casos se considera al número sectorial de trabajadores como un numerario, para simplificar la estimación del modelo y determinación de los shocks de oferta. Asimismo, hay un conjunto de variables que se determinan de manera exógena, es decir que son tomadas directamente de la matriz insumo producto empírica (tabla ICIO-OECD). Estos valores son nacionales y sectoriales, por lo que el cuadro solo muestra el valor de la mediana¹⁴.

Finalmente, se pueden observar los valores de los parámetros de la combinación obtenida en el proceso descrito en la sección 1.3, para ambos tipos de shock considerados. En ambos casos –aunque con mayor énfasis en el primer shock modelizado– el valor de γ sugiere cierta estabilidad en las expectativas a largo plazo y una reacción débil de las mismas ante cambios transitorios en las ventas.

¹⁴Los valores específicos para cada sector-país pueden encontrarse en la tabla ICIO de la OECD correspondiente al año 2018.

Cuadro 1.1: Valores de los parámetros y otros elementos necesarios para la estimación del modelo, dos tipos de shock.

Denominación	Descripción	Shock Tipo 1	Shock Tipo 2
Agentes			
n	Número de países	37.00	37.00
k	Número de sectores	44.00	44.00
T	Longitud temporal de las simulaciones	53.00	53.00
Parámetros			
δ	Parámetro de ajuste de la inversión	0.06	0.09
γ	Expectativas de largo plazo	46.00	31.00
β_{agro}	Agricultura, inventarios deseados	18.00	21.00
β_{min}	Minería, inventarios deseados	16.00	18.00
β_{ind}	Manufacturas, inventarios deseados	13.00	17.00
β_{ener}	Energía, inventarios deseados	25.00	26.00
β_{cons}	Construcción, inventarios deseados	25.00	28.00
β_{serv}	Servicios, inventarios deseados	11.00	19.00
Numerario			
\bar{I}	Trabajo sectorial, valor inicial	100.00	100.00
Valores matriz			
\bar{x}	Producción sector-país, mediana	7257.00	7257.00
\bar{c}	Consumo total sector-país, mediana	0.12	0.12
\bar{z}	Demanda intermedia sector-país, mediana	8.07	8.07
\bar{i}	Inversión total sector-país, mediana	5.93	5.93

Nota: los valores obtenidos de la matriz insumo producto se expresan en millones de dólares.

1.4 Resultados de la simulación

En la presente sección, realizamos simulaciones del modelo presentado en las secciones previas para evaluar, por un lado, el impacto de un shock sobre un conjunto de sectores productivos en diferentes países del mundo, tomando el caso de la pandemia de COVID como base; y, por el otro, el impacto de un shock que afecte la interrupción del suministro de un sector por parte de un país en el comercio internacional.

1.4.1 Shock 1: Shock sobre la oferta de trabajo sectorial

La Figura 1.2 muestra una comparación de la evolución de la producción sectorial simulada (mensualizada) en el modelo y la empírica (mensual, para el período enero-2020 a diciembre-2020). En líneas generales, se observa una caída repentina de la actividad económica –representada por la producción sectorial– en el momento en que el shock sobre la mano de obra tiene lugar. Si bien todas las industrias continúan luego en un sendero de recuperación, este es asimétrico a lo largo de ellas. Como puede observarse, en la mayoría de los casos el modelo puede reproducir tanto la caída de la producción como la recuperación posterior. No obstante, también se observan instancias en las que el modelo no logra reproducir la dinámica observada. Esto se debe a que el modelo no puede capturar algunas características específicas de las recesiones inducidas por un evento como lo fue la pandemia por COVID-19, en la que se conjugaron más factores al confinamiento que

restringieron la oferta laboral (único shock directo incorporado en este análisis). Por ejemplo, las limitaciones obligatorias y voluntarias a la movilidad de los consumidores probablemente impedían o desalentaban el consumo de ciertos tipos de bienes y servicios, algo que en el modelo no está representado. En líneas generales, se observa una correlación significativa entre los productos de diferentes sectores tanto en los datos empíricos como en los simulados.

A nivel agregado, el modelo establece una reducción en la producción bruta global del 32.1%, en el mes 4 respecto del período de inicio (mes 1). Si bien la unidad de tiempo en las simulaciones es una semana, se mensualiza este valor a fines de poder compararlo con la información empírica. La caída en la producción entre enero y abril de 2020 observada en los datos empíricos para el total de países considerados en la muestra fue del 28.3%. Este efecto total sobre la producción se explica por el efecto directo del shock –es decir, de la reducción en la oferta laboral disponible para un conjunto de sectores–, pero también por los efectos indirectos o de orden superior que tienen lugar por el hecho de que los distintos sectores y países, se encuentran conectados a través de relaciones comerciales. A continuación, intentamos acercarnos a la contribución relativa de los efectos directos e indirectos –es decir, los efectos de orden superior– para diferentes industrias y países, con el objetivo de comprender mejor los factores que impulsan y/o amplifican a las fluctuaciones económicas tanto a nivel local como global¹⁵.

Se busca identificar cuánto de la caída en la producción se debe al shock en sí mismo y cuánto se explica por la caída en la demanda intermedia del resto de los sectores. Así buscamos evaluar el efecto indirecto que se debe a la interrupción o reducción del peso de links productivos en eslabonamientos complejos. Para ello, en primer lugar, definimos el efecto directo sobre la producción ($\Delta \mathbf{x}_{t,t-1}^{\text{dir}}$) como la caída en la misma que se produce como consecuencia únicamente de las restricciones de oferta en la mano de obra en determinados sectores. Por simplicidad en la notación, denotamos la variación de manera general como $t, t-1$, pero con esto nos estamos refiriendo a la variación respecto al período previo (de la misma extensión) a aquel en el que el shock toma lugar. Como mencionamos previamente, el shock (restricciones asimétricas a la oferta de trabajo sectorial) se mantiene durante el período que abarca $t \in [14, 18]$, es decir 5 semanas o un mes.

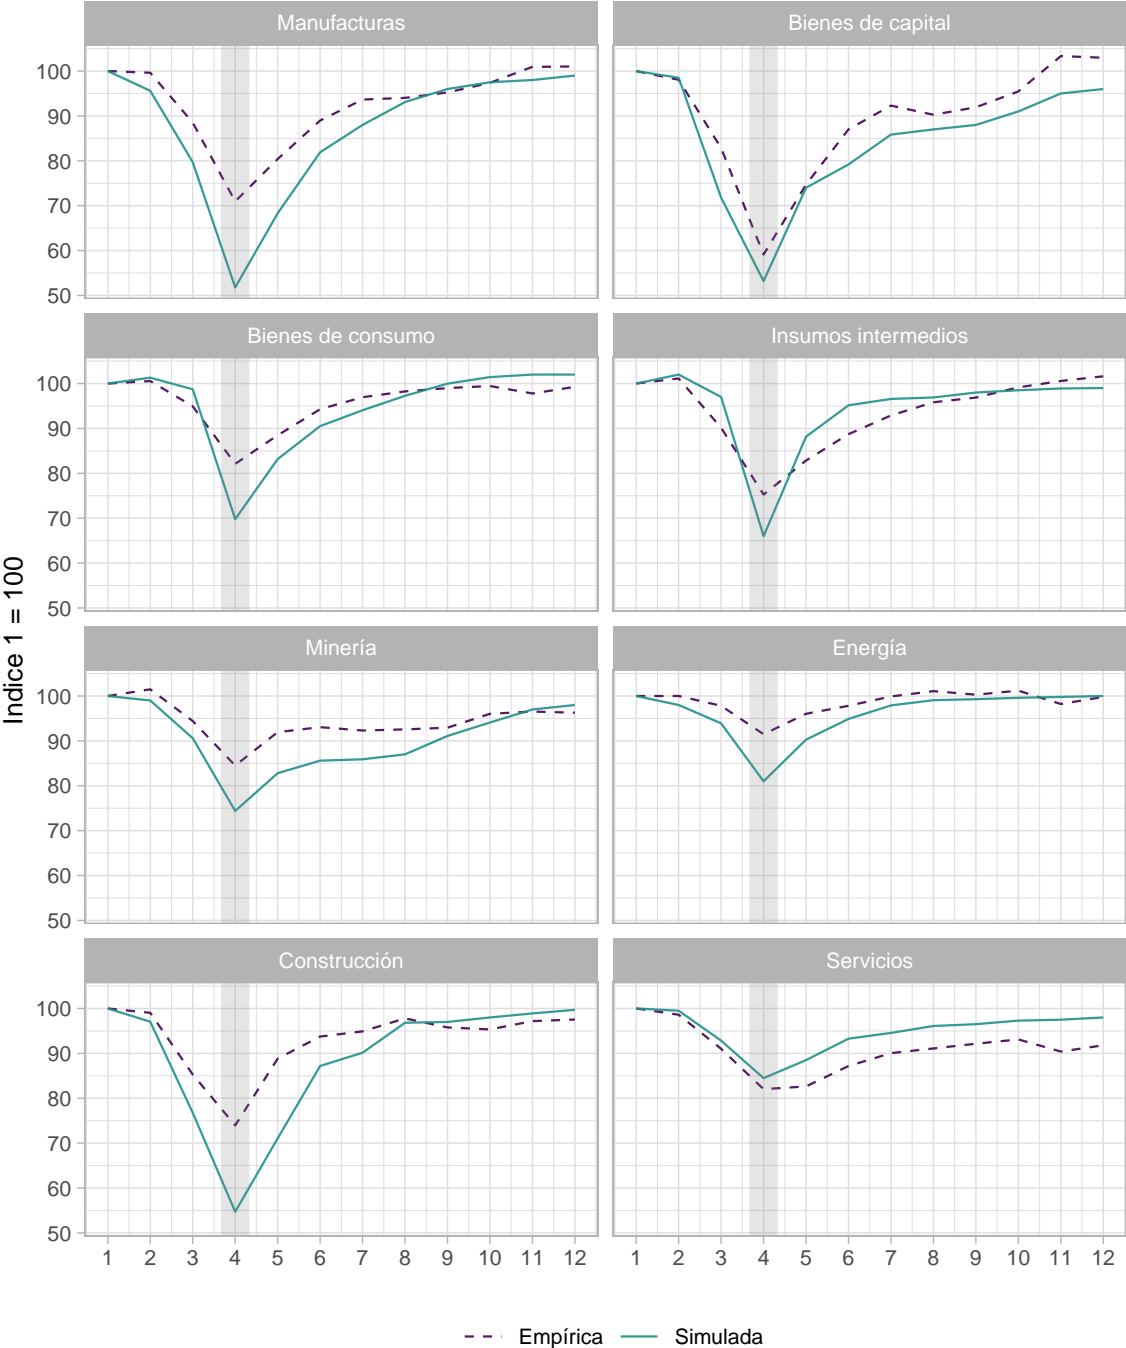
El trabajo es un factor productivo en la función de producción –como lo expresa la ecuación (1.3)–, por lo que la variación/caída en la producción como consecuencia en la reducción de este factor puede expresarse como:

$$\Delta \mathbf{x}_{t,t-1}^{\text{dir}} = \text{diag}^{-1}(\mathbf{a}^l) \Delta \mathbf{l}_{t,t-1}. \quad (1.17)$$

Es decir, que la caída en la producción explicada por el efecto directo del shock es proporcional a la reducción en la mano de obra disponible para cada sector. Esto se justifica porque los

¹⁵A fines expositivos, especificamos los efectos sobre la producción bruta, los efectos sobre otras variables como la demanda intermedia, el consumo o la inversión, pueden encontrarse de manera análoga.

Figura 1.2: Evolución de la producción sectorial en los datos simulados y empíricos. Sectores seleccionados.



shocks exógenos sobre la oferta de trabajo conducen a una reducción inmediata de la producción bruta.

Por otro lado, identificamos al efecto indirecto o de orden superior del shock, que es aquel que surge endógenamente por el hecho de que los distintos sectores se encuentran interconectados por relaciones comerciales. El efecto indirecto en sí depende del tiempo y de cómo los sectores económicos se van ajustando a los cambios en la demanda de insumos intermedios por parte del resto de los sectores, localizados tanto localmente como en el exterior. No obstante, en nuestro modelo es posible identificar una parte del mismo en el momento t en que el shock toma lugar, debido a cómo están especificadas las expectativas de corto plazo. Para analizar la descomposición del shock, tomamos el último período en el cual se mantuvieron las restricciones de oferta a la mano de obra; ya que los valores en este período conservan la información del proceso de amplificación del shock. Como lo expresa la ecuación (1.4), las expectativas de corto plazo –que determinan el nivel de producción en el período t – incorporan la caída en los pedidos de insumos como consecuencia del shock en la oferta laboral de sectores vinculados a ellos. Como se mencionó previamente, esto se obtiene pre-multiplicando la matriz de insumos \mathbf{A} por cuánto se ve afectada la disponibilidad de mano de obra de los distintos sectores como consecuencia del shock (efecto directo):

$$\mathbf{A} \left[\text{diag}^{-1}(\mathbf{a}^1) \Delta \mathbf{l}_{t,t-1} \right]. \quad (1.18)$$

Por lo tanto, el efecto indirecto o de orden superior estará determinado por cuánto cae la producción como consecuencia de la caída de la demanda de insumos intermedios del resto de los sectores. En este sentido, el alcance y magnitud del efecto indirecto depende de cuán interconectada está una industria con el resto de los sectores y el peso que tienen esos vínculos en la red de relaciones comerciales intersectoriales. Esto está expresado en la matriz \mathbf{A} . Es importante tener en cuenta que este efecto sobre la producción tiene lugar en cada unidad de tiempo t en la que se mantengan las restricciones a la mano de obra.

En la Figura 1.3 se presenta una comparación del cambio en la producción sectorial, distinguiendo entre aquel impulsado por el efecto directo y el indirecto. El primero se representa en el eje horizontal, el efecto indirecto se observa en el eje vertical y el tamaño del círculo corresponde a la producción bruta inicial de los diferentes sectores. Por cuestiones expositivas agregamos las ramas productivas, independientemente del país de origen. El efecto directo –es decir, el shock inicial sobre la oferta de trabajo– es el mismo, ya que se trató de la misma manera a cada sector en las diferentes localizaciones geográficas. Ahora bien, el efecto indirecto incorporado considera el asociado a los vínculos con otros sectores tanto a nivel local como global.

Como puede observarse, los sectores ubicados en el extremo superior derecho de la Figura 1.3 se ven levemente afectados por el shock sobre la oferta de trabajo, ya que el tamaño del efecto total sobre la producción es relativamente pequeño. Entre las ramas incluidas en este grupo

se destacan el sector de intermediación financiera (con un efecto indirecto cercano al 10%), la distribución de agua potable y tratamiento de residuos (con un efecto indirecto del 11%) y el sector de pesca (con un efecto indirecto del 15%). En todos estos casos, el efecto directo es igual a cero, mientras que el efecto indirecto no supera el 15%.


Luego, se observa un conjunto de sectores dispersos a lo largo del eje horizontal que experimentan un impacto directo sustancial, pero que no se ven tan afectados por los efectos de orden superior o indirectos. Esto quiere decir que se han visto fuertemente restringidos en lo que hace a la movilidad de la fuerza de trabajo, con pocas posibilidades de realizar trabajo remoto. Al mismo tiempo, se trata de industrias donde el efecto de la caída de la demanda de insumos por parte de otras ramas no ha sido altamente relevante para determinar su propio nivel de producción. Este grupo incluye, entre otros sectores, a la industria maderera, el sector de turismo (hoteles y restaurantes), y la producción de metales básicos. Centralmente, se trata de distintas ramas de la industria manufacturera. En líneas generales, la capacidad productiva de los sectores identificados en este grupo se ha visto limitada por el impacto directo en la oferta de trabajo y no tanto por efectos indirectos.

Finalmente, se puede identificar un último grupo de sectores productivos dispersos a lo largo del eje vertical. Estos sectores se vieron afectados de manera directa por el shock en menor medida, pero su producción cae sustancialmente al final del período en el que el evento disruptivo tiene lugar, como consecuencia de un importante efecto indirecto. Entre esas industrias se encuentran los tres sectores de transporte (aéreo, marítimo y terrestre), el sector de telecomunicaciones, de almacenamiento y los servicios sociales y de salud. Claramente, los sectores que conforman este grupo han sido declarados como “esenciales” al momento de determinar sobre qué sectores y orden de magnitud recaerían las restricciones de oferta de mano de obra, por lo que el efecto directo en la caída de la producción es reducido. No obstante, se han visto afectados por el impacto indirecto, asociado a una caída de la demanda de insumos intermedios al verse reducida la producción en otros sectores.

El Cuadro 1.2 resume lo analizado en la Figura 1.3. Específicamente, muestra la descomposición del efecto de un shock sobre la oferta laboral en el conjunto de sectores agregados, localizados en distintas partes del mundo, en su efecto directo e indirecto. Allí se puede identificar de manera clara, que la industria manufacturera es la que más afectada se vio por el efecto directo de las restricciones impuestas a la oferta de trabajo. Finalmente, de acuerdo a los resultados de nuestro modelo, la caída de la producción en los diferentes sectores a nivel global se debió principalmente al efecto directo sobre la oferta de mano de obra (62%), mientras que el efecto indirecto (local y global) explica el 38% de la caída en la producción global.

La Figura 1.4 muestra información similar a la descrita previamente, pero a nivel países. Es decir, se compara el cambio en la producción nacional, distinguiendo entre la proporción del mismo que corresponde al efecto directo y la que corresponde al indirecto. El tamaño del círculo corresponde a la participación en la producción bruta inicial de los diferentes países, dato extraído de la

Figura 1.3: Comparación efecto directo e indirecto del shock sobre la oferta de trabajo, en términos de reducción de la producción sectorial global. En porcentajes.



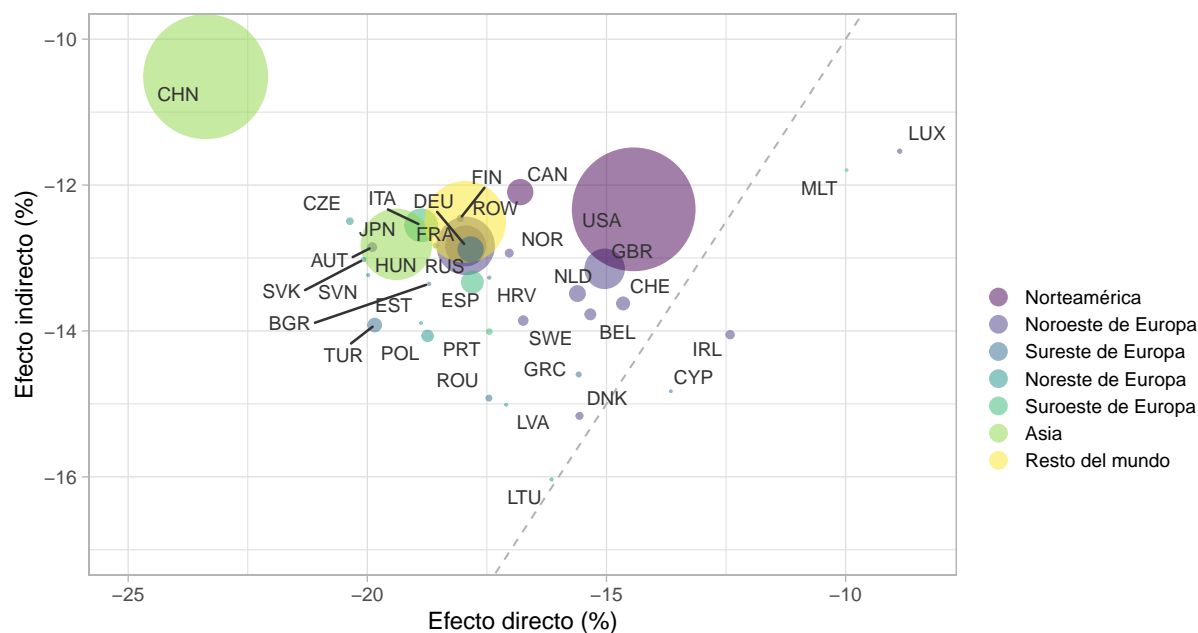
matriz insumo producto empírica (tabla ICIO-OECD). En este caso, el efecto directo sobre la producción a nivel nacional, relaciona de manera directa el tamaño del shock con la relevancia que cada uno de los sectores afectados tiene en la economía nacional. Al igual que antes, el efecto directo incorporado considera el asociado a los vínculos con otros sectores tanto a nivel local como global.

A nivel nacional, sin distinguir entre sectores, no se observa tanta dispersión entre los países como sí se observaba entre las ramas productivas. Cabe mencionar el caso de China, ya que es el país que se vio más afectado por el efecto directo, pero no tanto por el indirecto, como si lo hicieron el resto de los países. Una explicación posible para este resultado, es que las ramas que tienen mayor peso en la economía del gigante oriental se corresponden con aquellas que tuvieron el menor impacto de orden superior, como se mencionó previamente.

El Cuadro 1.3 muestra una descomposición adicional de los efectos del shock de acuerdo al alcance geográfico, si es local (nacional) o internacional. Esta última forma de descomposición, nos permite identificar cuánto de la caída de la producción se debe al shock en sí mismo y al hecho de que ha caído la demanda de insumos intermedios por parte de los sectores nacionales, y cuánto se debe al hecho de que se ha reducido el intercambio comercial entre países.

En líneas generales, se observa una mayor preponderancia del efecto indirecto a nivel local para la mayoría de los países (no todos). Es decir, que la mayor parte de la caída en la producción que se da por el efecto de orden superior, se explica por el hecho de que ha caído la demanda

Figura 1.4: Comparación efecto directo e indirecto del shock sobre la oferta de trabajo, en términos de reducción de la producción nacional. En porcentajes.



Nota: AUT–Austria, BEL–Bélgica, CAN–Canadá, CZE–República Checa, DNK–Dinamarca, EST–Estonia, FIN–Finlandia, FRA–Francia, DEU–Alemania, GRC–Grecia, HUN–Hungria, IRL–Irlanda, ITA–Italia, JPN–Japón, LVA–Letonia, LTU–Lituania, LUX–Luxemburgo, NLD–Países Bajos, NOR–Noruega, POL–Polonia, PRT–Portugal, SVK–Eslovaquia, SVN–Eslovenia, ESP–España, SWE–Suecia, CHE–Suiza, TUR–Turquía, GBR–Inglaterra, USA–Estados Unidos, BGR–Bulgaria, CHN–China, HRV–Croacia, CYP–Chipre, MLT–Malta, ROU–Rumania, RUS–Rusia, ROW–Resto del mundo

intermedia del resto de los sectores localizados en el mismo país. A nivel agregado, el efecto indirecto local explica el 32.64% de la caída en la producción, mientras que el indirecto global explica el restante 5.37%.

Del análisis realizado en esta sección, podemos concluir que la relevancia de los efectos directo e indirecto en la determinación del impacto, alcance y propagación de un shock, depende de cada industria y economía en particular. Hay algunos sectores que se vieron fuertemente afectados por las restricciones directas sobre la oferta de trabajo, mientras que otros lo hicieron centralmente por la caída en la demanda. El desempeño en los distintos países, respondió esencialmente al grado

Cuadro 1.2: Descomposición del impacto del shock asimétrico a la oferta de trabajo sobre la producción, en efecto directo e indirecto. Sectores agregados.

Sectores	Efecto directo	Efecto indirecto	Efecto total	Pesos
Agricultura	-3.62	-18.73	-22.35	7.13
Minería	-32.05	-1.52	-33.56	5.68
Manufacturas	-22.43	-11.04	-33.47	33.39
Bienes de capital	-51.16	0.00	-51.16	1.15
Bienes de consumo	-7.33	-21.78	-29.12	10.65
Insumos intermedios	-51.13	-0.19	-51.32	2.88
Energía	0.00	-40.07	-40.07	2.50
Construcción	-37.85	0.00	-37.85	13.11
Servicios	-18.66	-18.39	-37.06	29.79
Total	-19.90	-12.20	-32.10	
Porcentaje	61.99	38.01	100.00	

Cuadro 1.3: Descomposición del impacto del shock asimétrico a la oferta de trabajo sobre la producción, en efecto directo, indirecto local e indirecto global. Países.

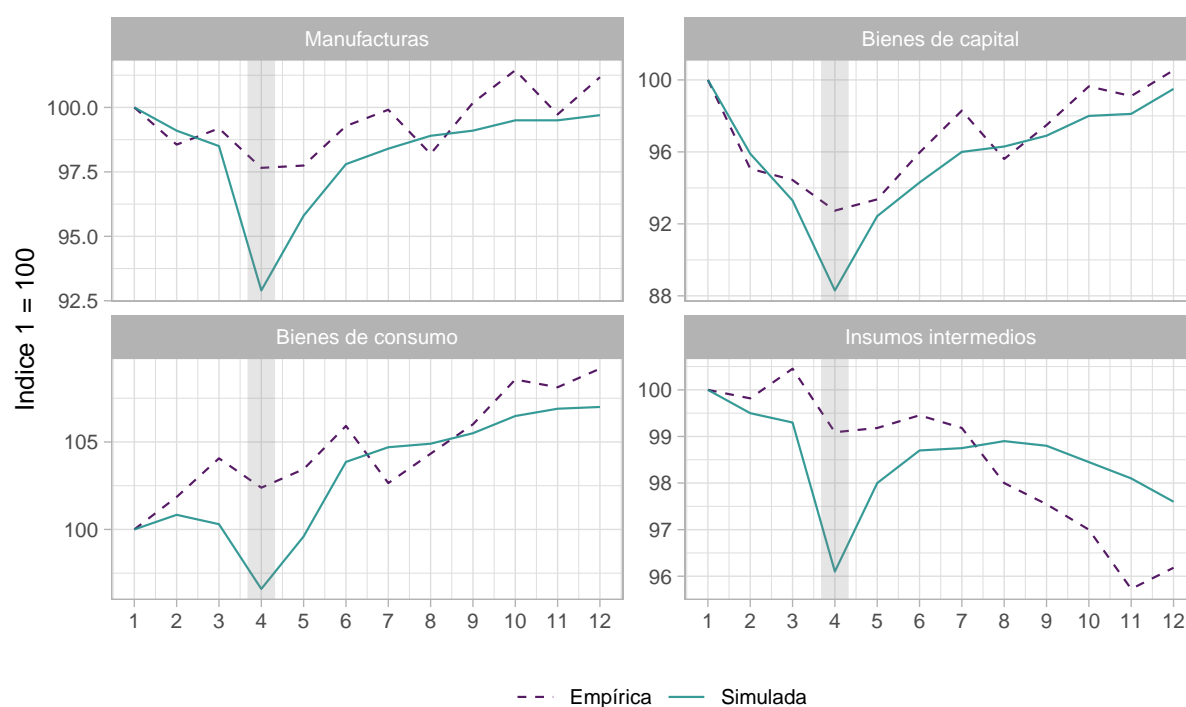
País	Efecto directo	Efecto indirecto			Efecto Total	Pesos
		Local	Global	Total		
Austria	-19.90	-8.86	-3.99	-12.85	-32.75	0.63
Bélgica	-15.34	-8.75	-5.02	-13.77	-29.11	0.83
Canadá	-16.80	-9.46	-2.64	-12.10	-28.90	2.24
República Checa	-20.37	-7.97	-4.52	-12.50	-32.86	0.42
Dinamarca	-15.56	-10.71	-4.45	-15.16	-30.73	0.46
Estonia	-18.88	-8.83	-5.06	-13.89	-32.77	0.05
Finlandia	-18.06	-9.30	-3.15	-12.46	-30.51	0.38
Francia	-17.94	-10.41	-2.42	-12.83	-30.78	3.66
Alemania	-17.94	-9.94	-2.89	-12.83	-30.78	5.37
Grecia	-15.58	-11.28	-3.32	-14.60	-30.18	0.26
Hungría	-18.57	-6.55	-6.28	-12.83	-31.40	0.23
Irlanda	-12.41	-6.08	-7.97	-14.05	-26.47	0.58
Italia	-18.87	-10.40	-2.16	-12.55	-31.43	2.96
Japón	-19.39	-11.21	-1.60	-12.81	-32.20	6.65
Letonia	-17.10	-11.14	-3.88	-15.01	-32.11	0.05
Lituania	-16.15	-10.03	-6.00	-16.04	-32.18	0.07
Luxemburgo	-8.87	-2.76	-8.77	-11.54	-20.41	0.19
Países Bajos	-15.61	-8.90	-4.59	-13.49	-29.09	1.32
Noruega	-17.03	-9.43	-3.51	-12.93	-29.97	0.54
Polonia	-18.74	-10.03	-4.04	-14.07	-32.81	0.89
Portugal	-17.45	-10.52	-3.49	-14.01	-31.46	0.32
Eslovaquia	-20.07	-7.48	-5.54	-13.02	-33.09	0.18
Eslovenia	-19.98	-8.05	-5.18	-13.23	-33.22	0.08
España	-17.80	-10.79	-2.54	-13.33	-31.13	1.90
Suecia	-16.74	-10.31	-3.55	-13.86	-30.60	0.70
Suiza	-14.65	-10.22	-3.40	-13.62	-28.28	1.04
Turquía	-19.84	-11.61	-2.31	-13.92	-33.76	1.10
Inglaterra	-15.04	-10.88	-2.27	-13.15	-28.19	3.63
Estados Unidos	-14.43	-11.39	-0.94	-12.33	-26.76	26.74
Bulgaria	-18.71	-8.66	-4.69	-13.35	-32.06	0.10
China	-23.38	-9.63	-0.88	-10.51	-33.89	26.09
Croacia	-17.45	-10.26	-3.01	-13.27	-30.72	0.08
Chipre	-13.65	-10.23	-4.60	-14.83	-28.48	0.03
Malta	-9.98	-5.56	-6.24	-11.79	-21.77	0.03
Rumania	-17.46	-11.57	-3.35	-14.92	-32.38	0.34
Rusia	-17.84	-10.38	-2.50	-12.88	-30.72	2.22
Resto del mundo	-17.95	-10.31	-2.20	-12.50	-30.46	7.65
Total	-19.90	-10.48	-1.72	-12.20	-32.10	
Participación	61.99	32.64	5.37	38.01	100.00	

de integración de los distintos sectores en la economía global y a la magnitud de los intercambios locales.

1.4.2 Shock 2: Interrupción de suministro exterior en un país-sector

Comenzamos el análisis de los resultados observando la evolución de la producción sectorial simulada y aquella observada empíricamente, que se muestra en la Figura 1.5. El período para la serie empírica es diciembre-2021 a noviembre-2022 y, al igual que en el caso de la sección previa, mensualizamos los resultados del modelo para hacer comparable su evolución con los datos reales. La Figura 1.5 muestra específicamente lo acontecido al interior de la industria manufacturera, ya que es el sector más afectado por la interrupción del suministro energético por parte de Rusia. En líneas generales, se puede observar una variación negativa en el período 4 –el cual se corresponde empíricamente con el mes de marzo de 2022–, coincidente en los distintos subsectores seleccionados de la industria manufacturera.

Figura 1.5: Evolución de la producción industrial en los datos simulados y empíricos. Países europeos incorporados en el estudio.



Como puede apreciarse, el modelo es capaz de reproducir de manera aproximada la caída en la actividad industrial observada en el período en que el shock toma lugar. Se modelizó un escenario extremo donde el corte en el suministro de energía se da a todo los países europeos, por lo que se observa una sobre-estimación del efecto negativo sobre la producción industrial. La escalada del conflicto al plano armado y económico (en términos de la aplicación de sanciones mucho más restrictivas) tuvo su inicio el 24 de febrero de 2022, y si bien las consecuencias de este evento

—que se extiende hasta el momento de redacción de este capítulo— se sostienen en el tiempo como bien puede observarse en la evolución de la producción real europea, el período que corresponde al inicio del estallido (marzo 2022) tiene la particularidad de reflejar el punto de inflexión que significó este evento histórico¹⁶. Es importante considerar que el evento disruptivo representado no tuvo lugar en la actualidad de la forma en la que se modeliza. Desde diciembre de 2021, los suministros de gas de Rusia han disminuido alrededor de un 30%, pero se han mantenido dentro de los límites contractuales preestablecidos¹⁷. Es decir, no hubo en el período en cuestión un corte abrupto de la energía suministrada por parte de Rusia a Europa, sino que es lo que usamos para simular el shock y analizar su propagación en nuestra economía.

El modelo predice una contracción global de la producción industrial del 4.5% respecto al período previo en el que el shock se modeliza y de un 7.6% respecto al período inicial. Los datos empíricos muestran que en marzo de 2022 la caída en la producción industrial fue del 1.8% y 2.5% en los períodos respectivos. El conjunto de sectores más afectado, como se aprecia en la Figura 1.5 fueron los productores de bienes de capital, con una caída (empírica) del 7.6% respecto de diciembre de 2021 y del 2.3% respecto de febrero de 2022.

Antes de continuar cabe recordar que en este trabajo analizamos una situación de corto plazo donde no hay posibilidad inmediata de sustitución del bien que se ve restringido, pero sí es posible utilizar las reservas con las que se cuenta en inventarios¹⁸. Entonces el efecto directo tiene un impacto pleno en la producción de los diferentes sectores y países, y depende centralmente de la participación que tienen las importaciones de energía rusa en cada uno de ellos. En este sentido, para interpretar mejor los resultados es importante conocer la importancia del sector energético ruso en las importaciones de los diferentes países a nivel mundial.

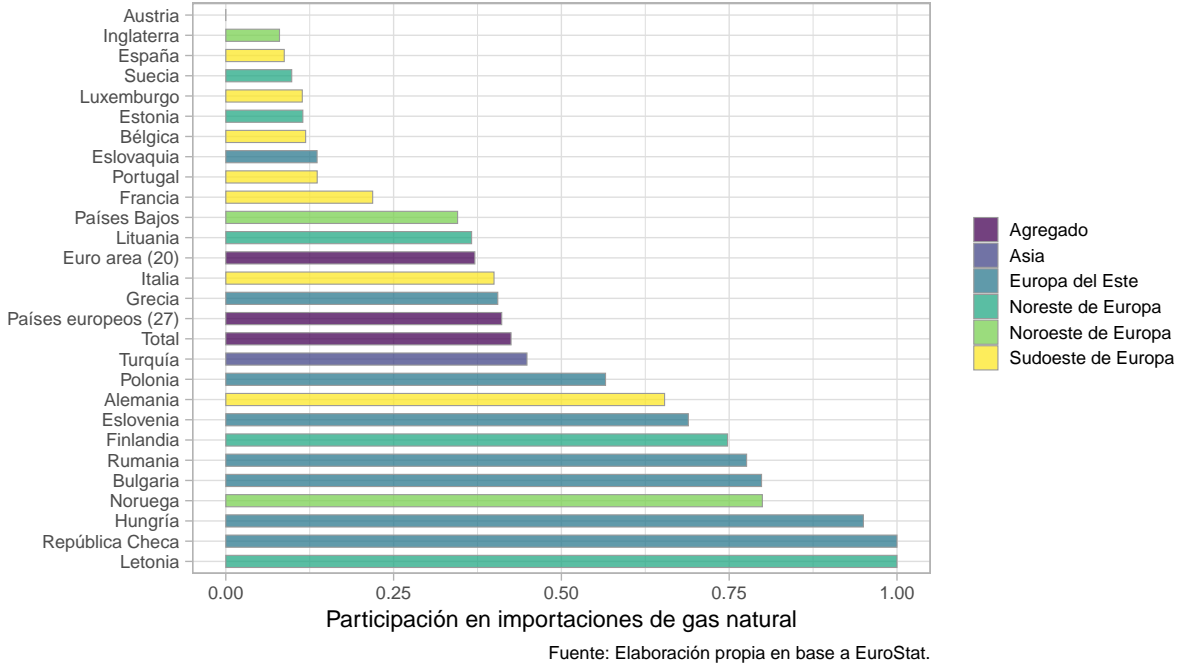
Las importaciones de Rusia representan alrededor del 32.5% del total del gas natural que consumen los países europeos. Esta dependencia le da a Rusia, por un lado, una gran influencia en Europa y, por el otro, continúa siendo dependiente ya que los países europeos representan el 40% de sus exportaciones de gas. Una gran proporción del gas consumido se utiliza para la calefacción de los hogares, por lo que la demanda de gas es muy estacional, aunque una buena parte se utiliza en el proceso productivo industrial y para generar energía. Como se observa en la Figura 1.6, la República Checa, Letonia y Hungría dependen totalmente del gas ruso; mientras que Alemania, Italia, Polonia, Bulgaria y Finlandia dependen de más del 40% del gas importado de Rusia. En el corto plazo, donde la demanda no es muy elástica, se espera que estas economías se vean afectadas por la desaceleración de las industrias intensivas en energía en caso de un corte total del suministro de gas ruso. Por el contrario, Francia, España, Suecia y Austria dependen menos del gas ruso.

¹⁶No obstante, una vez que se remueve el shock del modelo es difícil, dada la simplicidad del mismo, que pueda reproducir la dinámica de la producción sectorial. Por lo tanto, se identifican también instancias en las que el modelo no puede reproducir la dinámica observada ni siquiera aproximadamente.

¹⁷El mínimo contractual para que Rusia entregue a Europa es de 94 bcm/año.

¹⁸Es decir, lo que la literatura de desastres refiere como una situación de cortísimo plazo (Bouwmeester y Oosterhaven, 2017).

Figura 1.6: Participación de Rusia en las importaciones totales de gas natural. Año 2021.



De manera análoga al shock analizado en la sección 1.4.1, definimos al efecto directo como aquella parte de la caída en la producción que se explica exclusivamente por la caída en la disponibilidad de un insumo clave en la producción, la energía. En este sentido, el shock implica limitar la capacidad de producción por insumos intermedios (ver ecuación (1.3)), específicamente los que corresponden al sector energético. Formalmente, se puede expresar como

$$\Delta \mathbf{x}_{t,t-1}^{\text{dir}} = \text{diag}^{-1}(\mathbf{a}^i) \Delta \mathbf{z}_{i;t,t-1}, \text{ con } i \in \{23\text{-Electricidad y gas natural; } 03\text{-Minas-energéticos}\}, \quad (1.19)$$

donde \mathbf{a}^i representa el vector de insumos para el sector energético, que se obtiene de dividir la suma de lo que demanda cada sector-país de este sector en total por el vector de producción bruta inicial sectorial.

El efecto indirecto, es decir, aquel que se deriva por el hecho de que los diferentes sectores no pueden intercambiar plenamente entre ellos, también implica limitar la producción por insumos intermedios: cae la producción de los sectores impactados de manera directa y, por lo tanto, su demanda de insumos intermedios de otros sectores, lo que hace caer la producción de estos últimos; que incorporan el primer impacto en las expectativas de corto plazo (ver ecuación (1.6)).

En la Figura 1.7.A se puede observar el cambio en la producción de los diferentes sectores, desagregado entre el efecto directo y el indirecto. El primero se representa en el eje horizontal, el segundo en el eje vertical, y el tamaño de los puntos corresponde a la participación de cada

sector en la producción bruta inicial de los diferentes países. A diferencia del análisis para el tipo de shock previo, el efecto directo difiere entre un mismo sector localizado en diferentes países, ya que depende tanto de la proporción de la demanda de energía rusa, como de los coeficientes técnicos que esta rama tiene en la producción de cada sector en las diferentes localizaciones geográficas. La definición del efecto indirecto es análoga a la sección 1.4.1; es decir, incorpora los vínculos de cada sector con el resto de los sectores-países.

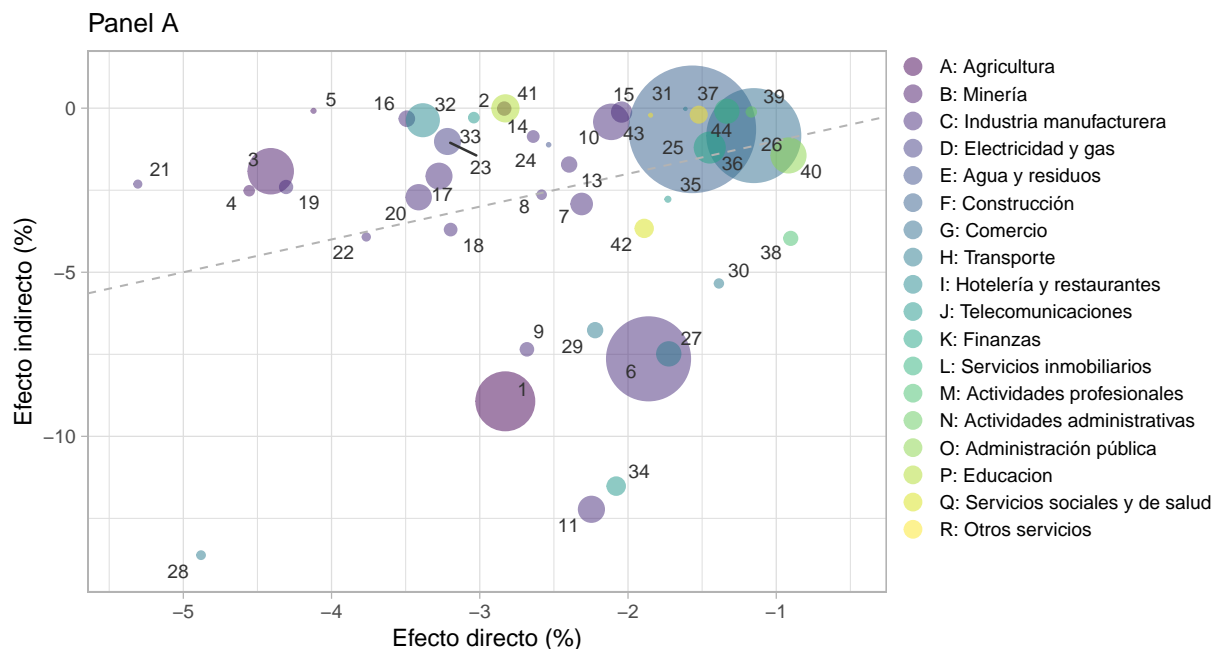
En líneas generales, se pueden identificar cuatro grupos de sectores. El primer de ellos se conforma por aquellas ramas ubicadas en el extremo superior derecho. Se trata de los sectores para los cuales el efecto directo no ha sido significativo, ya que la participación de la energía rusa no es de una magnitud considerable en la canasta de insumos que demandan para la producción. Este grupo está compuesto centralmente por sectores de servicios, y algunos de ellos son los que tienen la mayor participación en el producto global (como el caso de la construcción). Se destacan el comercio al por mayor y menor, el sector de administración pública, los servicios inmobiliarios, la construcción y el sector financiero. En todos estos casos el efecto directo es menor al 2%, mientras que el efecto indirecto no supera el 1%.

Luego, podemos identificar dos grupos: aquellos sectores para los que el efecto directo no es relevante pero sí lo es el indirecto, y viceversa. El primero, está compuesto por los sectores que se ubican verticalmente a la derecha del gráfico, de lo cuales se destacan la rama de almacenamiento (-5.4% de efecto indirecto, y -1.39% de efecto directo), la industria farmacéutica (-21% y -3.1%) y el sector de telecomunicaciones (-11.5% y -2%). Los sectores que conforman el segundo grupo se observan distribuidos horizontalmente sobre el eje de abscisas. Se destaca, como era de esperarse, el sector energético (-3.5% de efecto directo y -1% de efecto indirecto), la actividad minera, tanto la asociada al sector energético (-4.5% y -1.9%), como la no asociada al mismo (-4.6% y -2.5%), la fabricación de productos de metal (-3.5% y -0.32%), la industria de equipamiento para transporte (-5.3% y -2.3%) y la producción de maquinarias n.c.p. (-4.3% y -2.4%). Estos sectores recibieron el impacto directo de mayor tamaño entre todos los sectores bajo estudio, de una magnitud superior al 3%. Cabe destacar que en este grupo se encuentran en su mayoría, sectores pertenecientes a la industria manufacturera.

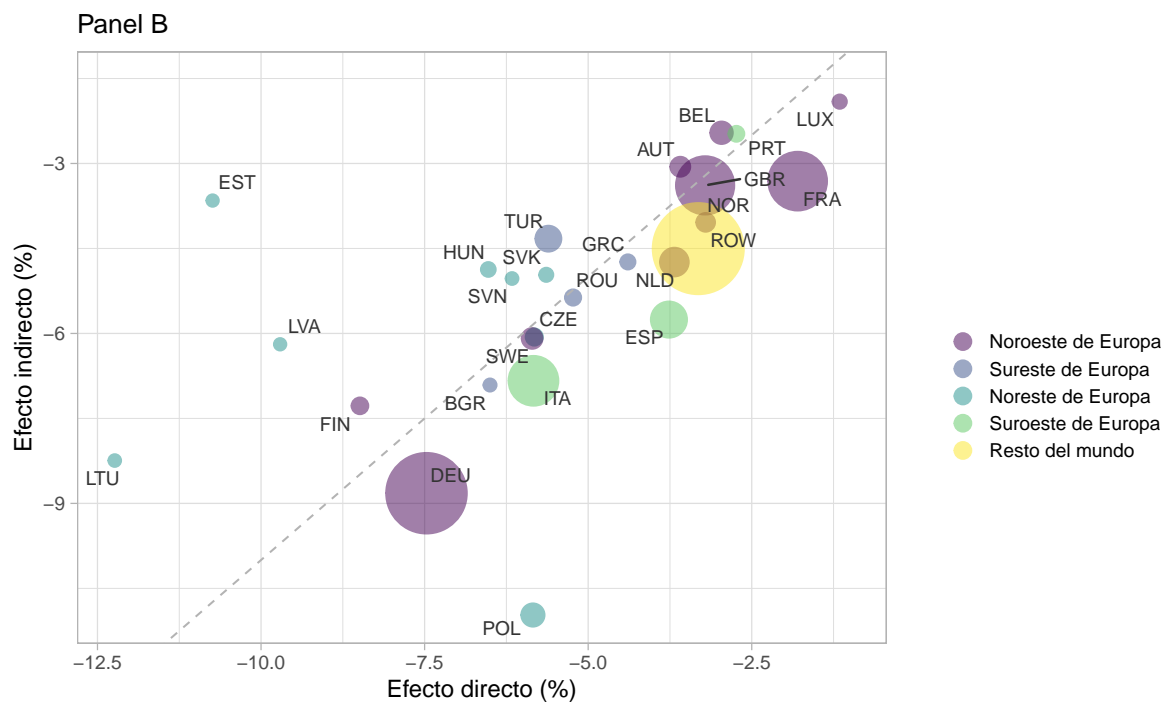
Finalmente, el último grupo se compone de aquellos sectores ubicados en torno a la recta de 45 grados, es decir, que los efectos directo e indirecto se encuentran relativamente balanceados. Aquí encontramos también gran parte de los sectores pertenecientes a la industria manufacturera, de los cuales se destaca a las manufacturas n.c.p. (-3.77% efecto directo y -3.92% efecto indirecto), la producción de vehículos (-3.41% y -3.1%), la industria electrónica (-3.28% y -2.7%) y la fabricación de equipamiento eléctrico (-3.2% y -3.7%).

La Figura 1.7.B muestra el cambio en la producción de los diferentes países. El efecto directo se representa en el eje horizontal, el indirecto en el eje vertical y el tamaño de los círculos corresponde a la participación del producto del país en el total de las economías de la muestra. Para facilitar la comprensión y lectura del gráfico, se muestran los resultados para los diferentes

Figura 1.7: Comparación efecto directo e indirecto del shock sobre la disponibilidad de energía, en términos de: Panel A) reducción de la producción sectorial global, Panel B) reducción de la producción nacional. En porcentajes.



Nota: 1–Agricultura, 2–Pesca, 3–Minas–energéticos, 4–Minas–no energéticos, 5–Minas–servicios, 6–Alimentos, 7–Textiles, 8–Madera, 9–Papel, 10–Petróleo, 11–Química, 12–Farmacéuticos, 13–Plástico, 14–Otros minerales, 15–Metales básicos, 16–Productos de metal, 17–Electrónica, 18–Eq. eléctrico, 19–Maquinaria n.c.p., 20–Vehículos, 21–Otro eq. Transporte, 22–Manufacturas n.c.p., 23–Electricidad, gas, 24–Agua y residuos, 25–Construcción, 26–Comercio, 27–Transporte terrestre, 28–Transporte marítimo, 29–Transporte aéreo, 30–Almacenamiento, 31–Correo, 32–Hostelería y rest., 33–Audiovisuales, 34–Telecomunicaciones, 35–IT, 36–Finanzas, 37–Ss. inmobiliarios y emp., 38–Act. Profesionales, 39–Act. Administrativas, 40–Admin. pública, 41–Enseñanza, 42–Ss. Soc. y de salud, 43–Ss. culturales, 44–Otros ss.



Nota: AUT–Austria, BEL–Bélgica, CZE–República Checa, EST–Estonia, FIN–Finlandia, FRA–Francia, DEU–Alemania, GRC–Grecia, HUN–Hungría, ITA–Italia, LVA–Letonia, LTU–Lituania, LUX–Luxemburgo, NLD–Países Bajos, NOR–Noruega, POL–Polonia, PRT–Portugal, SVK–Eslovaquia, SVN–Eslovenia, ESP–España, SWE–Suecia, TUR–Turquía, GBR–Inglaterra, BGR–Bulgaria, ROU–Rumania, ROW–Resto del mundo

Cuadro 1.4: Descomposición del impacto del shock asimétrico a la disponibilidad de energía, en efecto directo e indirecto. Países.

País	Efecto directo	Efecto indirecto	Efecto total	Pesos
República Checa	-5.82	-6.06	-11.89	1.23
Letonia	-9.71	-6.19	-15.90	0.86
Hungría	-6.53	-4.87	-11.40	1.04
Noruega	-3.20	-4.04	-7.24	1.35
Bulgaria	-6.50	-6.91	-13.41	0.91
Rumania	-5.23	-5.37	-10.60	1.15
Finlandia	-8.49	-7.28	-15.77	1.19
Eslovenia	-6.16	-5.03	-11.19	0.89
Alemania	-7.47	-8.82	-16.29	6.18
Polonia	-5.84	-10.97	-16.81	1.70
Turquía	-5.61	-4.33	-9.94	1.91
Grecia	-4.39	-4.74	-9.13	1.07
Italia	-5.84	-6.84	-12.67	3.77
Lituania	-12.24	-8.24	-20.48	0.88
Países Bajos	-3.68	-4.74	-8.42	2.13
Francia	-1.80	-3.31	-5.11	4.47
Portugal	-2.73	-2.48	-5.21	1.13
Eslovaquia	-5.64	-4.96	-10.61	0.99
Bélgica	-2.96	-2.46	-5.42	1.64
Estonia	-10.74	-3.65	-14.39	0.85
Luxemburgo	-1.16	-1.91	-3.06	1.00
Suecia	-5.86	-6.09	-11.94	1.51
España	-3.77	-5.76	-9.52	2.71
Inglaterra	-3.21	-3.39	-6.60	4.44
Austria	-3.59	-3.06	-6.65	1.44
Resto del mundo	-3.32	-4.50	-7.82	53.59
Total	-3.41	-4.20	-7.60	
Participación	44.83	55.17	100.00	

países europeos alcanzados por el efecto directo, mientras que el resto de los países (que se ven afectados por el efecto indirecto solamente, o donde el mismo es cercano a cero) se agrupan en “resto del mundo”.

Como se puede observar en la Figura 1.7.B, los países representados se ubican en torno a la recta de 45°, lo que indica que el efecto directo e indirecto al interior de los mismos se encuentra relativamente “balanceado”. No obstante, cabe destacar algunos casos donde los efectos son mayores. En primer lugar, podemos mencionar a Lituania, Letonia, Estonia y Finlandia, que son los países que reciben el mayor impacto directo, superando el 8% en todos los casos. En el caso de Estonia, la suspensión en el suministro de energía y gas por parte de Rusia tiene un importante efecto directo, que explica una caída en la producción del 10.7%, pero donde las economías afectadas no tienen grandes encadenamientos locales, ya que el efecto indirecto explica solo un 3.6% en la caída de la producción nacional.

Por último, se destacan los casos de Alemania y Polonia. Ambas economías tienen una dependencia del gas ruso considerable, como se puede observar en la Figura 1.6. No obstante, en lo que hace a la demanda de los distintos sectores productivos, el mayor impacto negativo sobre la producción se explica por el hecho de que los sectores demandantes (es decir, alcanzados por el efecto directo) tienen importantes encadenamientos en las economías nacionales. De esta manera, como se muestra en el cuadro 1.4, en Polonia de una caída total en la producción del 16.8%, un 5.8% corresponde al efecto directo, mientras que el restante 11% corresponde al efecto indirecto. En el caso de Alemania, estos valores son del 7.3% y 8.8%, respectivamente, lo que totaliza una caída en la producción de este país del 16.2% como consecuencia de un shock que impide el suministro de energía y gas desde Rusia hacia el resto del mundo.

Finalmente, en términos globales, el modelo predice una caída en la producción de 7.6%. Una variación del -3.4% –es decir, un 44.8% del cambio total– en el producto global se explica por el efecto directo, mientras que un -4.2% –es decir, el 55.2% del cambio total– se explica por el efecto indirecto (ver cuadro 1.4).

1.4.3 Análisis de la propagación de un shock: el efecto cascada

Realizamos un último ejercicio para evaluar la posición de los distintos sectores-países en términos de su capacidad de transmisión de shocks, factor determinante de la magnitud del efecto económico indirecto. Dicha posición la evaluamos a partir del “efecto cascada” que un evento desencadenante (shock inicial) genera cuando impacta individualmente a cada uno de ellos. En primer lugar, planteamos un shock de oferta (sobre la mano de obra disponible) que afecta en términos relativos a cada unidad de la misma manera y aplicamos un shock sobre un sector-país a la vez. En el enfoque adoptado, una vez que un sector-país ha sido alcanzado por un shock no puede serlo nuevamente.

Luego, siguiendo a [Alatríste Contreras y Fagiolo \(2014\)](#), definimos al tamaño del efecto cascada del sector i en el país r (ec_i^r) como el número de sectores que son alcanzados indirectamente por un shock (es decir, cuya variación en la producción es menor que cero) inicialmente iniciado en el sector i localizado en el país r . Tal como señalan los autores mencionados, esta definición del efecto cascada tiene la ventaja de no depender del tamaño del shock inicial. De esta manera, es posible obtener la distribución del tamaño del efecto cascada, compuesta por el efecto desencadenado por un shock en cada país-sector de manera individual, $\{ec_i^r; i = 1, \dots, k; r = 1, \dots, n\}$.

La matriz de relaciones intersectoriales entre sectores y países \mathbf{Z} , representa una red donde cada sector-país (cada fila/columna) es un nodo y los vínculos están representados por relaciones de oferta/demanda de insumos entre ellos. Es decir, las unidades interconectadas son sectores localizados geográficamente en diferentes países. Se trata de una red dirigida y ponderada, ya que es posible determinar la dirección del vínculo (un sector compra o vende bienes) y su tamaño es equivalente al valor de la transacción. Definimos la “relación intersectorial global” considerando las ventas de cada sector-país, por lo que cada elemento $ad_{i,j}^{r,s}$ la matriz de adyacencias \mathbf{Ad} será igual a 1 si el sector i en el país r le vende bienes y/o servicios al sector j en el país s , y será igual a 0 en caso contrario.


Como mencionamos previamente, la matriz \mathbf{Z} proviene de la información empírica publicada por la OECD, por lo que la red de relaciones intersectoriales a nivel global se construye a partir de datos empíricos. Al igual que en las simulaciones del modelo, se consideran 44 sectores y 37 países (36 más el “resto del mundo”), por lo que el número de nodos asciende a 1628. En el caso del número de vínculos –es decir, el número de relaciones totales que existen entre pares de sectores-países– supera los 2 millones. No es el objetivo de este estudio analizar las propiedades topológicas de esta red, sino que ponemos el foco las propiedades de propagación de un shock que tienen los distintos sectores-países para entender mejor los resultados encontrados previamente. Por lo tanto, nos limitamos a analizar algunas de las propiedades estructurales que sirven para tal fin¹⁹.

La Figura 1.8 muestra para cada país el coeficiente de variación de la distribución del tamaño del efecto cascada desencadenado por cada sector, frente a la densidad de la red nacional del país correspondiente. Es decir, la densidad de la red calculada para cada país, considerando solo las transacciones entre sectores a nivel local²⁰. El color de los puntos hace referencia al máximo tamaño del efecto cascada desencadenado por uno o un conjunto de sectores nacionales y el tamaño corresponde a la participación de cada país en el producto global. Esta representación nos permite visualizar el alcance de los efectos cascada desencadenados a partir de un shock de oferta individual y su vínculo con el tamaño de la economía donde se origina. El panel izquierdo muestra los resultados para el caso de las economías nacionales, consideradas de manera aislada, mientras que el panel derecho considera también las interconexiones a nivel global.

¹⁹Los lectores interesados en un análisis de las propiedades topológicas de la red global de producción, pueden ver por ejemplo [Fagiolo et al. \(2009\)](#).

²⁰Como mencionamos en la sección 1.2.2, las matrices insumo-producto nacionales están representadas en la

Figura 1.8: Densidad de la red insumo-producto nacional y coeficiente de variación del tamaño del efecto cascada. Por países, considerando solo interacciones nacionales (izq.) e interacciones nacionales y globales (der.).



Nota: AUT–Austria, BEL–Bélgica, CAN–Canadá, CZE–República Checa, DNK–Dinamarca, EST–Estonia, FIN–Finlandia, FRA–Francia, DEU–Alemania, GRC–Grecia, HUN–Hungria, IRL–Irlanda, ITA–Italia, JPN–Japón, LVA–Letonia, LTU–Lituania, LUX–Luxemburgo, NLD–Países Bajos, NOR–Noruega, POL–Polonia, PRT–Portugal, SVK–Eslovaquia, SVN–Eslovenia, ESP–España, SWE–Suecia, CHE–Suiza, TUR–Turquía, GBR–Inglaterra, USA–Estados Unidos, BGR–Bulgaria, CHN–China, HRV–Croacia, CYP–Chipre, MLT–Malta, ROU–Rumania, RUS–Rusia, ROW–Resto del mundo

En ambos casos se observa cierta heterogeneidad en el proceso de difusión del shock al interior de los países. En el caso de considerar solo los efectos locales/nacionales del shock (panel izq.), los coeficientes de variación observados son generalmente pequeños (en su mayoría menores a 0.17), lo que indica que las distribuciones del tamaño del efecto cascada se concentran en torno al valor máximo del efecto. Para el caso global (panel der.) la heterogeneidad es aún mayor, pero en este caso los coeficientes de variación están más dispersos en un rango mayor, entre 0.5 y 1.3. Por lo tanto, al considerar los vínculos que cada sector tiene no sólo en la economía local, sino también a nivel internacional, el tamaño del efecto cascada que puede provocar a partir del impacto de un shock cambia significativamente. El tamaño de la cascada ya no se encuentra concentrado en torno al máximo valor posible alcanzado. Estos resultados muestran claramente la existencia de desajustes entre sectores: hay un conjunto de ellos que es central para la transmisión internacional de shocks y otro conjunto que es central para su propagación interna o nacional.

Cabe recordar que en el modelo, los sectores productivos ajustan su producción en función de los insumos disponibles. Es decir, no solo se ajusta la cantidad de insumos que adquiere de un sector impactado por un shock de oferta, sino que también ajusta su propia producción a la nueva cantidad de insumos disponibles (post consumo de inventarios). Este comportamiento funciona como un mecanismo amplificador del tamaño del efecto cascada, incrementando la posición de vulnerabilidad de los sectores y países. Este mecanismo es, por lo tanto, la principal explicación al hecho de que observemos tamaños del efecto cascada concentrados en torno a su valor máximo, principalmente al considerar solo la economía nacional. Ahora bien, al abrir la economía, se están considerando muchas más posibilidades para el abastecimiento de insumos de un sector-país determinado; específicamente pasamos de considerar solo 44 sectores a un total de 1628. Por lo tanto, si bien una mayor interconexión incrementa la probabilidad de ser impactado indirectamente por un shock, dado que en este ejercicio estamos considerando el impacto en un sector a la vez, también reduce la exposición a un solo sector en particular, dando como resultado tamaños de efecto cascada mucho más heterogéneos y dispersos entre sectores y países.


En todos los países, cuando un sector nacional es alcanzado por un shock de manera directa, se observa al menos una cascada que alcanza a toda la economía local. Esto se puede observar en el rango de la escala de colores del panel izquierdo de la Figura 1.8. La gran mayoría de los países tuvieron efectos cascada donde el tamaño máximo alcanzó a los 44 sectores considerados de la economía. Dos excepciones notables son los casos de Luxemburgo e Italia, donde el tamaño máximo de la cascada es de 38 y 41, respectivamente. En términos de los sectores que desencadenan estos efectos cascadas, en 21 de los 36 países se identifican más de 18 sectores con capacidad para transmitir un shock que les impacta de manera directa, a toda la economía local.

Respecto al vínculo entre el tamaño del efecto cascada y las características estructurales y macroeconómicas de las economías, no es posible identificar un patrón claro que los relacione, especialmente para el caso donde se consideran los vínculos internacionales de los sectores

diagonal principal de la matriz \mathbf{Z}

económicos. Como se puede observar en la Figura 1.8 la densidad de la red, el tamaño relativo de las economías en el mundo y las propiedades estadísticas de las distribuciones del tamaño del efecto cascada, no siguen un patrón claramente identificable. En el caso de la densidad de la red, pareciera tener mayor incidencia respecto del tamaño máximo del efecto cascada cuando se consideran solo las economías nacionales como entes aislados unos de otros. Mientras que el tamaño relativo de las economías en el mundo, pareciera guardar cierta relación (aunque débil) con el tamaño máximo del efecto cascada (ver relación entre los colores del panel derecho de la Figura 1.8 y el tamaño de los puntos).

Figura 1.9: Tamaño del efecto cascada por país-sector y centralidad en la red internacional medida por el algoritmo HITS.



Nota: En el inset se observa la relación entre el valor del Hub (log) y el tamaño del efecto cascada.

En el plano sectorial, es posible analizar cuáles son los sectores que lideran los mayores efectos cascada tanto a nivel local como global. A nivel nacional, los sectores que más comúnmente dan lugar a los mayores tamaños de efecto cascada al interior del país son la industria química (32 países), el comercio mayorista y minorista (31 países), el sector financiero (31 países)²¹, petróleo y sus derivados (29 países), farmacéuticos (28 países), construcción (26 países), la industria alimenticia (24 países) y el sector agrícola (23 países). Como puede apreciarse, en el caso nacional, los sectores capaces de producir los mayores efecto cascada son relativamente variados, aunque existe cierta repetición de los mismos.

Si pasamos al plano internacional, dado que el tamaño del efecto cascada es mucho más heterogéneo entre sectores, es posible identificar a un único sector como el desencadenante de la mayor cascada

²¹En el capítulo 2 analizamos cómo se pueden propagar y/o amplificar las dificultades financieras en una economía a partir de la existencia de relaciones entre el sector financiero y los sectores productivos. Abordamos específicamente el canal del crédito bancario en una economía nacional.

en un país (o por lo menos un grupo mucho más reducido de sectores). En primer lugar, se ubica el sector de la construcción, que es capaz de desencadenar el mayor efecto cascada, considerando sectores nacionales e internacionales, en un total de 13 países. Luego, identificamos al sector de comercio mayorista y minorista (9 países), el sector financiero (9 países), el sector productor de alimentos (5 países) y la industria automotriz (4 países). Este último es el único que no había sido destacado entre los sectores que contagian a un mayor número de industrias nacionales el efecto de un shock que los impacta de manera directa.

Finalmente, realizamos un análisis de la distribución del tamaño del efecto cascada por sector-país de manera individual y a nivel internacional, la cual se puede observar a lo largo del eje de las abscisas de la Figura 1.9. En líneas generales, se observa que los sectores que revisten una mayor centralidad global en la red insumo-producto internacional –medida por el algoritmo HITS, es decir, la centralidad de autoridades (authority) y concentradores (hub)²², ver Kleinberg (1999)– son los que desencadenan los mayores tamaños de efecto cascada a nivel global. Es decir, encontramos una correlación positiva entre la centralidad global de los sectores-países en la red insumo-producto internacional y el tamaño del efecto cascada que cada uno es capaz de desencadenar. Esto se encuentra en línea con lo que Alatríste Contreras y Fagiolo (2014) encontraron para las redes insumo producto a nivel nacional, dado que tampoco se observa tal correlación fuertemente positiva con la centralidad local (particularmente la fuerza de entrada y de salida). Tal como mencionan los autores, este resultado implica que el alcance del efecto cascada desencadenado por un shock individual depende centralmente de la integración general que tiene un sector-país en la red insumo-producto, que depende también de la centralidad que tienen todos los demás sectores vinculados a él.

1.5 Comentarios finales

En este trabajo analizamos el impacto económico y el alcance de un shock sectorial asimétrico. Específicamente, modelizamos dos tipos de shock que afectan el normal funcionamiento de la cadena de suministro tanto a nivel local como global, en el marco de un modelo dinámico de las relaciones insumo-producto entre países y sectores. Calibramos el modelo usando datos de las matrices insumo-producto del mundo real, lo que nos permitió evitar hacer suposiciones arbitrarias acerca de las relaciones entre sectores. Asimismo, esta información incorpora tanto las transacciones sectoriales a nivel nacional, así como también los intercambios entre sectores de un país con otras industrias localizadas geográficamente en el resto del mundo. Esto nos permitió incorporar la dimensión internacional al análisis de la propagación de un shock sectorial asimétrico.

Analizamos el papel jugado por un evento idiosincrático con diferentes orígenes y su impacto global en la economía; por lo que una característica importante del modelo es que destaca el

²²Esta misma relación se evidencia en otras medidas de centralidad global, como el PageRank Ponderado.

carácter relacional del sistema económico. Asimismo, el marco estudiado permite descomponer el impacto económico del shock en su efecto directo –es decir, la variación en la producción como consecuencia del impacto directo del shock–, e indirecto –el cambio en el producto causado por el hecho de que los sectores económicos se vinculan entre sí–. Finalmente, la configuración del modelo permite evaluar la importancia relativa de los distintos sectores-países en la propagación de un shock, tanto a escala nacional como global.

En los experimentos de simulación, estudiamos dos configuraciones de shock bien diferentes. En el primer caso, se modeliza un shock negativo sobre la oferta de trabajo sectorial que afecta de manera asimétrica a un conjunto de sectores localizados en distintas partes del mundo, para lo que tomamos como ejemplo motivador el caso de la pandemia de COVID-19. Por lo tanto, se trata de muchos sectores en muchos países que son impactados simultáneamente de manera directa por el shock de oferta. En el segundo caso, modelizamos una interrupción completa en el suministro de un sector específico localizado en un país en particular (sector energético en Rusia), motivado en el conflicto entre Rusia y Ucrania. Es decir, que solo afectamos los vínculos de un sector-país para con el resto del mundo.

Para un shock que afecta de manera heterogénea a la oferta laboral sectorial, el modelo predice una caída de la producción global del 32.1%. De este cambio, el 62% es explicado por la caída en la producción de los sectores que fueron impactados de manera directa, mientras que el restante 38% corresponde al efecto indirecto. Este último, puede descomponerse en local (o nacional, 5.4%) y global (o internacional, 32.6%). En el caso del shock que afecta el suministro de energía de manera diferencial para distintos países europeos, la predicción en la caída de la producción es del 7.6%. Las participaciones de los efectos directo e indirecto son sustancialmente diferentes: el efecto directo explica el 44.8% de la caída, mientras que el indirecto explica el 55.2%.

Si bien el efecto global sobre la producción fue sensiblemente menor cuando los comparamos en términos absolutos, debe tenerse en cuenta que en términos relativos (por el número de sectores/vínculos afectados de manera directa) el impacto sobre la producción global en el segundo tipo de evento modelizado fue considerable. Esto se explica por la importancia sistémica que reviste el sector energético ruso en la producción global. Esto se observa en las magnitudes correspondientes a los efectos directo e indirecto del shock y se confirma en los resultados encontrados en la última sección del capítulo, donde el sector energético surge como aquel capaz de desencadenar los efectos cascada de mayor tamaño en un número considerable de países.

Los resultados del análisis de la propagación de shocks individuales (sección 1.4.3), muestran que en un contexto donde los sectores productivos ajustan su producción como consecuencia del ajuste en la oferta disponible de insumos de los sectores a los que demanda, las economías nacionales están sujetas a efectos cascada de gran tamaño aunque heterogéneos entre sectores y países. Esta heterogeneidad se incrementa significativamente cuando se considera a los sectores económicos como parte de un sistema global interconectado.

Respecto al vínculo con las características económicas y estructurales de los países, encontramos que cuanto mayor sea el tamaño del país en la economía mundial, y cuanto más central sea el sector en la red insumo-producto internacional, mayor es la probabilidad de que genere un efecto cascada de gran tamaño al ser impactado por un shock de manera directa. Estos resultados implican que los países de mayor peso en términos de producto en la economía mundial, son aquellos capaces de desencadenar las mayores cascadas a nivel global cuando son impactados directamente y, al mismo tiempo, son más vulnerables a grandes shocks económicos.

Finalmente, los resultados encontrados destacan la necesidad de considerar en el análisis de la importancia sistémica de los distintos sectores, no solo sus características económicas –como su tamaño en términos de valor agregado, producción o empleo generado–, sino también a las interrelaciones entre ellos y la posición que ocupa cada uno en las redes productivas. Adicionalmente, es importante tener en cuenta que las economías nacionales forman parte de un mundo cada vez más interconectado, por lo que también su posición e integración en el complejo entramado de relaciones insumo-producto a nivel global es una dimensión relevante. En este sentido, podría ser interesante en futuros considerar una definición de efecto cascada que incorpore la magnitud o intensidad del mismo en términos de producción; es decir, no solo el número de sectores que son alcanzados por dicho efecto, sino también traducirlo al monto en pérdidas sectoriales, de manera similar a la que se estima el efecto indirecto.

1.6 Anexo

1.6.1 Ejemplo numérico reducido

Para ilustrar la lógica del modelo desarrollado en este capítulo en un contexto más fácilmente comprensible, presentamos aquí un ejemplo numérico sencillo. Aunque el modelo aborda un fenómeno complejo, con una serie de variables y relaciones que no es posible incorporar en este ejemplo, el mismo puede permitir explorar algunas cuestiones asociadas a cómo emerge el fenómeno de contagio (foco del análisis en este capítulo) de manera más accesible.

Partimos de un mundo donde existen dos economías nacionales A y B y dos tipos de bienes, 1 y 2. Cada uno de estos sectores-países se encuentra vinculado entre sí a través de relaciones productivas y comerciales. Es decir, que cada sector en cada país requiere como insumos las producciones del resto de los sectores-países para llevar a cabo la propia. Para simplificar, asumimos que no hay demanda final y que los sectores no acumulan producción propia.

La matriz \mathbf{Z} de relaciones intersectoriales está dada por:

$$\mathbf{Z}_{4 \times 4} = \begin{array}{c} \mathbf{A1} \quad \mathbf{A2} \quad \mathbf{B1} \quad \mathbf{B2} \\ \mathbf{A1} \\ \mathbf{A2} \\ \mathbf{B1} \\ \mathbf{B2} \end{array} \begin{pmatrix} 10 & 0 & 10 & 5 \\ 5 & 10 & 15 & 0 \\ 5 & 10 & 10 & 10 \\ 15 & 10 & 5 & 0 \end{pmatrix}$$

donde las columnas indican las compras que le realiza cada sector-país al resto de los sectores-países y en las filas se leen las ventas realizadas por cada sector-país al resto de ellos.

Como no existe demanda final y la matriz ya incorpora la demanda externa (recordemos que hay dos países en este mundo simplificado) la producción de cada sector va a estar dada por el vector \mathbf{x} :

$$\mathbf{x} = \begin{array}{c} \mathbf{A1} \\ \mathbf{A2} \\ \mathbf{B1} \\ \mathbf{B2} \end{array} \begin{pmatrix} 25 \\ 30 \\ 35 \\ 30 \end{pmatrix}$$

Por lo tanto, la matriz \mathbf{A} de coeficientes técnicos va a estar dada por:

$$\mathbf{A} = \begin{array}{c} \mathbf{A1} \quad \mathbf{A2} \quad \mathbf{B1} \quad \mathbf{B2} \\ \mathbf{A1} \\ \mathbf{A2} \\ \mathbf{B1} \\ \mathbf{B2} \end{array} \begin{pmatrix} 0.4 & 0 & 0.28 & 0.16 \\ 0.2 & 0.33 & 0.42 & 0 \\ 0.2 & 0.33 & 0.28 & 0.33 \\ 0.6 & 0.33 & 0.14 & 0 \end{pmatrix}$$

Además de insumos, los sectores productivos requieren de trabajadores para la producción. Asumimos que en todos los sectores utilizan 100 unidades de trabajo para la producción especificada en \mathbf{x} , y definimos un vector de coeficientes técnicos para la mano de obra \mathbf{a}^1 dado por:

$$\mathbf{a}^1 = \begin{array}{c} \mathbf{A1} \\ \mathbf{A2} \\ \mathbf{B1} \\ \mathbf{B2} \end{array} \begin{pmatrix} 4 \\ 3.3 \\ 2.8 \\ 3.3 \end{pmatrix}$$

De esta manera, el trabajo puede ser entendido en este modelo como un insumo más para la producción. La producción máxima que puedan alcanzar entonces va a estar restringida por los insumos intermedios o por la disponibilidad de trabajadores:

$$\mathbf{x}^{\max} = \min[\text{diag}^{-1}(\mathbf{a}^1)\mathbf{l}; \text{colmin}(\mathbf{Z}^* \oslash \mathbf{A})]$$

donde \oslash indica división elemento por elemento en las dos matrices y \mathbf{Z}^* es la matriz de insumos efectivamente conseguidos en un momento determinado.

Dado que asumimos que los sectores no almacenan producción propia, la producción de cada uno va a estar dada por el mínimo entre lo máximo que es posible producir, dada la disponibilidad de insumos y trabajadores, y la demanda que reciben del resto de los sectores productivos \mathbf{x}^d :

$$\mathbf{x} = \min[\mathbf{x}^{\max}; \mathbf{x}^d]$$

donde \mathbf{x}^d es el vector de demanda total de producción que enfrenta cada sector del resto de los sectores. En ausencia de perturbaciones, en esta economía global $\mathbf{Z} = \mathbf{Z}^*$ y se alcanza el nivel de producción especificado en el vector \mathbf{x} .

Supongamos ahora que tiene lugar un shock sobre la disponibilidad de trabajadores en el sector 2, tanto en A como en B, que hace que se reduzca en un 50%. Este shock puede deberse a distintos motivos, como las restricciones a la movilidad que tuvieron lugar en la pandemia por COVID-19, o una nueva legislación laboral que reduce la jornada laboral en cierto sector, entre otras situaciones. Entonces ahora, el vector de trabajo va a ser igual a:

$$\mathbf{l}_1 = \begin{matrix} \mathbf{A1} \\ \mathbf{A2} \\ \mathbf{B1} \\ \mathbf{B2} \end{matrix} \begin{pmatrix} 100 \\ 50 \\ 100 \\ 50 \end{pmatrix}$$

Dado que se redujo la disponibilidad de un insumo, se reducirá el primer elemento de la ecuación \mathbf{x}^{\max} , lo cual nos indica cuánto se puede producir al nivel actual de trabajadores disponibles en cada sector. Este resultado podemos obtenerlo dividiendo el vector \mathbf{l} por el vector \mathbf{a}^1 , elemento por elemento:

$$\text{diag}^{-1}(\mathbf{a}^1)\mathbf{l}_1 = \begin{matrix} \mathbf{A1} \\ \mathbf{A2} \\ \mathbf{B1} \\ \mathbf{B2} \end{matrix} \begin{pmatrix} \frac{100}{4} = 25 \\ \frac{50}{3.2} = 15.6 \\ \frac{100}{2.8} = 35 \\ \frac{50}{3.2} = 15.6 \end{pmatrix}$$

El resultado anterior nos indica lo máximo que puede producir cada sector con la nuevas unidades de trabajo disponibles en la economía posterior al shock. Se ven afectados de manera directa el sector 2 en los países A y B, donde su producción se reduce en un 50%. Mientras que en el sector 1 de los países A y B, la producción no cambia como consecuencia directa del shock, ya que no se ven alcanzados por el mismo.

Claramente, esto no es un equilibrio estable; es decir, no es posible que todos los sectores alcancen dicha producción, porque al reducirse la producción en un sector este demandará menos insumos del resto de los sectores, impactando en la producción final de los mismos. La información respecto del cambio en la producción provocado por un cambio en los pedidos de insumos recibidos por cada sector productivo la podemos obtener premultiplicando por la matriz \mathbf{A} a $\text{diag}^{-1}(\mathbf{a}^1)(\mathbf{I} - \mathbf{I}_1)$, que nos dice el impacto del shock sobre el trabajo en la producción de los sectores afectados de manera directa. De esta manera:

$$\mathbf{A}[\text{diag}^{-1}(\mathbf{a}^1)(\mathbf{I} - \mathbf{I}_1)] = \underbrace{\begin{pmatrix} 0.4 & 0 & 0.28 & 0.16 \\ 0.2 & 0.33 & 0.42 & 0 \\ 0.2 & 0.33 & 0.28 & 0.33 \\ 0.6 & 0.33 & 0.14 & 0 \end{pmatrix}}_{\mathbf{A}} \cdot \underbrace{\begin{pmatrix} 25 \\ 15.6 \\ 35 \\ 15.6 \end{pmatrix}}_{\text{diag}^{-1}(\mathbf{a}^1)(\mathbf{I} - \mathbf{I}_1)} = \underbrace{\begin{pmatrix} 22.3 \\ 24.8 \\ 25.11 \\ 34.15 \end{pmatrix}}_{\mathbf{x}_1^d}$$

Ahora bien, la producción que efectivamente se lleva a cabo se determina por el mínimo entre lo máximo posible dados los recursos y la demanda que recibe cada sector-país del resto:

$$\mathbf{x}_1 = \min \left[\underbrace{\begin{pmatrix} 25 \\ 15.6 \\ 35 \\ 15.6 \end{pmatrix}}_{\mathbf{x}_1^{\max}} ; \underbrace{\begin{pmatrix} 22.3 \\ 24.8 \\ 25.11 \\ 34.15 \end{pmatrix}}_{\mathbf{x}_1^d} \right] = \begin{pmatrix} 22.3 \\ 15.6 \\ 25.11 \\ 15.6 \end{pmatrix}$$

Por lo tanto, la caída en la producción total contabilizando estos efectos postshock asimétrico en términos sectoriales sobre la disponibilidad de trabajo del 50% es del 35%. El efecto directo es aquel que se explica únicamente por el efecto del shock de manera directa, y esto sería una caída del 23% en la producción total. La diferencia, se explica por el hecho de que los sectores ven restringidos los vínculos productivos. Si lo miramos por sector-país, en el ejemplo representado la caída de la producción del sector 2 en ambos países del 50% se explica completamente por el efecto directo: el tamaño del mismo es tal que compensa lo que podrían disminuir adicionalmente por la caída en la demanda. Por su parte, el sector 1 en el país A se redujo en un 11% y en el país B en un 28%. En ambos casos, esto se explica únicamente por el efecto indirecto, ya que no han estado expuestos al shock sobre la oferta de trabajo de manera directa.

Vale destacar que lo presentado en esta sección representa un ejemplo numérico de lo que es una versión muy simplificada del modelo para poder ilustrar la lógica subyacente. En este sentido, en el modelo utilizado en este capítulo operan muchos mecanismos que aquí no se contemplan para mantener un entorno simple, como lo son, por ejemplo, el rol de las expectativas de demanda de los sectores y el rol también del tiempo.

1.6.2 Análisis de robustez ante cambios en la formación de expectativas

Realizamos un análisis de robustez de los principales resultados del modelo ante cambios en la forma en la que se modelizan las expectativas de corto plazo, factor clave para la determinación del volumen de producción de los distintos sectores. En específico, exploramos dos formas diferentes de expectativas adaptativas²³, alternativas a la ecuación (1.4).

Recordemos que en el modelo desarrollado en la sección 1.2, en las expectativas de demanda de corto plazo los sectores económicos incorporaban el efecto que tendría el shock (sobre la oferta de trabajo o sobre la disponibilidad de bienes de un sector específico) en la producción de sus socios comerciales y, por lo tanto, en los insumos que demandarían de su sector, como se expresa en la ecuación (1.4). Es decir, que sus expectativas podían ajustarse a lo que sucedería con los pedidos recibidos de otros sectores.

Ahora vamos a considerar dos alternativas de expectativas adaptativas, donde en lugar de conocer exactamente la variación en la demanda como consecuencia del shock, los agentes solo utilizan información de demanda pasada e información del ambiente.

En el primer caso, que llamaremos de *expectativas adaptativas* tradicionales los sectores económicos aprenden de sus predicciones y errores pasados. Es decir, igualan la demanda esperada a la predicción del período previo, ajustado por el error de pronóstico efectivamente alcanzado:

$$\mathbf{x}_t^{\text{e,CP1}} = \mathbf{x}_{t-1}^{\text{e,CP1}} + \theta_1 \left[\mathbf{x}_{t-1}^{\text{d}} - \mathbf{x}_{t-1}^{\text{e,CP1}} \right], \quad (1.20)$$

con $\theta_1 > 0$.

En el segundo caso, que se asemeja al que Dosi *et al.* (2006) llaman *expectativas "micro-macro"*, los sectores incorporan además la dinámica de la economía al formar sus expectativas, considerando la variación del producto global y de su demanda pasada:

$$\mathbf{x}_t^{\text{e,CP2}} = \left[1 + \theta_2 \Delta \mathbf{x}_{t-1,t-2}^{\text{d}} + \theta_3 \Delta \mathbf{y}_{t-1,t-2} \right] \mathbf{x}_{t-1}^{\text{d}}, \quad (1.21)$$

con $0 < \theta_{2,3} < 1$.

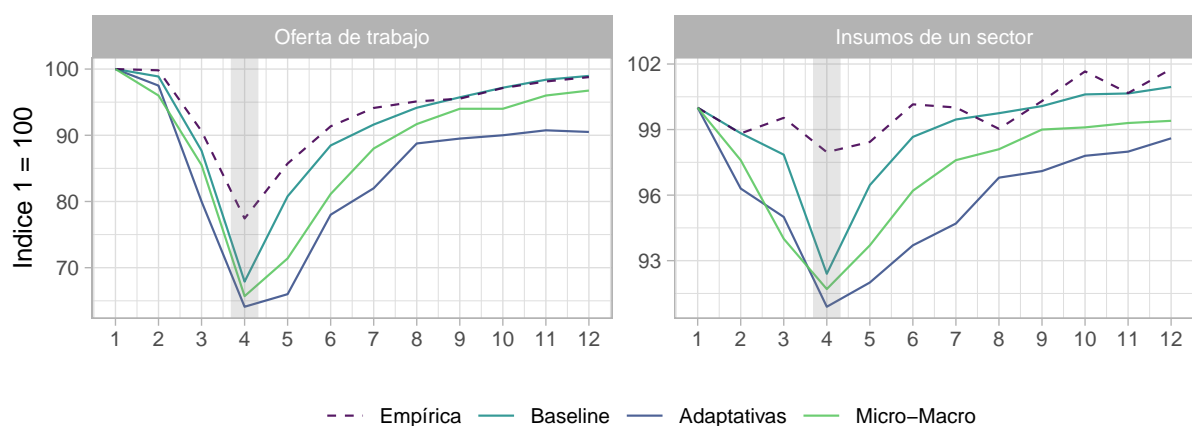
En estas dos especificaciones tenemos tres parámetros nuevos que deben ser estimados: $\theta_i, i = 1, 2, 3$. Para ello, seguimos el mismo procedimiento de estimación descrito en la sección 1.3, pero fijando los valores del resto de los parámetros en los mismos que habíamos determinado previamente, con el objetivo de poder comparar los resultados con los descritos en la sección 1.4. De esta manera, los valores de estos nuevos parámetros quedan determinados en: $\theta_1 = 1$, $\theta_2 = 0.06$ y $\theta_3 = 0.3$; mientras que el resto de los valores del modelo son los que se especifican en el cuadro 1.1.

²³Ver, por ejemplo, Dosi *et al.* (2006) para una exploración del efecto de cambiar el modelizado de expectativas de demanda en un Modelo Basado en Agentes macroeconómico.

El líneas generales, los resultados del modelo con diferentes alternativas en la especificación de las expectativas de corto plazo de los sectores son robustos en lo que refiere a las principales conclusiones obtenidas. La figura 1.10 muestra la evolución de la producción agregada para los dos tipos de shock modelizados (es decir, sobre la oferta de trabajo y sobre la energía proveniente de Rusia) considerando los distintos regímenes de expectativas de corto plazo: (1) baseline, ecuación (1.4); (2) adaptativas, ecuación (1.20); y (3) micro-macro, ecuación (1.21). La línea punteada representa, en ambos casos, a la evolución empírica observada de la producción global. Como puede observarse, las dos formas alternativas de modelizar a las expectativas de corto plazo sobreestiman más que en el caso base la caída de la producción respecto a lo observado empíricamente. No obstante, para ambos tipos de shock las diferencias en el período en cuestión no son considerables. Para el caso de un shock sobre la oferta de trabajo, el modelo predice una caída global de la producción de 34.4% y 33.4%, bajo expectativas adaptativas y micro-macro, respectivamente (versus el 32.1% bajo las expectativas base). En el caso de un shock que interrumpe el suministro de energía proveniente de Rusia, la caída en la producción global que predice el modelo es del 9.1% y 8.5%, respectivamente, bajo expectativas adaptativas y micro-macro (versus el 7.6% bajo expectativas base).

La evolución de la producción post-shock sigue una tendencia similar bajo los tres regímenes de expectativas de corto plazo consideradas. En los casos (2) y (3) –a diferencia del caso (1)– el retorno al momento inicial se da a una menor velocidad y se observa una mayor volatilidad cuando las expectativas son de tipo adaptativas o micro-macro, respecto de las modelizadas en el escenario base. Finalmente, cabe mencionar que a nivel sectorial se observan resultados similares.

Figura 1.10: Evolución de la producción industrial en los datos empíricos y simulados bajo diferentes reglas de formación de expectativas de corto plazo.



Las expectativas de corto plazo tienen un efecto directo sobre el stock de insumos que los sectores desean tener en el siguiente período. Por lo tanto, son un elemento clave del modelo para determinar el nivel de producción. No obstante, la producción efectivamente llevada adelante por los sectores no depende solamente de estas expectativas, sino también de la magnitud del shock

Cuadro 1.5: Descomposición del impacto del shock asimétrico a la oferta de trabajo sobre la producción, en efecto directo e indirecto. Sectores agregados.

Sector	Expectativas adaptativas			Expectativas micro-macro		
	Efecto directo	Efecto indirecto	Efecto total	Efecto directo	Efecto indirecto	Efecto total
Agricultura	-3.03	-21.73	-24.76	-3.03	-20.22	-23.25
Minería	-32.05	-1.99	-34.04	-32.05	-1.85	-33.90
Industria manufacturera	-22.43	-12.81	-35.24	-22.43	-11.92	-34.35
Electricidad y gas	0.00	-46.47	-46.47	0.00	-43.25	-43.25
Agua y residuos	0.00	-10.02	-10.02	0.00	-9.33	-9.33
Construcción	-37.85	-0.14	-37.99	-37.85	-0.13	-37.98
Comercio	-23.92	-16.53	-40.45	-23.92	-15.38	-39.30
Transporte	-7.17	-56.01	-63.18	-7.17	-52.13	-59.30
Hotelería y restaurantes	-61.87	-3.67	-65.54	-61.87	-3.41	-65.28
Telecomunicaciones	-8.19	-29.18	-37.38	-8.19	-27.16	-35.36
Finanzas	0.00	-9.08	-9.08	0.00	-8.45	-8.45
Servicios inmobiliarios	-8.41	0.00	-8.41	-8.41	0.00	-8.41
Actividades profesionales	-3.96	-23.36	-27.32	-3.96	-21.74	-25.70
Actividades administrativas	-31.29	0.00	-31.29	-31.29	0.00	-31.29
Administración pública	-1.12	-2.33	-3.45	-1.12	-2.17	-3.29
Educación	0.00	-25.71	-25.71	0.00	-23.93	-23.93
Servicios sociales y de salud	-0.03	-34.98	-35.01	-0.03	-32.56	-32.59
Otros servicios	0.00	0.00	0.00	0.00	0.00	0.00
Total	-19.90	-14.54	-34.44	-19.90	-13.54	-33.44
Participación	57.78	42.22		59.52	40.48	

Cuadro 1.6: Descomposición del impacto del shock asimétrico a la oferta de trabajo sobre la producción, en efecto directo e indirecto. Sectores agregados.

Sector	Expectativas adaptativas			Expectativas micro-macro		
	Efecto directo	Efecto indirecto	Efecto total	Efecto directo	Efecto indirecto	Efecto total
Agricultura	-2.83	-12.56	-15.39	-2.83	-11.28	-14.11
Minería	-4.42	-3.27	-7.68	-4.42	-2.93	-7.35
Industria manufacturera	-2.60	-8.64	-11.23	-2.60	-7.76	-10.35
Electricidad y gas	-3.22	-1.74	-4.96	-3.22	-1.56	-4.78
Agua y residuos	-2.54	-1.93	-4.46	-2.54	-1.73	-4.27
Construcción	-1.57	-1.09	-2.66	-1.57	-0.98	-2.55
Comercio	-1.15	-1.42	-2.57	-1.15	-1.27	-2.43
Transporte	-2.22	-13.03	-15.25	-2.22	-11.71	-13.92
Hotelería y restaurantes	-3.38	-0.63	-4.01	-3.38	-0.56	-3.95
Telecomunicaciones	-2.31	-12.11	-14.42	-2.31	-10.88	-13.19
Finanzas	-1.45	-2.05	-3.50	-1.45	-1.85	-3.29
Servicios inmobiliarios	-1.33	-0.16	-1.49	-1.33	-0.14	-1.47
Actividades profesionales	-0.90	-6.66	-7.57	-0.90	-5.99	-6.89
Actividades administrativas	-1.17	-0.20	-1.37	-1.17	-0.18	-1.35
Administración pública	-0.92	-2.49	-3.41	-0.92	-2.24	-3.15
Educación	-2.83	-0.01	-2.84	-2.83	-0.01	-2.84
Servicios sociales y de salud	-1.89	-6.21	-8.10	-1.89	-5.58	-7.47
Otros servicios	0.00	0.00	0.00	0.00	0.00	0.00
Total	-3.41	-5.70	-9.11	-3.41	-5.12	-8.53
Participación	37.44	62.56		39.99	60.01	

que afecta a los insumos y/o factores productivos disponibles para la producción. La ecuación (1.3) muestra que la producción puede estar limitada, en principio, o por la disponibilidad de mano de obra, o por la cantidad de insumos que los sectores acumularon el período previo para la producción actual. Como mencionamos, esto último es lo que determinan las expectativas de corto plazo, afectando lo que el sector demandará al resto de los sectores. La ecuación (1.3) refleja la máxima cantidad de producción que un sector puede llevar adelante dados los recursos disponibles. Luego, la producción que efectivamente se llevará adelante, dependerá de cómo es este valor respecto de la demanda final que enfrentan los sectores económicos: $\mathbf{x}_t = \min(\mathbf{x}^{\max}; \mathbf{x}^d)$. Por lo tanto, las expectativas pueden tener dos efectos posibles sobre la producción. (1) En primer lugar, si se subestima la demanda de insumos lo suficiente, entonces el valor de x^{max} puede ser menor al efecto directo y menor a la demanda recibida de los sectores. En este caso, se observará una mayor participación del efecto indirecto y una mayor caída en el producto. (2) Por otro lado, si se sobreestima la demanda de insumos, entonces x^{max} coincidirá con el efecto directo. En este caso, puede que tenga una mayor participación el efecto directo y se observe una menor caída del producto.

En los cuadros 1.5 y 1.6 se presentan los resultados de la descomposición del shock sectorial asimétrico en efecto directo e indirecto, para los casos en los que se afecta la oferta de trabajo y la disponibilidad de energía proveniente de Rusia, respectivamente.

En el caso de un shock sobre la oferta de trabajo, los resultados muestran un mayor efecto global sobre la producción respecto al escenario base, para ambas formas alternativas de modelizar a las expectativas de corto plazo. Dado que el shock se modelizó de la misma manera, el tamaño del efecto directo es el mismo, por lo que en ambos casos se observa un incremento en el tamaño del efecto indirecto. Las expectativas adaptativas dan como resultado una participación del 57.8% y 42.2% para los efectos directo e indirecto respectivamente. Estos valores implican un incremento de 4.2 p.p. en la participación del efecto indirecto. Por otro lado, las expectativas micro-macro predicen una participación del efecto directo del 59.5% y del indirecto del 40.5%, lo que implica un incremento en la participación de este último de 2.5 p.p.

Los resultados observados para el caso de un shock que interrumpe el suministro de energía por parte de Rusia, los resultados son similares, aunque parece que el efecto del cambio en el comportamiento de los sectores económicos es mayor. Esto puede explicarse por el hecho de que en este caso, la importancia del efecto indirecto era mucho mayor, respecto del caso en el que se modeliza un shock asimétrico sobre la oferta de trabajo. Al igual que en el caso previo, el shock no cambió por lo que el efecto directo es el mismo que obtenido en la sección 1.4.2, mientras que el efecto indirecto tiene un tamaño mayor. Si las expectativas se modelizan como adaptativas, la participación de los efectos directo e indirecto es, respectivamente, del 37.4% y 62.6%. Esto implica un incremento en la participación de este último efecto de 7.4 p.p. Por su parte, las expectativas micro-macro preveen una participación del efecto directo del 40% y del indirecto del 60%, lo que implica un incremento en la participación de este último de 4.8 p.p.

En síntesis, podemos decir que los resultados muestran que domina el efecto de la subestimación de la demanda en la formación de expectativas, lo que tiene un efecto positivo sobre la participación del efecto directo en la caída total de la producción.

1.6.3 Análisis de sensibilidad

Para el análisis de sensibilidad del modelo, obtuvimos los resultados considerando las dos variaciones estudiadas, es decir los dos tipos de shock, modificando el valor de a un parámetro a la vez, en una ventana o rango de valores determinado. Como variable a analizar seleccionamos la variación del producto total global mensualizada, entre el período de inicio y lo que se corresponde al mes 4. El objetivo de esta selección, es hacerlo comparable con los resultados que se presentan en las Figuras 1.2 y 1.5.

A continuación se detallan los valores asignados a los parámetros para análisis de sensibilidad. En todos los intervalos se consideró un total de 11 elementos y se mantuvo al valor del parámetro seleccionado en el procedimiento de calibración como la mediana de cada intervalo. Los límites superior e inferior se definieron como los valores cercanos al $\pm 25\%$ del valor original del parámetro.

- Para el caso del shock tipo 1 (sección 1.4.1):
 1. δ en el intervalo [0.0504; 0.0756] en saltos de a 0.0025
 2. γ en el intervalo [36; 56] en saltos de a 2
 3. β_{agro} en el intervalo [13; 23] en saltos discretos de a 1
 4. β_{min} en el intervalo [11; 21] en saltos discretos de a 1
 5. β_{ind} en el intervalo [8; 18] en saltos discretos de a 1
 6. β_{ener} en el intervalo [20; 30] en saltos discretos de a 1
 7. β_{cons} en el intervalo [20; 30] en saltos discretos de a 1
 8. β_{serv} en el intervalo [6; 16] en saltos discretos de a 1.

- Para el caso del shock tipo 2 (sección 1.4.2):
 1. δ en el intervalo [0.0728; 0.00364] en saltos de a 0.00364
 2. γ en el intervalo [21; 41] en saltos de a 2
 3. β_{agro} en el intervalo [16; 26] en saltos discretos de a 1
 4. β_{min} en el intervalo [13; 23] en saltos discretos de a 1
 5. β_{ind} en el intervalo [12; 22] en saltos discretos de a 1
 6. β_{ener} en el intervalo [21; 31] en saltos discretos de a 1
 7. β_{cons} en el intervalo [23; 33] en saltos discretos de a 1
 8. β_{serv} en el intervalo [14; 24] en saltos discretos de a 1.

Las Figuras 1.11 y 1.12 describen de manera general cómo se modifica la variación del producto en los datos simulados, cuando cambian los valores de los parámetros de a uno por vez, para

los casos respectivos de los eventos disruptivos modelizados en las secciones 1.4.1 y 1.4.2. Como era de esperarse, la influencia de cada parámetro en el output de las simulaciones respecto de la variación del producto global, es similar para ambos casos. En líneas generales, se observa que la caída en el producto es más sensible al valor de δ que al de cualquier otro parámetro, seguido de γ y los parámetros específicos de la industria manufacturera y el sector de servicios (β_{ind} y β_{serv}). El resto de los parámetros tienen un impacto pequeño o nulo sobre el resultado final en la producción global.

En otras palabras, la caída en el producto global que predice el modelo depende centralmente de la mayor o menor estabilidad que tienen las expectativas de largo plazo (ecuación (1.8)). También resulta relevante la sensibilidad o reacción que la demanda de inversión tiene en relación a la dinámica del producto. Esta importancia de γ tiene sentido cuando se considera el papel de las expectativas de largo plazo en el impulso de la producción objetivo de los sectores –también en el largo plazo– para la determinación de los inventarios de insumos intermedios. Menores valores de γ implican que las expectativas de largo plazo están más ligadas a las variaciones de corto plazo de la demanda, incrementando su prociclicidad.

Finalmente, respecto a planificación y el ajuste de los diferentes sectores que da lugar al stock que desean mantener de insumos en cada período (inventarios), los dos sectores con capacidad para modificar la variación del producto son el sector de servicios (explicado en mayor medida por el sector de comercio minorista y mayorista) y la industria manufacturera. Estos dos ramas mencionadas, representan la mayor parte de la producción en las economías que se modelizan en este capítulo, como puede apreciarse en la Figura 1.13.

Referencias

- Acemoglu, D., Akcigit, U., & Kerr, W. (2016). Networks and the macroeconomy: An empirical exploration. *Nber macroeconomics annual*, 30(1), 273-335.
- Acemoglu, D., Carvalho, V. M., Ozdaglar, A., & Tahbaz-Salehi, A. (2012). The network origins of aggregate fluctuations. *Econometrica*, 80(5), 1977-2016.
- Acemoglu, D., Ozdaglar, A., & Tahbaz-Salehi, A. (2015). Networks, shocks, and systemic risk. En Y. Bramoullé, A. Galeotti, & B. Rogers (Eds.), *The oxford handbook on the economics of networks*. Oxford University Press.
- Alatraste Contreras, M., & Fagiolo, G. (2014). Propagation of economic shocks in input-output networks: A cross-country analysis. *Physical Review E*, 90(6), 062812.
- Arto, I., Dietzenbacher, E., & Rueda-Cantuche, J. M. (2019). *Measuring bilateral trade in terms of value added*. Publications Office of the European Union.
- Baqae, D. R., & Farhi, E. (2019). The macroeconomic impact of microeconomic shocks: Beyond Hulten's theorem. *Econometrica*, 87(4), 1155-1203.
- Baqae, D. R., & Farhi, E. (2020). Productivity and misallocation in general equilibrium. *The Quarterly Journal of Economics*, 135(1), 105-163.

Figura 1.11: Caída en el producto mensualizada, período 4 respecto del período 1, de acuerdo al valor de los parámetros. Shock tipo 1.

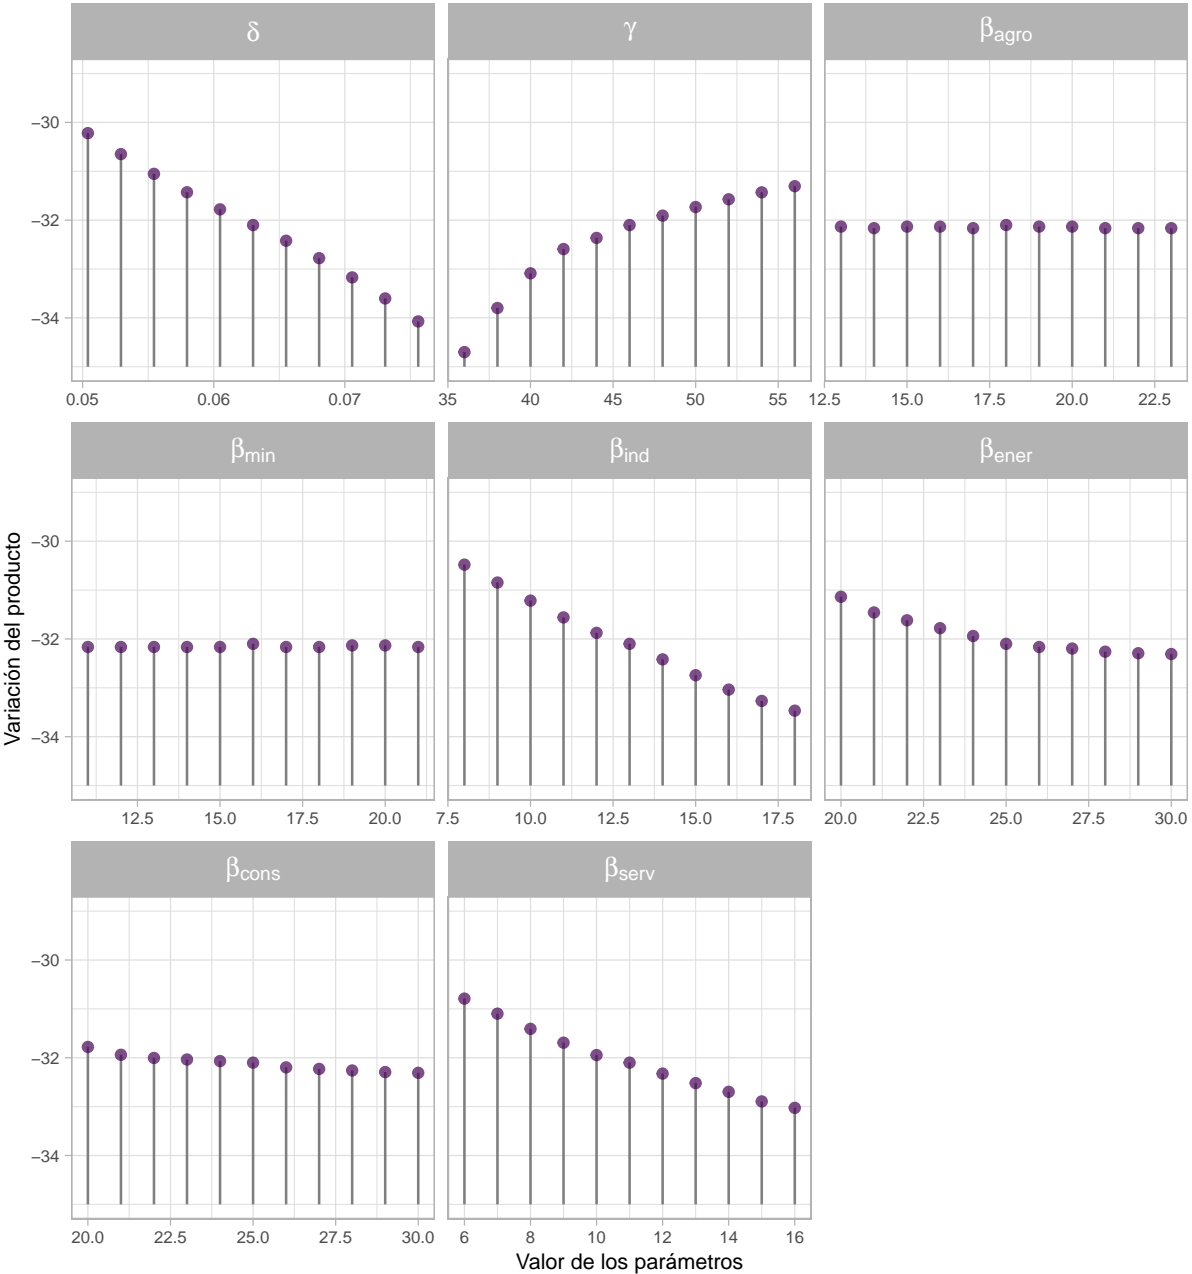



Figura 1.12: Caída en el producto mensualizada, período 4 respecto del período 1, de acuerdo al valor de los parámetros. Shock tipo 2.



- Barrera Insua, F., & Noguera, D. (2023). Determinantes salariales intersectoriales en la Argentina: un modelo de análisis para las dinámicas desiguales del capital y el trabajo. *Cuadernos de economía*, 42(90).
- Barrot, J.-N., & Sauvagnat, J. (2016). Input specificity and the propagation of idiosyncratic shocks in production networks. *The Quarterly Journal of Economics*, 131(3), 1543-1592.
- Battiston, S., Delli Gatti, D., Gallegati, M., Greenwald, B., & Stiglitz, J. E. (2007). Credit chains and bankruptcy propagation in production networks. *Journal of Economic Dynamics and Control*, 31(6), 2061-2084.
- Bellingeri, M., Bevacqua, D., Scotognella, F., Alfieri, R., & Cassi, D. (2020). A comparative analysis of link removal strategies in real complex weighted networks. *Scientific reports*, 10(1), 1-15.
- Bems, R., Johnson, R. C., & Yi, K.-M. (2010). Demand spillovers and the collapse of trade in the global recession. *IMF Economic review*, 58(2), 295-326.
- Bouwmeester, M. C., & Oosterhaven, J. (2017). Economic impacts of natural gas flow disruptions between Russia and the EU. *Energy Policy*, 106, 288-297. <https://doi.org/10.1016/j.enpol.2017.03.030>
- Carvalho, V., & Gabaix, X. (2013). The great diversification and its undoing. *American Economic Review*, 103(5), 1697-1727.
- Christ, C. F. (1955). A review of input-output analysis. *Input-output analysis: An appraisal*, 137-182.
- Cochrane, J. (2009). *Asset pricing: Revised edition*. Princeton university press.
- Conley, T. G., & Dopor, B. (2003). A spatial analysis of sectoral complementarity. *Journal of political Economy*, 111(2), 311-352.
- Costa, S., Sallusti, F., & Vicarelli, C. (2022). Trade networks and shock transmission capacity: a new taxonomy of Italian industries. *Journal of Industrial and Business Economics*, 49(1), 133-153.
- Costa, S., Sallusti, F., Vicarelli, C., & Zurlo, D. (2021). From micro to macro: Micro-foundations of the Italian business cycle co-movements during the crises. *Italian Economic Journal*, 1-24.
- Cresti, L., Dosi, G., & Fagiolo, G. (2023). Technological interdependencies and employment changes in European industries. *Structural Change and Economic Dynamics*, 64, 41-57.
- D'Anieri, P. (2023). *Ukraine and Russia*. Cambridge University Press.
- del Rio-Chanona, R. M., Mealy, P., Pichler, A., Lafond, F., & Farmer, J. D. (2020). Supply and demand shocks in the COVID-19 pandemic: an industry and occupation perspective. *Oxford Review of Economic Policy*, 36(S1), S94-S137. <https://doi.org/10.1093/oxrep/graa033>
- Delli Gatti, D., & Reissl, S. (2022). Agent-Based Covid economics (ABC): Assessing non-pharmaceutical interventions and macro-stabilization policies. *Industrial and Corporate Change*, 31(2), 410-447.
- DePaolis, F., Murphy, P., & De Paolis Kaluza, M. C. (2022). Identifying key sectors in the regional economy: a network analysis approach using input-output data. *Applied Network Science*, 7(1), 86.

- Di Giovanni, J., Levchenko, A. A., & Mejean, I. (2014). Firms, destinations, and aggregate fluctuations. *Econometrica*, *82*(4), 1303-1340.
- Di Giovanni, J., Levchenko, A. A., & Mejean, I. (2018). The micro origins of international business-cycle comovement. *American Economic Review*, *108*(1), 82-108.
- Dosi, G., Fagiolo, G., & Roventini, A. (2006). An evolutionary model of endogenous business cycles. *Computational Economics*, *27*, 3-34.
- Duchin, F. (1983). The World Model: An Interregional Input-Output Model of the World Economy. *Contributions to Economic Analysis*, *147*, 167-182.
- Durán Lima, J. E., & Banacloche, S. (2021). *Análisis económicos a partir de matrices de insumo-producto: definiciones, indicadores y aplicaciones para América Latina*.
- Fagiolo, G., Reyes, J., & Schiavo, S. (2009). World-trade web: Topological properties, dynamics, and evolution. *Physical Review E*, *79*(3), 036115.
- Fernandez-Stark, K., & Gereffi, G. (2019). Global value chain analysis: A primer. En *Handbook on global value chains* (pp. 54-76). Edward Elgar Publishing.
- Gabaix, X. (2011). The granular origins of aggregate fluctuations. *Econometrica*, *79*(3), 733-772.
- Galbusera, L., & Giannopoulos, G. (2018). On input-output economic models in disaster impact assessment. *International journal of disaster risk reduction*, *30*, 186-198.
- Gilli, M., & Winker, P. (2003). A global optimization heuristic for estimating agent based models. *Computational Statistics & Data Analysis*, *42*(3), 299-312.
- Giuliani, E. (2013). Network dynamics in regional clusters: Evidence from Chile. *Research Policy*, *42*(8), 1406-1419.
- Grazzini, J., & Richiardi, M. (2015). Estimation of ergodic agent-based models by simulated minimum distance. *Journal of Economic Dynamics and Control*, *51*, 148-165.
- Guilhoto, J. M., Webb, C., & Yamano, N. (2022). *Guide to OECD TiVA Indicators, 2021 edition* (Working Paper 2022/02). OECD Science, Technology; Industry Working Papers.
- Iliopoulos, P. T., Galanis, G., Kumar, A., & Popoyan, L. (2022). Sectoral market power in global production: a theoretical and observational study. *Advances in Complex Systems*, *25*(02n03), 2240005.
- Kleinberg, J. M. (1999). Authoritative sources in a hyperlinked environment. *Journal of the ACM (JACM)*, *46*(5), 604-632.
- Koks, E., Pant, R., Husby, T., Többen, J., & Oosterhaven, J. (2019). Multiregional disaster impact models: Recent advances and comparison of outcomes. *Advances in spatial and economic modeling of disaster impacts*, 191-218.
- Lamperti, F. (2018). An information theoretic criterion for empirical validation of simulation models. *Econometrics and Statistics*, *5*, 83-106.
- Leontief, W. (1986). *Input-output economics*. Oxford University Press.
- Leontief, W. W. (1936). Quantitative input and output relations in the economic systems of the United States. *The review of economic statistics*, 105-125.
- Long, J. B., & Plosser, C. I. (1983). Real business cycles. *Journal of political Economy*, *91*(1), 39-69.

- Miller, R. E., & Blair, P. D. (2009). *Input-output analysis: foundations and extensions*. Cambridge university press.
- Miyazawa, K. (1968). Input-Output Analysis and Interrelational Income Multiplier as a Matrix. *Hitotsubashi Journal of Economics*, 8(2), 39-58.
- Mottaleb, K. A., Kruseman, G., & Snapp, S. (2022). Potential impacts of Ukraine-Russia armed conflict on global wheat food security: A quantitative exploration. *Global Food Security*, 35, 100659.
- Okuyama, Y. (2007). Economic modeling for disaster impact analysis: past, present, and future. *Economic Systems Research*, 19(2), 115-124.
- Oosterhaven, J., & Bouwmeester, M. C. (2016). A new approach to modeling the impact of disruptive events. *Journal of Regional Science*, 56(4), 583-595.
- Perdana, S., Vielle, M., & Schenckery, M. (2022). European Economic impacts of cutting energy imports from Russia: A computable general equilibrium analysis. *Energy Strategy Reviews*, 44, 101006. <https://doi.org/10.1016/j.esr.2022.101006>
- Pichler, A., Pangallo, M., del Rio-Chanona, R. M., Lafond, F., & Farmer, J. D. (2022). Forecasting the propagation of pandemic shocks with a dynamic input-output model. *Journal of Economic Dynamics and Control*, 144, 104527. <https://doi.org/10.1016/j.jedc.2022.104527>
- Reissl, S., Caiani, A., Lamperti, F., Guerini, M., Vanni, F., Fagiolo, G., Ferraresi, T., Ghezzi, L., Napoletano, M., & Roventini, A. (2022). Assessing the economic impact of lockdowns in Italy: A computational input-output approach. *Industrial and Corporate Change*, 31(2), 358-409.
- Romanoff, E., & Levine, S. H. (1986). Capacity limitations, inventory, and time-phased production in the sequential interindustry model. *Papers in Regional Science*, 59(1), 73-91.
- Shea, J. (2002). Complementarities and comovements. *Journal of Money, Credit, and Banking*, 34(2), 412-433.
- Sraffa, P. (1960). *Production of Commodities by Means of Commodities: Prelude to a Critique of Economic Theory*. Cambridge University Press.
- Umar, Z., Polat, O., Choi, S.-Y., & Teplova, T. (2022). The impact of the Russia-Ukraine conflict on the connectedness of financial markets. *Finance Research Letters*, 48, 102976. <https://doi.org/10.1016/j.frl.2022.102976>

2 Un modelo minskyano con racionamiento de crédito en una economía de red.

2.1 Introducción

La reciente crisis financiera destacó la necesidad de una mejor comprensión de los riesgos sistémicos asociados con las interconexiones dentro del sistema financiero. A su vez, este evento remarcó la importancia de los conceptos de Minsky (1976; 1986; 2016) sobre la fragilidad e inestabilidad financiera, donde se potencia el papel de los bancos para el funcionamiento del sistema financiero y los efectos de la política monetaria. Más importante aún, enfatizó el doble papel del crédito para establecer vínculos entre los sectores real y financiero y como impulsor de inestabilidad (ver, por ejemplo, Schularick y Taylor, 2012; Gusella y Stockhammer, 2021).

En el marco conceptual de Minsky los complejos arreglos financieros desestabilizan las economías, afectando negativamente al sector real. La Hipótesis de Inestabilidad Financiera (HIF) de este autor establece que la estabilidad produce inestabilidad: en períodos de alto crecimiento los agentes forman expectativas optimistas, que luego se traducen en posiciones financieras riesgosas. Mientras los ingresos netos sean positivos, la economía es estable, pero puede ocurrir una crisis cuando no lo sean. Minsky definió así las posiciones financieras con base en la dinámica de sus flujos de caja, como cubiertas, especulativas y Ponzi. En el primer caso, los ingresos esperados superan los compromisos financieros. En el segundo caso, los ingresos son suficientes para pagar intereses pero no capital, por lo que requieren una renovación constante de la deuda. Finalmente, las unidades Ponzi requieren préstamos adicionales y venta de activos porque los ingresos no son suficientes para pagar los intereses. La estabilidad económica depende de las proporciones relativas de cada tipo²⁴.

La teoría de la inestabilidad financiera de Minsky se centra en el financiamiento de las inversiones y la relación entre firmas y bancos. Caverzasi (2014) destaca que los bancos determinan el nivel de deuda agregado y, por lo tanto, son un actor clave en el desempeño general de la economía. En palabras de Minsky, los bancos *“solicitan activamente préstamos a los clientes, asumen compromisos financieros, construyen conexiones con empresas y otros banqueros, y buscan fondos.”* Nikolaidi y Stockhammer (2017) proporcionan una revisión reciente y exhaustiva de la literatura

²⁴Ver, por ejemplo, Chiarella y Di Guilmi (2011) para un modelo dinámico que distinga entre dos grupos de empresas, especulativas y de cobertura.

sobre los modelos económicos consistentes con las propuestas de Minsky, incluyendo los trabajos existentes que destacan el papel activo de los bancos en la emergencia de fragilidad financiera e inestabilidad. Por ejemplo, [Nikolaïdi \(2014\)](#) desarrolla un modelo que distingue entre la inversión deseada y la inversión efectiva de las empresas, donde esta última es menor que la primera debido al racionamiento de crédito. El papel desestabilizador de los bancos ha sido estudiado también en la literatura con respecto al acelerador financiero, un mecanismo que intensifica las fluctuaciones del producto (ver, por ejemplo, [Bernanke, 1989](#); [Bernanke y Gertler, 1990](#); [Bernanke y Blinder, 1988, 1992](#); [Kiyotaki y Moore, 1997](#)). En esta literatura, el sector financiero impone costos crecientes en el lado real de la economía produciendo crisis ([Bernanke *et al.*, 1996](#)). Más específicamente, shocks negativos idiosincráticos en la producción de las firmas hacen que los bancos sean menos propensos a prestar, lo que reduce la inversión y, por lo tanto, produce una nueva caída en la producción.

Gran parte de la literatura que modeliza formalmente la teoría de Minsky, se basa en modelos macroeconómicos agregados. Como señala [Di Guilmi \(2017\)](#), en esta estrategia de modelado se pierde una parte importante de la historia, ya que la participación de las entidades en las distintas posiciones financieras descritas por Minsky –Ponzi, de cobertura y especulativas– en cualquier sector dado puede variar sin cambios en la hoja de balance agregada; como por ejemplo, cuando el aumento de las unidades Ponzi se compensa con mejoras en las hojas de balance de las unidades de cobertura y especulativas. Por su parte, la literatura sobre el acelerador financiero se basa principalmente en modelos de agentes representativos. Sin embargo, como señala [Delli Gatti *et al.* \(2010\)](#), estos modelos no capturan el importante papel de las redes financieras modernas, que ayudan a explicar la inestabilidad económica por al menos tres razones. En primer lugar, los shocks son heterogéneos entre los agentes, por lo que pueden surgir fallas de coordinación y comunicación ([Delli Gatti *et al.*, 2007](#)). En segundo lugar, [Delli Gatti *et al.* \(2010\)](#) muestra que la heterogeneidad juega un papel central para explicar el comportamiento procíclico ([Lavoie y Seccareccia, 2001](#); [Chiarella y Di Guilmi, 2011](#); [Di Guilmi, 2017](#)), un elemento clave en el análisis de Minsky. En tercer lugar, las estructuras de red juegan un papel importante para estudiar las crisis. Como afirman [Stiglitz y Greenwald \(2003\)](#), el crédito es heterogéneo y el exceso de liquidez en algunos agentes no sustituye la escasez de fondos en otros.

Para superar estas dificultades, la literatura desarrolló un marco para estudiar estos fenómenos utilizando modelos basados en agentes (ABM, por sus siglas en inglés) y análisis de redes ([Gallegati *et al.*, 2006](#); [Delli Gatti *et al.*, 2010](#); [Sornette, 2017](#); [Dosi y Roventini, 2019](#)). En líneas generales, los ABM adoptan un enfoque basado en la complejidad que concibe a las economías como sistemas dinámicos de agentes que interactúan entre sí y con el ambiente ([Tsfatsion y Judd, 2006](#)), donde los resultados a nivel macroeconómico son propiedades emergentes. Esto quiere decir que se trata de propiedades del sistema macroeconómico en su conjunto, que no posee por sí sola ninguna parte individual de la economía y, por lo tanto, no se pueden inferir directamente del comportamiento a nivel microeconómico ([Epstein, 2006](#)). En su forma más simple, un ABM se compone por un conjunto de agentes heterogéneos, una escala ajustada a los

fenómenos estudiados y un conjunto de reglas de comportamiento de los agentes, que incluye la forma en la que interactúan²⁵ (LeBaron y Tesfatsion, 2008). En cada período de la simulación, agentes con racionalidad limitada desarrollan sus acciones siguiendo reglas preespecificadas y basadas en la información (limitada) a su disposición. Estas acciones influyen colectivamente en el comportamiento macroeconómico del sistema.

El modelado ABM es un enfoque adecuado para formalizar la HIF centralmente el hecho de que permite incorporar la heterogeneidad entre agentes a nivel individual, tanto en términos de sus atributos o características como respecto a la toma de decisiones. En la HIF es precisamente la heterogeneidad de las condiciones financieras de los agentes y su evolución a lo largo del ciclo lo que impulsa las fluctuaciones macroeconómicas. Asimismo, este marco permite modelizar explícitamente las interacciones directas e indirectas entre agentes y analizar la estructura que las mismas adquieren bajo diferentes condiciones; elemento clave para estudiar la dinámica de contagio, como se mencionó previamente. Al respecto, Minsky (1976) enfatiza la necesidad de considerar las interacciones entre los agentes, ya que “*una realidad última en una economía capitalista es el conjunto de hojas de balance interrelacionadas entre las diversas unidades*” (p. 116). Finalmente, el mismo Minsky (1976) plantea que la forma más adecuada para abordar el fenómeno de inestabilidad financiera es mediante “*estudios de simulación, donde los modelos de simulación se rediseñan para reflejar formas alternativas en que se puede inducir la inestabilidad financiera*”.

Hay varias contribuciones relacionadas con el estudio de redes financieras usando ABM que combinan el origen financiero de las fluctuaciones del producto²⁶ con los riesgos sistémicos derivados de los sistemas financieros²⁷. Algunos resultados clave muestran que cuando la economía crece, las empresas tienen fondos suficientes para pagar sus deudas y, por lo tanto, aumentan las inversiones. Cuando aumenta el apalancamiento agregado, también crece el número de empresas que se declaran en quiebra, lo que afecta las tasas de interés y, posteriormente, la economía real. El análisis de las redes financieras proporciona una compensación interesante entre la diversificación del riesgo y el riesgo sistémico. En general, esta literatura muestra que modelos simples con agentes heterogéneos que interactúan son suficientes para replicar características interesantes.

Este documento contribuye a esta literatura mediante la construcción de un marco de red ABM para evaluar el papel de los bancos en la propagación del estrés financiero al sector real. Este modelo permite estudiar las propiedades del mercado crediticio y su influencia en la economía. Construimos un sistema económico con empresas y bancos que interactúan en un mercado de crédito usando una versión extendida del modelo en Noguera y Montes-Rojas (2022), que se basa en el trabajo de Delli Gatti *et al.* (2010). Modelizamos más en detalle el comportamiento

²⁵El conjunto de agentes y las reglas de comportamiento constituyen lo que se llama la microespecificación del modelo y la escala establece el alcance de los fenómenos macroeconómicos analizados.

²⁶Ver, por ejemplo, Delli Gatti *et al.* (2005); Delli Gatti *et al.* (2008); Russo *et al.* (2007); Delli Gatti *et al.* (2007); Delli Gatti *et al.* (2010); Riccetti *et al.* (2013); Riccetti *et al.* (2016a); Tedeschi *et al.* (2019).

²⁷Ver, por ejemplo, Allen y Gale (2000); Iori *et al.* (2006); Gai y Kapadia (2010); Wagner (2011); Battiston *et al.* (2012a); Gai y Kapadia (2019); Eboli (2019); Mazzarisi *et al.* (2020); Noguera y Montes-Rojas (2022).

de los bancos, donde el racionamiento selectivo del crédito y las tasas de interés se forman endógenamente. El modelo desarrollado corresponde, por lo tanto, a un modelo de tipo Minsky de racionamiento de crédito, tal como se categoriza en [Nikolaïdi y Stockhammer \(2017\)](#).

Las empresas producen un bien final con una demanda dada por un precio estocástico y pueden requerir crédito para la producción. En este marco, la dinámica del flujo de caja es importante. Dado que las firmas son tomadoras de precios, esto genera incertidumbre en los bancos por los riesgos de solvencia financiera de los deudores. Si las dificultades financieras son lo suficientemente grandes, las empresas podrían ser incapaces de pagar sus deudas y enfrentar la quiebra. En una economía de red, la quiebra de una empresa puede afectar los activos netos de los bancos. Estos, a su vez, pueden aumentar las tasas de interés para enfrentar el deterioro de su posición financiera neta. Además, un hecho típico en economías inestables es que los bancos tienen preferencia por la liquidez ([Lavoie, 2014](#)). Entonces, las dificultades de las empresas aumentan las expectativas pesimistas de los bancos, lo que a su vez aumentará su preferencia por la liquidez al racionar el crédito afectando todo el mercado crediticio y las tasas de quiebra de las empresas. Este proceso es similar al de [Delli Gatti *et al.* \(2010\)](#), pero la principal diferencia es que reduce la probabilidad de una quiebra bancaria al mantener los bancos una mayor cantidad de reservas de capital, al tiempo que mantiene (o profundiza) las dificultades del sector real.

Estudiamos dos escenarios diferentes. En el escenario base, los bancos fijan las tasas de interés en función del apalancamiento de las empresas. Los bancos usan fondos para otorgar crédito y no hay racionamiento de crédito, excepto por las restricciones de liquidez de los bancos. Esto está en línea con la compensación entre la solvencia de los bancos y la reducción de los costos de los servicios financieros ([Saunders y Schumacher, 2000](#)).

En un segundo escenario, modelizamos la preferencia de liquidez de los bancos ([Keynes, 1930, 1936](#); [Dow y Dow, 1989](#); [Lavoie, 2009](#); [Minsky, 2016](#)) ya sea por motivos especulativos o para protegerse del riesgo. Los bancos tienen la posibilidad de invertir parte de sus fondos en un determinado activo financiero (cuyo rendimiento se supone exógeno). Este activo corresponde a los bonos del gobierno o de los Bancos Centrales (BC), y puede considerarse exógeno y estar determinado por consideraciones de política que no se modelizan explícitamente aquí (también podría estar relacionado con un cambio exógeno en las preferencias de los bancos). El propósito es estudiar cómo el cambio de la preferencia de liquidez de los bancos afecta tanto al sector financiero como al real. Este escenario pretende describir la economía argentina, un país en el que debido a las presiones inflacionarias y devaluatorias (y también por la estabilidad macroeconómica), el BC utilizó bonos (específicos para bancos) para mantener la moneda local depositada y no canjeada por dólares estadounidenses (ver [D'Erasmus *et al.*, 2020](#), para un estudio relacionado en Argentina). Como consecuencia, la intervención del BC resultó en el desplazamiento de fondos del circuito productivo. Para nuestros propósitos, esto se modeliza como un incremento en la preferencia de liquidez de los bancos.

Los resultados de la simulación muestran que cambiar las estrategias crediticias de los bancos

tiene un efecto en la economía real. Más específicamente, cuando los bancos restringen el crédito a las empresas y reasignan fondos dentro del sistema financiero, aumenta la proporción de quiebras y deudas incobrables de las empresas. Las características topológicas de la red crediticia resultante son relevantes para explicar las fluctuaciones del producto. En particular, un mayor crecimiento está relacionado con más crédito y menores índices de concentración en el mercado crediticio. El modelo ilustra cómo el cambio en la preferencia de liquidez de los bancos afecta a los sectores financiero y real, y la red derivada del análisis conjunto.

Este capítulo está estructurado de la siguiente manera. Las secciones 2.2.1 y 2.2.3 describen las reglas de comportamiento de las firmas y los bancos, y la sección 2.2.2 define su interacción en el mercado de crédito. La sección 2.3 muestra los resultados de la simulación y describe la topología de la red resultante. Luego, se estudia la sensibilidad a parámetros clave en la sección 2.5. La sección 2.6 concluye.

2.2 El modelo

Consideramos una versión extendida del modelo en [Noguera y Montes-Rojas \(2022\)](#), que se basa en el trabajo de [Delli Gatti *et al.* \(2010\)](#) y se corresponde con lo que [Minsky \(1986, 250\)](#) definió como una “economía capitalista básica”. Presenta una economía dinámica poblada por dos tipos de agentes heterogéneos, firmas (i) y bancos (z), que interactúan en el mercado crediticio, por períodos de tiempo $t = 1, 2, \dots, T$. Las firmas producen un bien que se vende a un precio estocástico y solicitan crédito para la producción. La incertidumbre de los precios afecta el comportamiento de las firmas y los bancos porque shocks negativos pueden afectar la solvencia de las firmas. La estructura del modelo permite analizar las formas de interacción entre los agentes y sus comportamientos. El foco de este estudio está en el comportamiento de los bancos en un contexto de incertidumbre. Simplificamos la representación del sector real de la economía, pero presentamos un mayor detalle de los balances de los bancos e incluimos la posibilidad de que adquieran activos financieros, lo cual no está presente en el trabajo de [Delli Gatti *et al.* \(2010\)](#).

Por otro lado, analizamos cómo las expectativas de los bancos con respecto a la evolución de la economía (y, por lo tanto, la capacidad de pago de las empresas) tienden a ser procíclicas, un elemento clave en la dinámica de Minsky. El racionamiento de crédito por parte de los bancos se ve afectado por su ratio de apalancamiento, sus expectativas sobre la actividad económica y el ratio de apalancamiento de las empresas. En períodos de auge, la provisión de préstamos se vuelve gradualmente mayor, lo que puede llevar a la inestabilidad. Los bancos están más dispuestos a reducir el racionamiento de crédito cuando sus expectativas sobre la actividad económica son positivas.

Finalmente, el capítulo muestra el valor añadido de un enfoque de agentes heterogéneos en los modelos de Minsky, no extensamente explorado en la literatura, como señalan [Nikolaïdi y Stockhammer \(2017\)](#).

2.2.1 Firmas

Las firmas $i = 1, 2, \dots, I$ producen un bien de consumo en cada período t , Y_{it} . La producción se vende en el mismo período y no hay acumulación de inventarios entre períodos. Todas las empresas tienen la misma tecnología lineal que utiliza el trabajo (L_{it}) como único factor de producción, dada por

$$Y_{it} = L_{it} \frac{1}{\phi_1}, \quad (2.1)$$

donde $\frac{1}{\phi_1}$ representa la productividad laboral constante. Se asume un salario constante w y una oferta de trabajo perfectamente elástica. Los costos se definen entonces como $W_{it} = wL_{it}$.

La demanda de trabajo de cada firma depende de los recursos financieros de los que dispone: fondos propios, representados por el patrimonio neto A_{it} , y fuentes externas, representadas por el crédito bancario. Para determinar cuántos recursos financieros requerirán en cada período, las firmas computan la cantidad de producción deseada Y_{it}^d , con

$$Y_{it}^d = \phi_o (A_{it})^\beta, \quad (2.2)$$

donde $\phi_o > 0$ y $0 < \beta < 1$ son parámetros constantes. La ecuación (2.2) representa una forma reducida del problema de optimización presentado en [Greenwald y Stiglitz \(1993\)](#)²⁸.

Combinando las ecuaciones (2.1) y (2.2) obtenemos la demanda de trabajo,

$$L_{it} = \phi_1 \phi_o (A_{it})^\beta. \quad (2.3)$$

Para financiar la producción se establece una jerarquía de fuentes de recursos (ver, por ejemplo, [Céspedes et al., 2010](#); [Maquieira et al., 2012](#)). En primer lugar, utilizan recursos propios y, luego, si es necesario fuentes externas. Definimos a la posición financiera (FP) de una firma i como

$$FP_{it} = W_{it} - A_{it}. \quad (2.4)$$

Luego, definimos \mathcal{F}_t^1 al set de firmas i con $FP_{it} > 0$ (firmas autosuficientes en términos financieros, es decir, autofinanciadas) y \mathcal{F}_t^0 al set de firmas i con $FP_{it} \leq 0$ (firmas no autofinanciadas).

Por lo tanto, las firmas demandan crédito cuando $FP_{it} > 0$, y esto está dado por

$$Bd_{it} = FP_{it} \cdot \mathbf{1}[FP_{it} > 0], \quad (2.5)$$

²⁸Para una discusión detallada sobre el uso de esta función de producción ver [Delli Gatti et al. \(2010, 1630:1631\)](#).

donde $\mathbf{1}[\cdot]$ es la función indicadora y Bd_{it} es el monto de crédito demandado por la firma i en el momento t , el cuál podría diferir del monto recibido, B_{it} .

Los bancos $z = 1, 2, \dots, Z$ (descritos en la sección 2.2.3) cobran a las firmas en \mathcal{F}_t^1 una tasa de interés r_{izt} por el crédito otorgado. Las firmas pueden obtener crédito de distintos bancos y el costo de los intereses varía en función del banco (ver la ecuación 2.13). La tasa de interés promedio para la empresa i es $r_{it}^* = \frac{1}{B_{it}} \sum_z r_{izt} B_{izt}$, with $B_{it} = \sum_z B_{izt}$, donde B_{it} es el crédito efectivamente obtenido.

Por simplicidad, se supone que las firmas con excedentes de recursos financieros lo mantienen en efectivo por fuera del sistema financiero. Por lo tanto, los beneficios de las firmas (Π_{it}) están dados por

$$\Pi_{it} = p_{it}Y_{it} - \left[W_{it} + \sum_z r_{izt}B_{izt} \right], \quad (2.6)$$

donde p_{it} es el precio unitario, que se modeliza como una variable aleatoria $p_{it} = \alpha + g_{it}$, con $g \sim \mathcal{N}(0, \sigma^2)$ ²⁹

La quiebra de empresas es un elemento central en el modelo. Siguiendo a [Arslan et al. \(2016\)](#), una empresa puede declararse en quiebra por dos razones: insolvencia y liquidez. Una empresa entra en quiebra debido a la insolvencia cuando su patrimonio neto toma un valor negativo. Dado que el modelo no incorpora dividendos y la empresa suma sus ganancias al patrimonio neto, la ley de movimiento de este último se determina de la siguiente manera:

$$A_{it} = A_{it-1} + \Pi_{it} \quad (2.7)$$

Por lo tanto, la regla para determinar si una empresa está en quiebra debido a insolvencia se determina mediante la ecuación (2.8).

$$quiebra1_{it} = \begin{cases} verdadero & \text{si } A_{it} \leq 0 \\ falso & \text{si } A_{it} > 0 \end{cases} \quad (2.8)$$

Una empresa también puede entrar en quiebra debido a la falta de liquidez, lo que ocurre cuando los compromisos de deuda (capital e intereses) superan las ganancias obtenidas en el período (ver ecuación 2.9). Según [Minsky \(1986\)](#), es necesario entender las unidades económicas en términos de sus flujos de efectivo para comprender cómo sus compromisos financieros afectan a la economía real. Los compromisos de pago de las empresas están limitados por los flujos de efectivo realizados y esperados. En el modelo, se supone que las empresas mantienen una proporción θ de su patrimonio en activos líquidos. Por lo tanto, en cada período, los ingresos en efectivo se

²⁹Esta forma de modelizar un shock exógeno específico para cada unidad productiva es común en la literatura, véase, por ejemplo, [Delli Gatti et al. \(2010\)](#); [Ricetti et al. \(2013\)](#); [Ricetti et al. \(2016a\)](#).

componen de ganancias y activos líquidos, mientras que los egresos en efectivo son los pagos de capital e intereses de la deuda asumida. La diferencia entre ellos da como resultado el flujo de efectivo neto (liq_{it}):

$$liq_{it} = \Pi_{it} + \theta A_{it} - \sum_z (1 + r_{izt}) B_{izt}. \quad (2.9)$$

Si liq_{it} es negativo, la empresa carece de liquidez. Esta falta de liquidez no es lo que lleva a la empresa a la quiebra, ya que esto ocurre –como se indica en la ecuación (2.10)– cuando la relación entre la liquidez y el valor de la producción (en términos absolutos) supera cierto nivel liq_{max} . Si la posición de liquidez de la empresa es negativa pero su valor absoluto está por debajo del nivel de liq_{max} , la empresa no declara quiebra, pero los bancos pueden negarle el acceso al crédito, lo que complica la situación financiera de la empresa.

$$quiebra_{2it} = \begin{cases} verdadero & \text{si } \left| \frac{liq_{it}}{Y_{it}} \right| > liq_{max} \\ falso & \text{si } \left| \frac{liq_{it}}{Y_{it}} \right| \leq liq_{max} \end{cases} \quad (2.10)$$

En las simulaciones (ver Sección 2.3), cuando una empresa i quiebra, es reemplazada por otra empresa con un valor neto pequeño en comparación con el de las empresas incumbentes. Más específicamente, será un número aleatorio distribuido uniformemente entre cero y \bar{A} ($\mathcal{U}[0; \bar{A}]$). Este mecanismo de entrada y salida de empresas en el mercado mantiene constante el vector I entre períodos.

2.2.2 Interacción entre empresas no autofinanciadas y formación de la red de crédito de los bancos

La red de crédito está compuesta por \mathcal{FP}_t de I empresas y \mathcal{Z}_t de Z bancos, con I y Z constantes a lo largo del tiempo. El grupo de empresas que no pueden financiar su producción solo con fondos propios es \mathcal{FP}_t^1 , de lo contrario es \mathcal{FP}_t^0 (ver ecuación 2.4 para la definición de estos grupos). Por lo tanto, $\mathcal{FP}_t = \mathcal{FP}_t^1 \cup \mathcal{FP}_t^0$. Dado que la posición financiera de las empresas cambia con el tiempo, también lo hace el tamaño y la composición de estos dos grupos.

Para la interacción entre empresas y bancos en el mercado de crédito, utilizamos un mecanismo de correspondencia aleatoria (Delli Gatti *et al.*, 2010). En período inicial, la formación de los vínculos entre empresas y bancos es aleatoria. Luego, cada período las empresas con demanda de crédito positiva observan las tasas de interés de los bancos con los que ya tenían una línea abierta en el período anterior y, al mismo tiempo, solicitan información a otros n bancos. Estos n bancos se eligen al azar de entre aquellos que no tenían un vínculo previo con la empresa. De esta manera, una empresa $i \in \mathcal{FP}_t^1$ observa solo un grupo $\mathcal{Z}_{it} \subset \mathcal{Z}_t$ ³⁰. Los bancos $z \in \mathcal{Z}_t$ reciben

³⁰ \mathcal{Z} indica el conjunto de bancos y los subíndices i y t indican la empresa que los observa y el período, respectivamente.

las solicitudes de crédito de las empresas $i \in \mathcal{FP}_t^1$ y deciden si otorgan crédito o no, dependiendo de los fondos disponibles y el nivel de liquidez. Calculan e informan a las empresas las tasas de interés para los fondos solicitados.

Las empresas eligen pedir prestado a los bancos que ofrecen la tasa de interés más baja. Si el crédito disponible del banco que ofrece la tasa de interés más baja no es suficiente para cubrir la demanda de fondos de la empresa, la empresa utiliza el crédito parcialmente disponible y continúa con el siguiente banco de la lista, hasta que se cubra la cantidad total o se agote la lista de bancos. Para modelizar una relación de crédito estable, como la que se observa en la realidad, siguiendo a [Delli Gatti et al. \(2010\)](#) asumimos que la empresa cambia el banco con el que tenía un vínculo de crédito con una probabilidad ps . Esta probabilidad aumenta de manera no lineal con la diferencia entre la tasa de interés del banco anterior (r_o) y la tasa de interés establecida por el nuevo banco potencial observado (r_n), como indica la ecuación (2.11).

$$ps_i = \begin{cases} 1 - e^{\lambda \frac{r_n - r_o}{r_n}} & \text{if } r_o > r_n \\ 0 & \text{caso contrario} \end{cases} \quad (2.11)$$

ps_i , la probabilidad de que la empresa i cambie a un nuevo banco, toma valores positivos solo cuando uno de los bancos observados ofrece una tasa más baja que la ofrecida por el banco con el que ya tenía un vínculo de crédito. En caso de que $r_n < r_o$, la empresa i toma un número aleatorio de una distribución uniforme $\mathcal{U}(0, 1)$ y cambia de banco si este número está por debajo de ps_i . El parámetro λ afecta a la asimetría en el grado de distribución de bancos y en la distribución de crédito. Un valor más alto de λ implica una mayor propensión a cambiar de un banco a otro (basado en la tasa de interés más baja). Establecemos $\lambda = 1$ y luego realizamos un análisis de sensibilidad sobre este parámetro.

Hay un elemento adicional que influye en la formación de vínculos entre empresas y bancos y en la red de crédito. En el escenario en el que existen restricciones crediticias más estrictas como resultado de la preferencia de liquidez de los bancos (ver sección 2.2.3.1), los bancos podrían rechazar completamente el crédito solicitado. En este caso, la empresa pedirá al siguiente banco de la lista hasta encontrar un banco dispuesto a prestar y así cubrir sus necesidades financieras. Si la empresa solicita sin éxito a todos los bancos de su lista, deberá reducir su producción para cubrir los costos solo con recursos internos. Por lo tanto, la producción real diferirá de la producción deseada:

$$Y_{it}^d > Y_{it} = \frac{A_{it}}{w\phi_1}. \quad (2.12)$$

La introducción de estas restricciones incorpora un mecanismo que puede amplificar las dificultades financieras de la economía real. Una empresa con un alto apalancamiento o baja liquidez es probable que obtenga crédito solo de bancos que ofrecen las tasas de interés más altas entre los

observados. En el peor de los casos, nadie otorga crédito a la empresa, lo que la obliga a reducir su producción (y sus futuros beneficios).

En las simulaciones, las empresas observan al 10% de los bancos, pueden establecer vínculos de crédito con $MB = 2$ bancos cada período y el plazo máximo del crédito es de $H = 2$ períodos³¹. Existen dos mecanismos aleatorios que influyen en la evolución de la red: el componente aleatorio del precio al que se enfrentan las empresas (determina si una empresa pertenecerá a \mathcal{FP}_t^0 o a \mathcal{FP}_1^1) y la lista de n bancos que una empresa observa (que se elige al azar a partir del número total de bancos).

En resumen, la red de crédito se reestructura en cada período en función de: (i) cambios en el tamaño de los grupos de empresas autofinanciadas y no autofinanciadas; (ii) la composición del grupo de bancos observados por cada empresa no autofinanciada (que es aleatoria); (iii) la modificación de las condiciones financieras de los bancos y empresas, así como las expectativas de los bancos sobre la evolución futura de la economía, factores que determinan el crédito y la tasa de interés; y (iv) la formación de vínculos resultante³².

2.2.3 Bancos

El comportamiento de los bancos y cómo se conectan con las empresas es el principal interés del análisis en este trabajo. Los bancos otorgan crédito a las empresas para financiar su producción en caso de que no puedan ser financiadas completamente con sus propios fondos. No se modelizan las interacciones de crédito entre las empresas, por lo que toda la deuda que incurren es a través del crédito bancario (B). La contraparte está compuesta por las dos obligaciones de los bancos: capital y depósitos³³. Siguiendo la narrativa de Minsky, el modelo se basa en el enfoque del balance para modelizar la red de interacciones: los balances y los flujos de efectivo son fundamentales para comprender los vínculos entre las empresas y los bancos en un marco teórico de red.

Para nuestros fines, desarrollaremos dos escenarios diferentes y compararemos los diferentes resultados de cada uno. En el escenario base, los bancos establecen tasas de interés basadas en el apalancamiento de las empresas. Los bancos utilizan fondos para otorgar crédito y no hay racionamiento de crédito, excepto por problemas de liquidez de los bancos. Esto está en línea con el equilibrio entre la solvencia de los bancos y la reducción de los costos de los servicios financieros (Saunders y Schumacher, 2000).

En un segundo escenario, modelizamos la preferencia por la liquidez (Keynes, 1930, 1936) en los bancos (Dow y Dow, 1989; Lavoie, 2009; Minsky, 2016), ya sea por motivos especulativos

³¹Esto es consistente con lo que sucede en Argentina. Según las estadísticas presentadas por D'Erasmus *et al.* (2020), más del 90% de las empresas tienen relaciones crediticias con 1 o 2 bancos.

³²Para más detalles sobre la formación de la red de crédito, referimos a Noguera y Montes-Rojas (2022).

³³Dado que el análisis se centra en el comportamiento de los bancos y su interacción con las empresas productivas en el mercado crediticio, es posible asumir sin pérdida de generalidad que los bancos pueden obtener las cantidades necesarias de depósitos.

o para protegerse del riesgo. Los bancos tienen la posibilidad de invertir parte de sus fondos en un activo financiero dado, que es determinado exógenamente por el BC (también podría estar relacionado con un cambio exógeno en las preferencias de los bancos). El propósito es estudiar cómo la preferencia por la liquidez de estas instituciones financieras afecta tanto al sector financiero como al real, y la red de crédito generada. Este escenario tiene la intención de describir la economía argentina, un país en el que debido a las presiones inflacionarias y de devaluación (y también por la estabilidad macroeconómica), el BC utilizó bonos (específicos para bancos) para mantener la moneda local depositada y no cambiada a dólares estadounidenses (Hernán Zeolla y Médici, 2022). Como resultado, la intervención del BC resultó en la salida de fondos del circuito productivo.

En ambos escenarios, todos los bancos pagan la misma tasa de interés sobre los depósitos (r_{min}), pero cobran diferentes tasas de interés a las empresas. Siguiendo a Arslan *et al.* (2016), la tasa de interés específica para la empresa i establecida por el banco z en el período t , se indica en la ecuación (2.13).

$$r_{izt} = r_{mint} + \gamma CS_{zt}^{-\gamma} + \psi \frac{lev_{it}}{(1 + A_{it}/A_{t-1}^{max})^\psi} \quad (2.13)$$

donde:

1. r_{min} : es el valor mínimo de la tasa de interés fijada por los bancos. Se asume exógeno y corresponde a la tasa que los bancos cobran por los depósitos.
2. $\gamma CS_{zt}^{-\gamma}$: es el componente de la tasa de interés relacionado con variables específicas de los bancos. Específicamente, es una función de la relación de adecuación de capital: $CS_{zt} = \frac{A_{zt}}{B_{zt}}$, donde A_{zt} es el patrimonio neto del banco z en el período t , $B_{zt} = \sum_i B_{izt}$ es el monto total del crédito otorgado por el banco z y γ es un parámetro que mide la sensibilidad de la tasa de interés a cambios en el indicador de solidez financiera.
3. $\psi \frac{lev_{it}}{(1 + A_{it}/A_{t-1}^{max})^\psi}$: es el componente de la tasa de interés relacionado con variables específicas de las firmas. Se considera una función del apalancamiento $lev_{it} = \frac{B_{it}}{A_{it}}$ y el patrimonio neto con el parámetro ψ , donde A_{t-1}^{max} es el patrimonio neto de la empresa que alcanzó el valor máximo en el período anterior. Esto indica que cuanto mayor sea el apalancamiento de la empresa en relación a su tamaño (medido por el patrimonio neto en relación con el de mayor valor en el período anterior), mayor será el costo de financiamiento para la empresa.

Como consecuencia: (i) los bancos financieramente sólidos pueden otorgar crédito en mejores condiciones que otros bancos: reducen la tasa de interés y atraen a más empresas; y (ii) las empresas financieramente sólidas obtienen mejores condiciones de crédito: la tasa de interés cobrada por el prestamista incorpora una prima por financiamiento externo, que aumenta con el apalancamiento y, por lo tanto, está inversamente relacionada con el patrimonio neto del prestatario.

Los bancos tienen costos c , proporcionales a su tamaño. En caso de que un cliente del banco quiebre, el banco solo puede obtener una proporción RR (tasa de recuperación) de los préstamos vencidos. Por lo tanto, las ganancias del banco (Π_{zt}) se determinan como:

$$\Pi_{zt} = \sum_i r_{izt} B_{izt} - r_{mint} D_{zt} - c(A_{zt} + D_{zt}) - (1 - RR)bad_{zt} \quad (2.14)$$

donde r_{izt} es la tasa de interés que el banco z cobra a la empresa i (si no está en quiebra) sobre el crédito B_{izt} , r_{mint} es la tasa de interés de los depósitos, D_{zt} es la cantidad depositada en el banco z y bad_{zt} es la deuda incobrable del banco z .

Un banco puede otorgar préstamos con tasas de interés variables, por lo que en cualquier período, un banco y una empresa pueden tener múltiples vínculos de crédito con diferentes tasas. La cantidad de crédito ($cred$) que cada banco puede otorgar está limitada por un requisito de adecuación del capital (CS^*) establecido exógenamente:

$$cred_{zt} = A_{zt}/CS^* - B_{zt}. \quad (2.15)$$

2.2.3.1 Racionamiento crediticio debido a la preferencia por la liquidez

Para analizar el efecto del comportamiento de los bancos en la aparición de la inestabilidad financiera, proponemos un escenario en el que representamos la preferencia de los bancos por la liquidez. En general, esta preferencia se satisface mediante la adquisición de activos líquidos, pero no necesariamente dinero en efectivo. Según el trabajo seminal de Keynes (1930), los bancos tienen una relación deseada y relativamente estable entre reservas y pasivos a corto plazo. El aumento en la demanda de reservas responde a situaciones de incertidumbre o expectativas pesimistas sobre la evolución de la actividad económica.

Los bancos pueden invertir en un activo financiero F , cuyo plazo es de un período. Este activo está disponible con una probabilidad pa (la misma para todos los bancos) que sigue una distribución uniforme entre 0 y 1: $pa \sim \mathcal{U}[0; 1]$. Los bancos utilizarán la liquidez disponible para adquirir el activo financiero. F tiene un rendimiento dado igual a $\varrho = r_{min}$.

En este escenario, se produce un racionamiento como resultado de la preferencia de los bancos por la liquidez. Los bancos mantienen liquidez, ya sea en efectivo o en activos F , por lo que los beneficios siguen la ecuación (2.16).

$$\Pi_{zt} = \sum_i r_{izt} B_{izt} - r_{mint} D_{zt} - c(A_{zt} + D_{zt}) - (1 - RR)bad_{zt} + \varrho F_{zt}. \quad (2.16)$$

Los bancos tienen un objetivo de cobertura de liquidez que varía según sus expectativas sobre la evolución futura de la economía. En particular, desean mantener la proporción entre activos

líquidos (dinero y F) y flujos de efectivo netos esperados (LIQ) por encima de un umbral l (endógeno) que depende de la evolución reciente de la economía:

$$LIQ_{zt} \geq l_{zt}$$

$$\text{con } l_{zt} = \begin{cases} \bar{l} & \text{si } GR^e > 0 \\ \bar{l}(1 + \mathcal{U}[0; u_{max}]) & \text{si } GR^e \leq 0 \end{cases} \quad (2.17)$$

Donde GR_t^e es el crecimiento esperado por el banco z para el período y $LIQ_{zt} = \frac{LA_{zt}}{SE_{zt}}$. SE_{zt} es el flujo de efectivo neto esperado del banco z . Se calcula como el promedio ponderado de las obligaciones del banco (D_{zt}) ponderadas por la tasa de liquidación ζ_p , y los activos (F_{zt} y B_{zt}) ponderados por la tasa de incumplimiento ζ_a . Estas tasas son las mismas para todos los bancos y se supone que están definidas por la agencia reguladora (es decir, el comité de supervisión bancaria de Basilea) (BCBS, 2014). Formalmente:

$$SE_{zt} = O_{zt} + \zeta_p D_{zt} - (I_{zt} + \zeta_{aF} F_{zt} + \zeta_{aB} B_{zt})$$

donde O_{zt} e I_{zt} indican los flujos de efectivo contractuales actuales de salida y entrada del banco z .

2.2.3.2 Bancos con expectativas heterogéneas

En este segundo escenario, asumimos que los bancos siguen reglas de comportamiento o heurísticas para formar sus expectativas de crecimiento. El uso de reglas de comportamiento en la toma de decisiones que se dan bajo incertidumbre se encuentra ampliamente documentado en la literatura. Por ejemplo, Gigerenzer (2015) lo aplica a pronósticos de tasas de cambio realizados por bancos que utilizan una heurística adaptativa, mientras que Boneva *et al.* (2020) lo aplican a otras decisiones de gestión y económicas³⁴. Siguiendo la evidencia experimental proporcionada por Anufriev y Hommes (2012), modelizamos un mecanismo en el cual los bancos pueden elegir entre las siguientes especificaciones³⁵:

$$\begin{aligned} GR_t^{e1} &= GR_{t-1}^e + \epsilon_{ad}(GR_t - GR_{t-1}^e) \\ GR_t^{e2} &= GR_{t-1} + \epsilon_{tf1}(GR_{t-1} - GR_{t-2}) \\ GR_t^{e3} &= GR_{t-1} + \epsilon_{tf2}(GR_{t-1} - GR_{t-2}) \\ GR_t^{e4} &= \epsilon_{aa} \overline{GR}_{t-1} + (1 - \epsilon_{aa})GR_{t-1} + (GR_{t-1} - GR_{t-2}) \end{aligned} \quad (2.18)$$

³⁴Ver Dosi *et al.* (2018a) para una revisión más general sobre la racionalidad limitada.

³⁵En la sección 2.4 se presenta un análisis de los efectos que tiene sobre los principales resultados del modelo un cambio en la regla de formación de expectativas, en particular, hacia modelos predictivos más efectivos.

La primera regla representa expectativas adaptativas. La segunda y tercera incorporan dos reglas de seguimiento de tendencias (débil $0 < \epsilon_{tf1} < 1$ y fuerte $\epsilon_{tf2} > 1$). Finalmente, la última incluye un mecanismo de “anclaje y ajuste” con el promedio móvil de GR como anclaje. Los bancos cambian entre estas reglas en función de una función de aptitud, que se calcula utilizando el error entre los valores esperados y las realizaciones de las variables pronosticadas, como se detalla en [Anufriev y Hommes \(2012\)](#)³⁶.

Cuando el nivel de liquidez de z está por debajo del umbral l_{zt} , el banco raciona el crédito. Una vez que regresa al umbral de liquidez, la oferta de crédito toma valores positivos.

$$cred_{zt} = \begin{cases} A_{zt}/CS^* - B_{zt} & \text{si } LIQ_{zt} \geq l_{zt} \\ 0 & \text{si } LIQ_{zt} < l_{zt} \end{cases} \quad (2.19)$$

Como se mencionó, la configuración de la tasa de interés es la misma que en el escenario base.

En la siguiente sección, presentamos los resultados de las simulaciones para los dos escenarios descritos.

2.3 Simulaciones: dinámica macroeconómica y topología de la red de crédito

2.3.1 Configuración de las simulaciones

La economía está poblada por 500 empresas y 50 bancos. La simulación se ejecuta durante 1000 períodos. Presentamos los resultados para el intervalo 200-1000, ya que como es usual en la literatura, consideramos que el intervalo de tiempo entre 1-199 es un período de inicialización, por lo que puede contener algunos valores atípicos.

Inicialmente, el patrimonio neto de cada empresa es igual a 20 y el de cada banco es igual a 40. Cuando una empresa i entra en quiebra, es reemplazada por otra empresa con un patrimonio neto mucho menor en comparación con el de las empresas existentes. En particular, el patrimonio neto de la nueva empresa será un número aleatorio en una distribución uniforme entre 0 y 5 ($\mathcal{U}[0; 5]$). Del mismo modo, un nuevo banco entra con un patrimonio neto en una distribución $\mathcal{U}[20; 30]$. Este mecanismo puede interpretarse como una nueva entidad que asume la posición del banco que sale del mercado, incluyendo sus cuentas por cobrar.

La lista de parámetros, junto con sus valores, lo que representan y la referencia a la ecuación correspondiente, se presenta en el cuadro 2.1. Estimamos los parámetros con el fin de reproducir en los datos simulados algunas regularidades empíricas de las variables macroeconómicas en

³⁶Para ver otros trabajos donde se modelizan bancos con expectativas heterogéneas en contextos de Modelos Basados en Agentes se puede consultar, por ejemplo, [Kukacka y Barunik \(2017\)](#); [Anufriev et al. \(2019\)](#); [Assenza et al. \(2019\)](#); [Dosi et al. \(2020\)](#); [Schmitt y Westerhoff \(2021\)](#); [Reissl \(2021\)](#) y [Gusella \(2022\)](#).

Argentina, como la asimetría negativa³⁷ y la leptocurtosis³⁸ en la distribución de las tasas de crecimiento. El cuadro 2.12 muestra algunos indicadores macroeconómicos clave comparando los datos simulados con datos reales³⁹.

Para la estimación, aplicamos el método de inferencia indirecta (Gourieroux *et al.*, 1993; Gilli y Winker, 2003), un enfoque estándar desarrollado para la estimación de modelos basados en agentes a pequeña escala, caracterizados por tener un corto tiempo computacional, como es el caso del modelo trabajado en este capítulo. La inferencia indirecta permite estimar o realizar inferencias sobre los parámetros de un modelo mediante métodos de simulación. Siguiendo a Chen *et al.* (2012), el procedimiento se puede resumir de la siguiente manera. En primer lugar, se elige un vector de valores de parámetros para generar la serie temporal simulada ejecutando el modelo descrito en la sección 2.2 con el conjunto de valores de parámetros elegidos. Seleccionamos estos valores de los parámetros de acuerdo a los utilizados en Noguera y Montes-Rojas (2022), quienes calibraron el modelo a partir de un método de ajuste. Luego comparamos algunas estadísticas (momentos) de esta serie temporal simulada –es decir, los momentos simulados– con los obtenidos a partir de datos reales –es decir, los momentos muestrales–. La diferencia entre ambos se utiliza para formar una función de distancia, y el conjunto de parámetros seleccionado será aquel que minimice esta distancia. Las series de datos utilizadas fueron las correspondientes a la economía Argentina para el producto bruto interno obtenido del Instituto Nacional de Estadísticas y Censos (INDEC) y el crédito bancario al sector privado no financiero, provisto por el Banco de Pagos Internacionales (BPI). Todas las series tienen una frecuencia trimestral, para el período 2004-2018. Las características de las series que queremos reproducir se centran en la distribución de las tasas de crecimiento: su volatilidad (varianza), asimetría negativa y leptocurtosis.

Las simulaciones se centran en el mecanismo de configuración de la oferta de crédito, con el objetivo de analizar los efectos del comportamiento de los bancos con preferencia por la liquidez en las fluctuaciones económicas. La sección 2.3.2 presenta los resultados de las simulaciones y la sección 2.3.3 analiza la estructura de la red en ambos escenarios. Finalmente, los resultados del análisis de sensibilidad se encuentran en la sección 2.5.

2.3.2 Dinámica macroeconómica y quiebras

Como mencionamos anteriormente, la cantidad total de crédito que un banco puede otorgar está limitada por la relación de adecuación de capital, como se indica en la ecuación (2.15)⁴⁰. A su vez, la tasa de interés se determina como se indica en la ecuación (2.13): cuanto mayor sea

³⁷Que la distribución de la tasa de crecimiento está sesgada hacia la izquierda significa que hay más años con tasas de crecimiento negativas que con tasas de crecimiento positivas.

³⁸Que la distribución tenga colas más pesadas que una distribución normal significa que hay más años con tasas de crecimiento muy altas o muy bajas.

³⁹Esto no pretende ser un ejercicio de validación en datos empíricos porque el modelo no permite incorporar características esenciales de una economía del mundo real, como inversión en bienes de capital, inventarios, innovación y progreso tecnológico, dinámicas del mercado laboral y salariales, entre otros factores relevantes.

⁴⁰Aunque, según Basel II y III, los créditos se ponderan según el riesgo, en el modelo no hay diferenciación de riesgo entre activos, por lo que (por simplicidad) establecemos $CS = A/L$.

Cuadro 2.1: Valores de los parámetros.

Parámetro	Valor	Ecuación
ϕ_0	1	Función de producción de las firmas; ec. (2.2)
β	0.15	Función de producción de las firmas; ec. (2.2)
ϕ_1	1.2	Productividad laboral (inversa); ec. (2.1)
w	1	Salario; ec. (2.1)
α	10%	Ganancia bruta esperada firmas (precio); ec. (2.6)
σ^2	0.01	Varianza de g ; ec. (2.6)
θ	0.5	Proporción del capital que la firma puede mantener líquido; ec. (2.9)
liq_{max}	0.4	Umbral de liquidez relativa a la producción; ec. (2.10)
r_{min}	2%	Piso de la tasa de interés; eq. (2.13)
γ	0.01	Parámetro (banco) en la fijación de tasa de interés; ec. (2.13)
ψ	0.03	Parámetro (firma) en la fijación de tasa de interés; ec. (2.13)
RR	50%	Tasa de recuperación de fondos en caso de quiebra de una firma; ec. (2.14)
c	0.5%	Costos operativos de los bancos; eq. (2.14)
CS^*	12%	Requisito de adecuación del capital bancos; ec. (2.15)
l_z	0.6	Umbral mínimo de liquidez; ec. (2.17)
ϵ_{ad}	0.65	Expectativas; ec. (2.18)
ϵ_{tf1}	0.4	Expectativas; ec. (2.18)
ϵ_{tf2}	1.3	Expectativas; ec. (2.18)
ϵ_{aa}	0.5	Expectativas; ec. (2.18)
MB	2	Máximo número de bancos con los que una firma puede tener crédito
n	10%	Proporción de bancos que observan las firmas cada período
H	2	Plazo máximo del crédito

la relación entre el apalancamiento y el patrimonio neto de la empresa, mayor será la tasa de interés que cobra el banco. Como se describe en la Sección 2.2.3, la diferencia central entre los dos escenarios es la provisión de crédito.

Los cuadros 2.2 y 2.3 muestran los resultados de las simulaciones correspondientes a los períodos 200-1000. Los resultados presentados son consistentes con lo que encontraron Delli Gatti *et al.* (2010), Riccetti *et al.* (2013) y Riccetti *et al.* (2016b): shocks idiosincráticos conducen a fluctuaciones macroeconómicas que aumentan la fragilidad financiera de los agentes. Los bancos con un patrimonio neto más alto –y, por lo tanto, con una mayor relación de adecuación de capital– pueden establecer tasas de interés más bajas y, por lo tanto, aumentar su cuota de mercado⁴¹. En cuanto a las empresas, el mecanismo es similar: aquellas con una posición financiera más sólida se benefician de tasas de interés más bajas, realizan inversiones (proyectos que no eran rentables a tasas más altas) y, por lo tanto, contribuyen al crecimiento. Sin embargo, si una empresa quiebra, esto afecta la posición financiera de los bancos, que pueden quebrar o aumentar las tasas de interés si permanecen en pie en reacción a la pérdida de patrimonio. Esta reacción de los bancos genera dificultades financieras para los clientes de los bancos, causando nuevas pérdidas y quiebras.

Las figuras 2.1.a, 2.1.b y 2.1.c muestran la evolución de la producción agregada y la tasa de

⁴¹Como ocurrió con los bancos extranjeros que comenzaron a operar en algunos países de América Latina en la década de 1990, particularmente en Argentina, véase por ejemplo, Martínez Peria y Mody (2004)

Cuadro 2.2: Resultados variables económicas, escenario base. Períodos 200-1000.

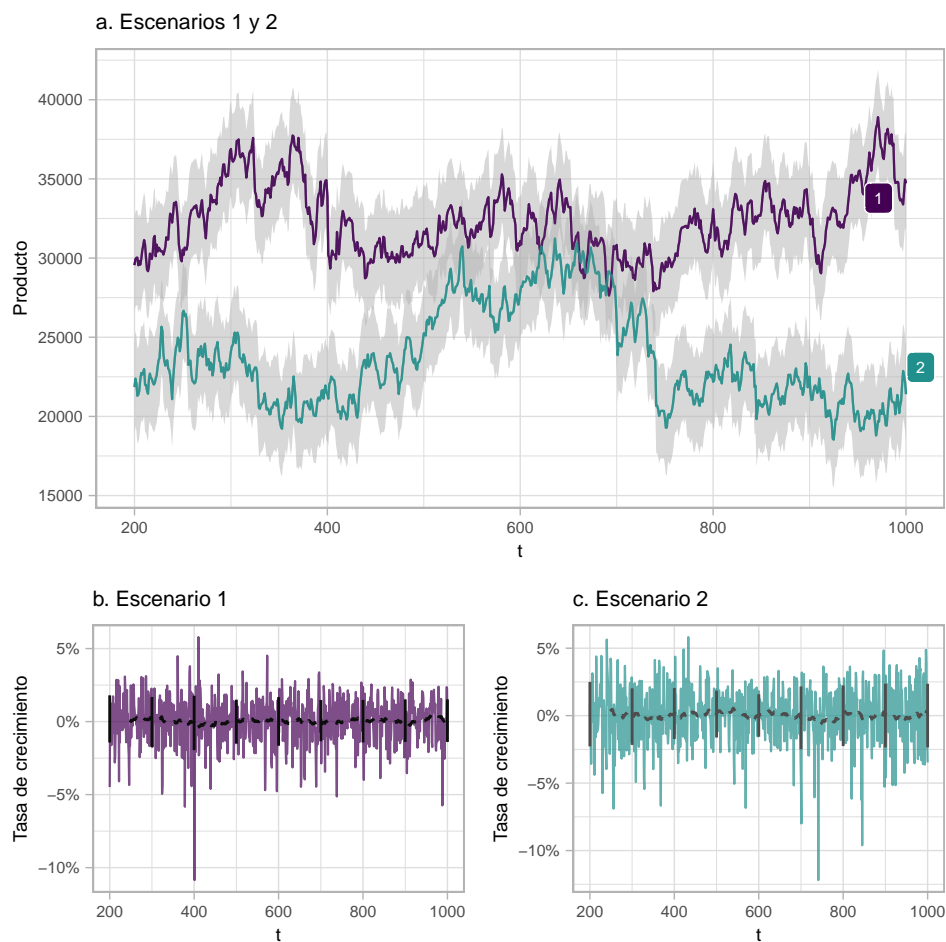
Variable	Media	Desvío	Mín.	Máx.	Asimetría	Curtosis
Deuda incobrable (%)	8.57	3.31	1.56	20.84	0.52	0.35
Quiebra bancos	0.30	0.62	0.00	5.00	2.79	11.05
Patrimonio neto bancos	33,416.47	19,180.58	3,085.83	91,147.50	0.70	0.00
Deuda	10,387.52	1,319.93	7,287.36	14,380.64	0.48	0.35
Quiebra firmas	27.15	4.82	12.00	40.00	0.12	-0.38
Patrimonio neto firmas	29,775.33	22,059.20	10,833.68	84,720.00	1.40	0.39
Producto	32,362.15	2,177.42	27,629.60	38,905.70	0.52	-0.18
Tasa de interés (%)	5.99	0.02	5.95	6.05	0.10	-0.63
Apalancamiento	0.77	0.26	0.26	1.24	-0.56	-0.77
Quiebra bancos (%)	0.60	1.25	0.00	10.00	2.79	11.05
Quiebra firmas (%)	5.43	0.96	2.40	8.00	0.12	-0.38
Tasa de crecimiento (%)	4.40	1.32	-9.85	6.99	-0.27	3.22

Cuadro 2.3: Resultados variables económicas, escenario con preferencia por la liquidez (bancos). Períodos 200-1000.

Variable	Media	Desvío	Mín.	Máx.	Asimetría	Curtosis
Deuda incobrable (%)	9.98	4.21	2.64	58.68	3.26	27.47
Quiebra bancos	0.13	0.41	0.00	4.00	4.32	25.46
Patrimonio neto bancos	27,818.36	24,017.67	3,002.62	91,796.90	0.88	-0.45
Deuda	5,750.79	1,335.16	3,843.81	9,913.38	0.83	-0.35
Quiebra firmas	29.86	5.61	10.00	48.00	-0.19	0.13
Patrimonio neto firmas	23,799.05	12,309.79	10,861.90	50,982.70	0.92	-0.59
Producto	23,666.37	3,088.96	18,479.70	31,189.00	0.65	-0.71
Tasa de interés (%)	6.40	0.02	6.35	6.45	0.03	-0.77
Apalancamiento	1.05	0.30	0.47	1.60	-0.21	-1.30
Quiebra bancos (%)	0.26	0.81	0.00	8.00	3.21	11.42
Quiebra firmas (%)	5.97	1.12	2.00	9.60	0.09	0.51
Tasa de crecimiento (%)	1.97	1.99	-11.45	5.29	-0.33	2.17

crecimiento, respectivamente, para ambos escenarios. En ambos casos, podemos observar patrones de fluctuaciones irregulares que muestran diferencias significativas entre diferentes subperíodos. Esto se debe tanto a la exogeneidad de los precios como a la estructura adaptativa y compleja del sistema (Delli Gatti *et al.*, 2010). En el escenario base, la desviación estándar de la distribución de la tasa de crecimiento es del 1,32%, está sesgada hacia la izquierda (coeficiente de sesgo -0,27) y es leptocúrtica (curtosis 3,22). En el escenario que reproduce un comportamiento de preferencia por la liquidez por parte de los bancos, tanto el producto como la tasa de crecimiento son, en promedio, más bajos que en el escenario base y muestran un mayor grado de volatilidad.

Figura 2.1: Producto y tasa de crecimiento. Escenarios 1 y 2. Períodos 200-1000.

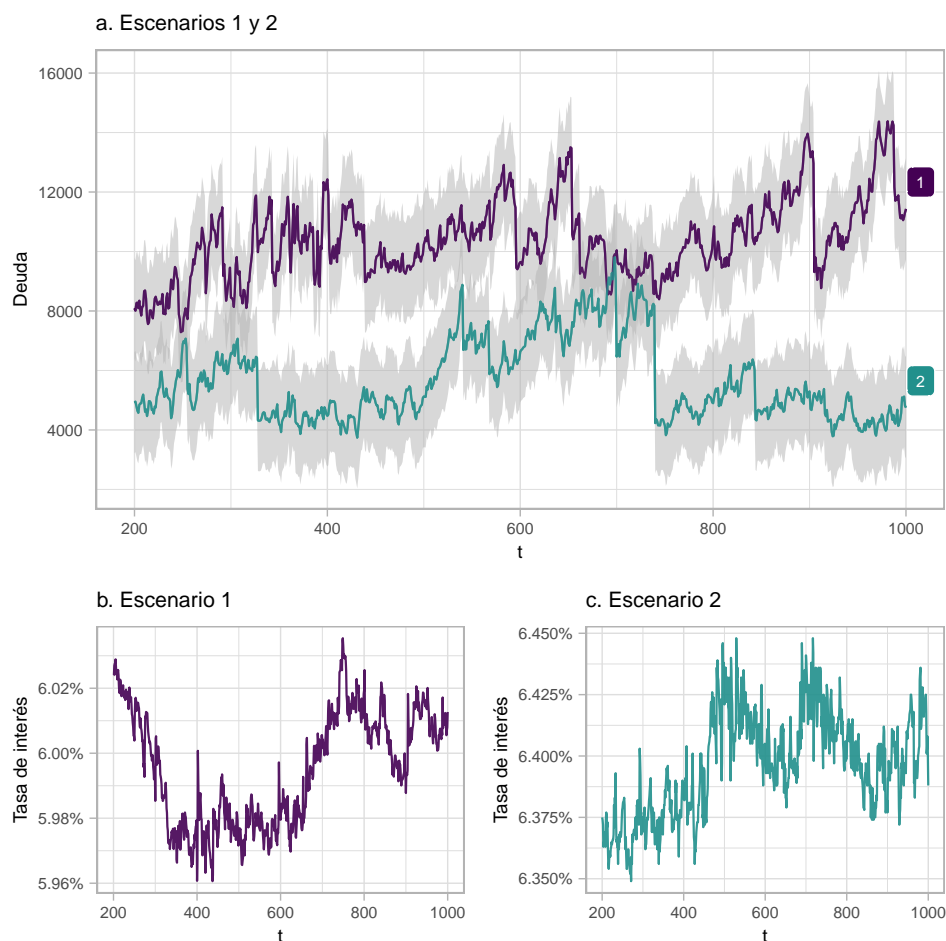


La figura 2.2.a muestra que la dinámica de la deuda total exhibe un comportamiento similar al de la producción agregada. La correlación de la deuda (con un rezago de un período) con la producción es positiva, lo cual concuerda con la dinámica descrita por Minsky (1986; 2016). Si las empresas encuentran bancos que las financien, pueden aumentar la producción y, por lo tanto, una deuda más alta implica una mayor producción en tiempos de crecimiento. Pero esto amplifica el efecto de un shock negativo en el precio del bien que las empresas venden. En el escenario base, la relación deuda/PIB tiene un promedio del 30,5%. La proporción de deuda incobrable alcanza un valor promedio del 8,57% y un máximo del 20,84%. En el escenario alternativo, la deuda total se reduce, especialmente como consecuencia de las restricciones de los bancos para otorgar crédito.

Aunque la correlación con la producción es positiva, al igual que en el escenario base, la relación deuda/PIB desciende en promedio al 24%. La proporción media de deuda impaga aumenta de 8,6 a 10 (ver cuadros 2.2 y 2.3). Esto implica que las restricciones en la oferta de crédito pueden amplificar las dificultades financieras de las empresas. Si ningún banco está dispuesto a prestar a una empresa, esta se ve obligada a reducir su producción y sus ganancias futuras, lo que dificulta aún más su capacidad para enfrentar la deuda en el futuro.

En cuanto al apalancamiento de las empresas, en el escenario base tiene una media de 0,77 y una desviación estándar de 0,26. El valor máximo observado es 1,24, que coincide temporalmente con uno de los valores más bajos del producto y el patrimonio neto de las empresas. Debido a que los precios se establecen de manera exógena, exhibe una alta volatilidad. En el escenario en el que los bancos tienen preferencia por la liquidez, el apalancamiento de las empresas es mayor que el observado en el escenario base (ver cuadros 2.2 y 2.3). Aunque la deuda es menor, también lo es el patrimonio neto de las empresas, lo que se refleja en el menor nivel de producción.

Figura 2.2: Deuda y tasa de interés, escenarios 1 y 2. Períodos 200-1000.



En los primeros períodos, la tasa de interés muestra una tendencia a la baja (ver figura 2.2.b). Esto es una consecuencia del crecimiento sostenido y los bajos niveles de apalancamiento de las empresas. Luego, muestra una tendencia al alza, que se explica centralmente por el aumento del

apalancamiento de las empresas y la disminución del patrimonio neto de los bancos (causada por el crecimiento de la proporción de deuda incobrable). Los valores fluctúan con una media del 6% y una desviación estándar del 0,02%. En el escenario alternativo, no hay cambios significativos en la tasa de interés promedio (ver figura 2.2.b y 2.2.c). Es más alta en comparación con el escenario base. Hay dos factores que la afectan: un efecto positivo debido al mayor apalancamiento en relación con el patrimonio neto de las empresas y un efecto negativo debido a una mayor proporción de adecuación de capital de los bancos. Se mantiene en un rango entre el 6,3% y el 6,4%, exhibe una mayor volatilidad en comparación con el escenario anterior y está correlacionada con el apalancamiento de las empresas.

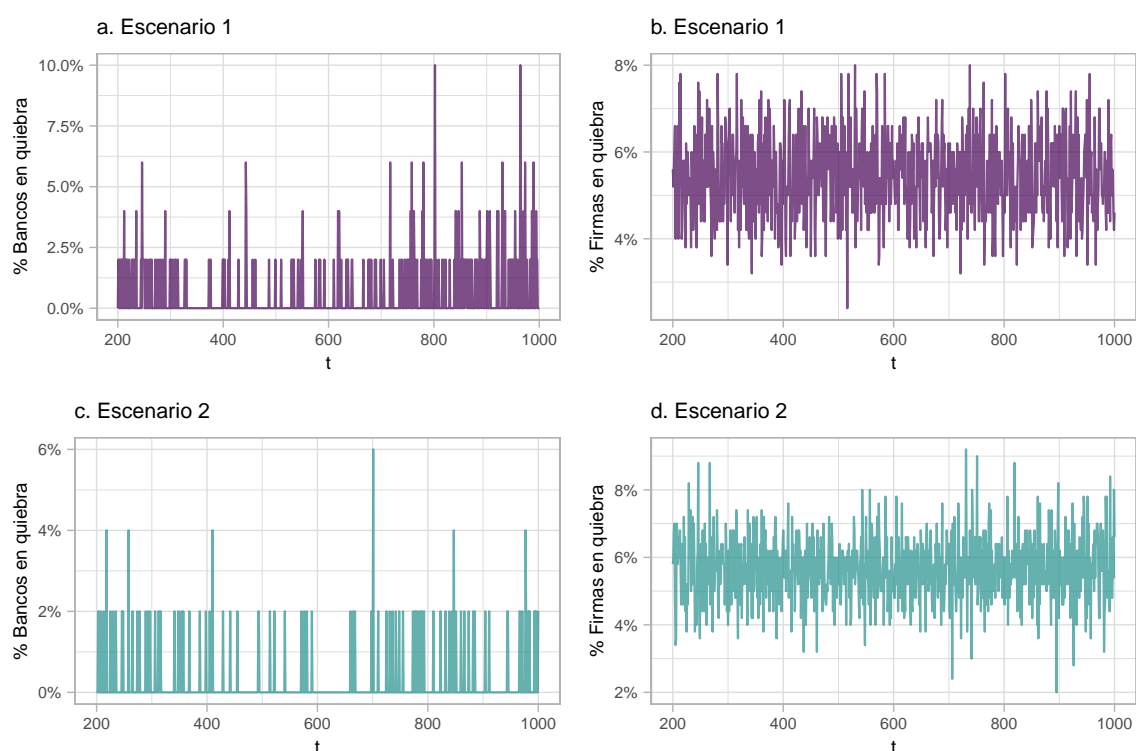
Por construcción, los bancos solo pueden quebrar como consecuencia del contagio, es decir, el impago de las empresas a las que prestaron. En otras palabras, los bancos no pueden salir del mercado sin deuda incobrable causada por la quiebra de uno o más prestatarios. Por el contrario, para las empresas podemos distinguir las dificultades que surgen del mercado (en el modelo, causadas por shocks negativos en la demanda) de las dificultades resultantes de la propagación. En el primer caso, la quiebra se produce como consecuencia de pérdidas, independientemente del diferencial de prima de riesgo cobrado por los bancos. Entonces, en este caso, las empresas salen del mercado debido al efecto de una variable exógena: el shock de demanda. En el caso de las dificultades por propagación, la quiebra se produce como consecuencia del aumento de la tasa de interés, que es una variable endógena determinada por las conexiones de crédito: (i) la situación financiera de la empresa depende no solo del shock de demanda, sino también del diferencial cobrado en el pasado por los bancos; (ii) la condición financiera del propio banco depende de la solidez financiera del resto de los bancos prestatarios. Por lo tanto, estas dificultades están determinadas endógenamente por la quiebra pasada de otras empresas prestatarias del mismo banco, es decir, conexiones de crédito.

Observamos que el porcentaje promedio de quiebras de empresas en cada período es del 5,43% (27 empresas), con un máximo del 8% (40 empresas) y un mínimo del 2,4% (12 empresas). El número promedio de quiebras debido a la propagación en cada período es de 2,6. Por lo tanto, la proporción de incumplimientos producidos por contagio es del 9,6%. En el escenario en el que los bancos muestran una preferencia por la liquidez, la proporción de empresas que quiebran es, en promedio, mayor que en el escenario de referencia, mientras que el patrimonio neto se reduce.

En cuanto a los bancos, observamos un patrón estable. La quiebra alcanza un máximo de 5 (10%) y un promedio cercano a 0. Las figuras 2.3.a y 2.3.c muestran que la proporción de bancos que quiebran se reduce en relación con el escenario de referencia. El promedio pasa de 0,38% a 0,26%. Este resultado explica en parte el comportamiento de los bancos de preferencia por la liquidez: los activos líquidos permiten a los bancos hacer frente a situaciones de incumplimiento eventual en un contexto incierto. Aunque el patrimonio neto de los bancos es menor que en el escenario base, en este escenario es superior al patrimonio neto de las empresas.

En resumen, las simulaciones muestran que cuando los bancos conservan liquidez y restringen la

Figura 2.3: Quiebra de bancos y firmas, escenarios 1 y 2. En porcentajes, períodos 200-1000.



disponibilidad de fondos para financiar proyectos productivos, la inestabilidad en el sector real puede aumentar.

2.3.3 Topología de la red de crédito

Consideramos tres características para analizar la estructura de la red de crédito emergente: (i) la distribución del grado de los bancos, (ii) la distribución de los créditos prestados por los bancos y (iii) la distribución de los créditos otorgados a las empresas.

La estructura de la red de crédito permanece relativamente estable a lo largo de los períodos en ambos escenarios. La distribución del grado de la red de crédito tiende a una ley de potencia, es decir, el modelo reproduce una estructura de red específica llamada “libre de escala” (consulte, por ejemplo, [Clauset *et al.*, 2009](#), para obtener más información). Por lo tanto, la probabilidad $p(k)$ de que un nodo en la red esté conectado a k nodos es proporcional a $k^{-\alpha}$. En otras palabras, la distribución del grado sigue una ley de potencia, un patrón que tiene implicaciones para la estructura y dinámica de los sistemas complejos. En particular, hay un pequeño grupo de nodos que están altamente conectados mientras que el grado promedio de conexión es bastante bajo. Valores más bajos de α indican una red más concentrada (para este punto, se puede ver, entre otros, [Barabási y Albert, 1999](#)).

El número de enlaces para cada banco se vuelve asimétrico con el tiempo como consecuencia del mecanismo de interacción en el mercado de crédito. Los prestamistas financieramente sólidos

Cuadro 2.4: Valores medio, mínimo y máximo de α . Escenarios 1 y 2, períodos 200-1000.

α	Escenario 1			Escenario 2		
	Media	Máximo	Mínimo	Media	Máximo	Mínimo
Grados bancos	2.86	3.17	2.41	1.79	1.99	1.24
Creditos otorgados bancos	2.03	2.39	1.31	1.41	1.86	1.06
Creditos recibidos firmas	1.92	2.49	1.26	1.82	2.17	1.21

pueden ofrecer mejores condiciones de crédito y aumentar su participación en el mercado. Lo contrario es cierto para los agentes financieramente frágiles. Como resultado, los sectores real y financiero se polarizan y la distribución del grado se vuelve asimétrica. Más específicamente, la distribución del crédito prestado por los bancos resulta ser más sesgada que la distribución del grado de los bancos, pero menos sesgada que la distribución de la deuda de las empresas. Por lo tanto, observamos un mercado crediticio concentrado alrededor de los bancos más grandes. Esta concentración aumenta en el escenario en el que los bancos restringen el crédito como consecuencia de las preferencias de liquidez. En este escenario, hay una mayor proporción de empresas que se autofinancian en comparación con el escenario de referencia.

El cuadro 2.4 muestra estadísticas descriptivas del exponente α de la ley de potencia $p(k) \propto k^{-\alpha}$ ajustada en la cola derecha de las distribuciones simuladas para ambos escenarios. La distribución del grado de los bancos y la distribución del crédito otorgado tienen un valor α más bajo en el escenario alternativo.

Realizamos un análisis de sensibilidad del parámetro λ , que es fundamental para determinar la estructura de la red de crédito. La ecuación (2.11) desempeña un papel clave en la formación de los enlaces de crédito y en la estructura de la red. El parámetro λ es importante porque determina la propensión de una empresa a cambiar de un prestamista a otro, dependiendo de cuál ofrezca mejores condiciones de crédito. Por lo tanto, un valor de λ más alto implica una mayor probabilidad de que las empresas cambien de banco con el que tienen una relación crediticia, mientras que un valor de λ más bajo reduce esta probabilidad. Por lo tanto, los cambios en el valor de este parámetro modificarán la estructura de la red de crédito simulada.

Anteriormente establecimos $\lambda = 1$. En el análisis de sensibilidad encontramos que todas las características del ciclo económico observadas en la simulación de referencia se mantienen cuando modificamos λ . Los cambios en este parámetro no tienen efectos significativos en la distribución de la deuda de las empresas. Esto se explica por el hecho de que la demanda de crédito de las empresas está determinada por mecanismos económicos independientes de λ en la formación de la red de crédito (consulte el cuadro 2.5). Lo contrario sucede con la topología de la red bancaria, ya que exhibe cambios significativos a medida que cambia este parámetro. Cuando λ pasa de 1 a 4, el mecanismo previamente explicado –que da lugar a la distribución sesgada a la derecha del grado de los bancos– se profundiza y el exponente α disminuye. Por lo tanto, el crédito otorgado por los bancos también muestra un sesgo positivo creciente y un α decreciente en el valor de λ . En otras palabras, a medida que aumenta la propensión de las empresas a cambiar de banco, la


Cuadro 2.5: Media de α para diferentes valores de λ . Escenarios 1 y 2, períodos 200-1000.

λ	0.5	1	2	3	4	6	10	16
α Grados bancos	2.91	2.86	2.39	2.06	1.78	1.71	1.70	1.72
α Créditos otorgados bancos	2.10	2.03	1.67	1.42	1.25	1.23	1.25	1.29
α Créditos recibidos firmas	1.94	1.92	1.90	1.89	1.87	1.86	1.88	1.90

concentración del mercado crediticio crece hacia los bancos más grandes, es decir, aquellos que pueden ofrecer mejores condiciones de crédito.

El análisis de sensibilidad muestra que λ tiene un impacto económico porque está relacionado positivamente con el número de bancarrotas en el sector financiero. En particular, este número aumenta considerablemente para valores de λ de 1 a 10 (consulte la Figura 2.4). Un banco con deuda morosa aumenta su tasa de interés y, por lo tanto, sus deudores cambiarán a otros bancos financieramente sólidos que cobran tasas de interés más bajas. Luego, el banco que recibe el shock negativo inicial termina con un número reducido de clientes y, en consecuencia, con una cartera de préstamos menos diversificada. Esta situación lleva al banco en cuestión a una mayor probabilidad de quiebra. En este contexto, las dificultades bancarias son tanto una causa como un efecto del aumento de la concentración del mercado.

Figura 2.4: Porcentaje promedio de bancos en quiebra según valor de λ , períodos 200-1000. Escenario base.



2.4 Efectos de cambios en la regla de formación de expectativas de los bancos

En esta sección realizamos un experimento para evaluar cómo afecta al desempeño individual y macroeconómico –en términos de los resultados principales del modelo– incluir diferentes grados

de sofisticación en las reglas de comportamiento de los bancos. En particular, analizamos los efectos de introducir en el modelo bancos que sean capaces de formular pronósticos de crecimiento más efectivos, lo cual es un elemento determinante de la oferta de crédito. Comparamos los errores de pronóstico a los que incurren los bancos mediante tres formas diferentes de modelizar las reglas de formación de expectativas: (1) expectativas adaptativas; (2) expectativas con reglas heterogéneas (ecuación (2.18)) y (3) un modelo autorregresivo.

Respecto a las expectativas con reglas heterogéneas, cabe mencionar aquí que en esta forma de modelizar el comportamiento de formación de expectativas –seguida en el análisis realizado en la sección 2.3–, los bancos cambian entre diferentes heurísticas y tienden a preferir una mezcla entre las reglas de seguimiento de tendencias fuertes y débiles, con el uso ocasional de las reglas adaptativa y de “ancla y ajuste”⁴². En este sentido, no parece surgir una estrategia de pronóstico dominante en particular.

El caso de expectativas adaptativas, coincide con la primera regla por la que pueden optar los bancos bajo la especificación de la formación de expectativas descrita en la ecuación (2.18). Es decir, para realizar sus predicciones los bancos miran centralmente el crecimiento en el período anterior, pero corrigen esta estimación a partir del error incurrido en la predicción pasada.

Las expectativas que siguen un Modelo Autoregresivo (AR) consideran un conjunto de tres variables: (1) crecimiento agregado en el pasado; (2) deuda agregada y (3) tasa de interés promedio de la economía. Utilizamos este conjunto de tres variables porque después de varios intentos es el conjunto más pequeño de variables que permite al modelo autoregresivo formular expectativas no sesgadas.

Las salidas se traducen en una predicción más simple del signo de la tasa de crecimiento, que es la información relevante para los bancos al momento de tomar decisiones asociadas al racionamiento de crédito, de acuerdo a la ecuación (2.17). Para aumentar la precisión del modelo autoregresivo, que depende del volumen de datos que pueden procesar, los nuevos bancos que ingresan heredan datos procesados por un banco ya establecido elegido aleatoriamente.

A continuación proporcionamos los resultados sobre el rendimiento de diferentes reglas de pronóstico o formación de expectativas y los efectos sobre los principales resultados del modelo.


Para evaluar el rendimiento en la predicción del crecimiento de los modelos de expectativas, computamos el error cuadrático medio (ECM), que está dado por la diferencia cuadrática promedio entre el valor predicho y el valor efectivo del indicador que los bancos buscan pronosticar:

$$ECM = \frac{\sum_z (GR_{zt} - GR_{zt-1}^e)^2}{Z}$$

⁴²Ver Coibion *et al.* (2018) para revisar evidencia empírica que respalda la heterogeneidad de creencias entre empresas (no específicamente en el sector bancario).

En primer lugar, se destaca que el modelo autorregresivo es capaz de proporcionar predicciones imparciales y presenta un cierto grado de precisión. Asimismo, como se puede observar en la figura 2.5, el pronóstico de los bancos es menos sesgado en este modelo, centralmente respecto a la regla (1); es decir, los bancos tienden a cometer errores más pequeños. En el caso del modelo autorregresivo sigue una tendencia decreciente: de acuerdo con Evans y Honkapohja (2001) este algoritmo de aprendizaje cae en la categoría de ganancias decrecientes, lo que significa que el cambio de un período a otro en los parámetros estimados tiende a disminuir a medida que se acumulan más datos. Aunque es menos preciso, también se observa una mejora respecto de la regla (1) en la predicción de los bancos al seguir la heurística de cambio de regla; es decir, las expectativas con reglas heterogéneas.

Figura 2.5: Error cuadrático medio en el pronóstico de crecimiento de los bancos. Expectativas adaptativas (EA), expectativas con reglas heterogéneas (EH) y modelo autorregresivo (AR).



Si bien en el caso de los modelos (2) y (3) se observa una mejora clara en términos de los errores de pronóstico en comparación con las expectativas adaptativas, que miran la realización de la variable de interés en el período previo y corrijen por el error incurrido en el último pronóstico realizado, estas últimas por sí solas resultan ser una heurística de pronóstico bastante decente sobre la cual las heurísticas alternativas no realizan cambios suficientes como para alterar significativamente la dinámica del modelo (cuadro 2.6). Una evaluación de los resultados de las simulaciones muestra que esto conduce a un ligero aumento en el nivel promedio del patrimonio neto de los bancos y una disminución en su volatilidad, así como una disminución en la incidencia de la restricción de crédito a medida que los bancos cometen errores más pequeños al pronosticar correctamente la evolución del crecimiento. De esta manera, se observa una leve disminución en la deuda total promedio contraída por las firmas. Finalmente, respecto al producto y al patrimonio de las firmas, la formación de expectativas con menos sesgos tiene un efecto procíclico y se observa un ligero incremento en la volatilidad de estas variables.

Cuadro 2.6: Media y desvío, resultados bajos diferentes reglas de formación de expectativas. Períodos 200-1000.

Variable	Expectativas adaptativas		Reglas heterogéneas		Modelo autoregresivo	
	Media	Desvío	Media	Desvío	Media	Desvío
Deuda incobrable (%)	10.18	4.42	9.98	4.21	8.98	3.79
Patrimonio neto bancos	25592.89	24041.69	27818.36	24017.67	29904.74	15611.49
Deuda	5837.05	1375.21	5750.79	1335.16	5635.77	1308.46
Patrimonio neto firmas	24037.04	12186.69	23799.05	12309.79	22847.09	12925.28
Producto	22009.72	3336.08	23666.37	3088.96	22719.72	3243.41
Tasa de interés (%)	6.66	0.02	6.40	0.02	6.50	0.02
Apalancamiento	1.06	0.32	1.05	0.30	1.17	0.33
Quiebra bancos (%)	0.26	0.82	0.26	0.81	0.22	0.67
Quiebra firmas (%)	6.27	1.19	5.97	1.12	6.15	1.16
Tasa de crecimiento (%)	1.87	1.96	1.97	1.99	1.93	1.98

No obstante, vale mencionar que estas diferencias no son lo suficientemente grandes como para producir una dinámica significativamente diferente en el modelo, ya que a pesar de la diferencia entre los errores observados en la figura 2.5, los errores de pronóstico de los bancos ya son bastante pequeños bajo expectativas de reglas heterogéneas.

2.5 Análisis de sensibilidad

Realizamos un análisis de sensibilidad para evaluar en qué medida los resultados de la simulación dependen de los valores especificados para los parámetros y, en el caso del segundo escenario, el efecto de cambiar los parámetros de la regla de expectativas y el rendimiento del activo financiero. En primer lugar, realizamos simulaciones del escenario de referencia cambiando el valor de un parámetro a la vez para analizar cómo se modifican los resultados. Luego, realizamos simulaciones del escenario alternativo modificando los valores de los parámetros de la regla de expectativas, –es decir, ϵ_j , $j = ad, tf1, tf2, aa-$ y de ρ . A continuación, describimos los resultados más relevantes.

2.5.1 Escenario base

Para evaluar la sensibilidad de los resultados a los cambios en los parámetros de decisión de producción de las empresas, ϕ_0 , ϕ_1 y β en las ecuaciones (2.1) y (2.2), modificamos el valor de ϕ_0 en el intervalo $[0.6; 3]$, β en $[0.1; 0.7]$, y ϕ_1 en $[1; 2]$, con cambios discretos de 0.2 en todos los casos. En términos generales, observamos resultados similares en estos experimentos. Un aumento en la productividad (representada por estos parámetros) tiene efectos positivos en la economía, tanto en términos de producción como de estabilidad financiera. Se observa un mayor crecimiento promedio, una disminución en la quiebra promedio de empresas y bancos, una disminución en la tasa de interés promedio y una disminución en el apalancamiento.

Respecto a los bancos, destacamos los siguientes resultados relacionados a la sensibilidad del modelo frente a cambios en los parámetros relevantes en la determinación de la oferta y el costo del crédito. En primer lugar, consideramos el parámetro r_{min} , que representa un límite inferior o “piso” en la tasa de interés del crédito. Lo modificamos desde 0.01 hasta 0.1 en cambios discretos de 0.01. A medida que r_{min} aumenta, la desviación estándar de la tasa de crecimiento disminuye. Además, la probabilidad de quiebra bancaria disminuye a medida que aumenta r_{min} .

Por su parte, el parámetro γ representa cuán importante es el componente específico de la situación financiera de los bancos (en particular, el ratio de adecuación de capital) en la determinación de la tasa de interés. Lo modificamos en el intervalo $[0.005; 0.05]$ en saltos de 0.005. Los aumentos en γ tienen un efecto positivo en la proporción promedio de deuda incobrable, la deuda total y la probabilidad de quiebra bancaria.

El último parámetro relevante en la determinación de la tasa de interés es ψ , que representa la importancia de las características específicas de las empresas. Lo modificamos entre 0.005 y 0.05 en saltos discretos de 0.005. A medida que ψ aumenta, la desviación estándar de la tasa de crecimiento disminuye y tanto la deuda total como la proporción de bancos en quiebra disminuyen.

Finalmente, modificamos el valor del requisito de adecuación de capital CS^* , inicialmente establecido en 12%. Lo modificamos en el intervalo $[0.04; 0.22]$ aumentando en 0.02 cada vez. A medida que CS^* aumenta, la tasa de crecimiento promedio disminuye y la desviación estándar exhibe un comportamiento cuadrático. Además, aumentos en el requisito de adecuación de capital reducen la inestabilidad financiera.

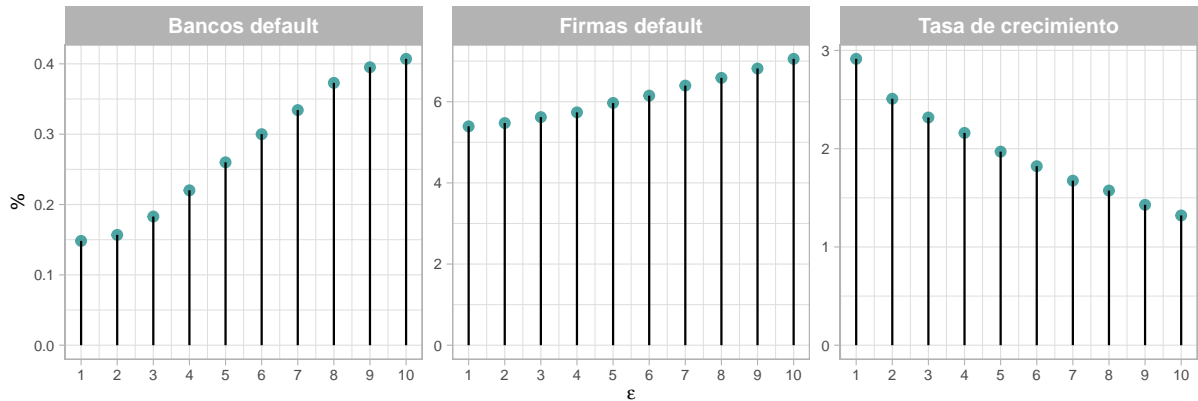
2.5.2 Escenario de preferencia por la liquidez

Realizamos una evaluación de sensibilidad cambiando el parámetro ϵ en la regla de formación de expectativas para evaluar el efecto de los errores de pronóstico de los bancos en la dinámica macroeconómica y las quiebras. Dado que los bancos siguen un enfoque heurístico, modificamos todos los parámetros en la regla de formación de expectativas, en saltos discretos de 0.05. Específicamente, ϵ_{ad} en el rango $[0.45; 0.9]$, ϵ_{tf1} en el rango $[0.25; 0.65]$, ϵ_{tf2} en el rango $[1.15; 1.55]$ y ϵ_{aa} en el rango $[0.3; 0.75]$.

Estos cambios tienen un ligero efecto en la volatilidad macroeconómica y conducen a un mayor número de quiebras tanto en el sector corporativo como en el bancario (ver figura 2.6). Un valor mayor (menor) de ϵ tiende a aumentar (disminuir) las fluctuaciones a medida que las expectativas que influyen en la determinación de las variables de decisión de los bancos se vuelven más (menos) sensibles a los errores de pronóstico.

Analizamos también la sensibilidad de los resultados principales del modelo frente a cambios en el valor del parámetro ρ , que representa el rendimiento del activo financiero que los bancos pueden adquirir. Modificamos su valor en saltos discretos de 0.02 dentro del intervalo $[0.02; 0.5]$ y

Figura 2.6: Sensibilidad ante cambios en el valor de ϵ . Tasa de crecimiento, firmas en default y bancos en default.

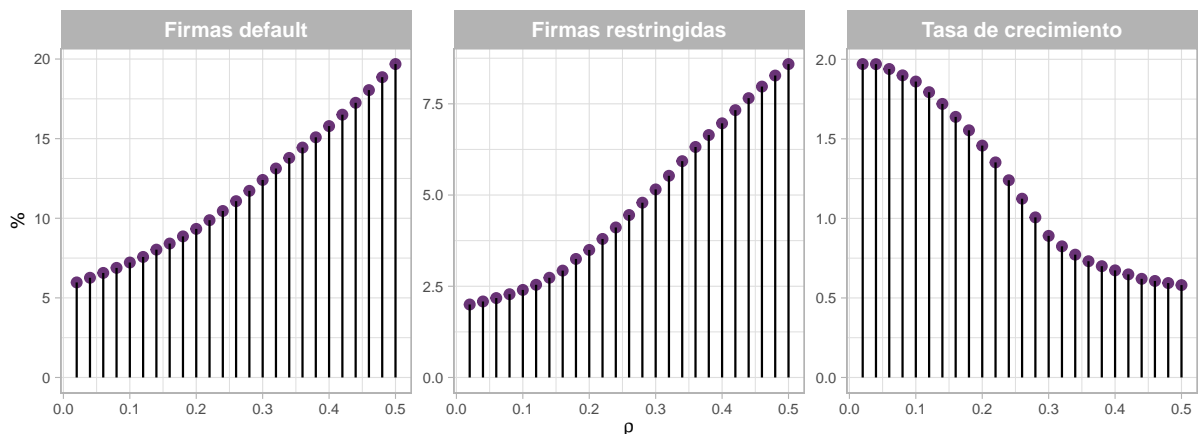


Los valores de ϵ corresponden a la posición que ocupan en los intervalos especificados para cada regla de la ecuación 1.18.

analizamos con mayor detalle el efecto que tiene este parámetro sobre la tasa de crecimiento, la proporción de firmas en default y la proporción de firmas restringidas en el mercado de crédito bancario.

Como se puede observar en la figura 2.7, un mayor rendimiento del activo financiero se asocia con una menor tasa de crecimiento en el largo plazo. Este movimiento no es lineal –es decir, no se produce a una velocidad constante–, sino que se observa una caída en la tasa de crecimiento más acelerada en los valores pequeños de ρ , mientras que se desacelera para los valores más grandes considerados. Al mismo tiempo, a medida que ρ crece hay un mayor número de firmas que se ven restringidas en el mercado de crédito. Esto implica una menor producción y menores posibilidades de repagar su deuda en el futuro, lo que explica en parte la relación observada entre el parámetro en cuestión y la tasa de crecimiento. Relacionado a esto último, cabe mencionar también que a medida de asumimos una rentabilidad mayor para el activo financiero, crece la probabilidad de quiebra de las firmas productivas, dificultades que se extienden al resto de la economía a través de la red.

Figura 2.7: Sensibilidad ante cambios en el valor de ρ . Tasa de crecimiento, firmas en default y firmas restringidas.



2.6 Comentarios finales

En este capítulo estudiamos un modelo basado en agentes con el objetivo de analizar el potencial papel desestabilizador que juegan los bancos en el sistema económico en contextos inciertos, en línea con la hipótesis de inestabilidad financiera de Minsky (1986). En particular, reproducimos dos estrategias para determinar la oferta de crédito por parte de los bancos. Consideramos dos escenarios. Uno en el cual los bancos solo asignan sus fondos para financiar proyectos productivos de las empresas. Los bancos consideran la relación de adecuación de capital ($CS = A/L$) para determinar tanto la cantidad como el costo del crédito y restringen el crédito solo a las empresas con problemas de liquidez. En el segundo escenario, los bancos pueden adquirir un activo financiero, es decir, distribuyen los fondos disponibles entre el mercado crediticio y el mercado financiero. Se asume que tienen un objetivo de cobertura de liquidez, que aumenta cuando forman expectativas pesimistas sobre la evolución de la actividad económica. En consecuencia, los bancos racionan el crédito cuando no alcanzan sus objetivos de liquidez. En cuanto a la fijación de la tasa de interés, el mecanismo es el mismo en ambos escenarios. Los bancos tienen en cuenta tanto la situación financiera de la empresa solicitante como la solidez financiera en sí para determinar el costo del crédito.

Las propiedades dinámicas del modelo son consistentes con el análisis de Minsky. Los cambios en las estrategias de oferta de crédito de los bancos tienen efectos significativos sobre la (in)estabilidad en el sector real. A medida que los bancos restringen el crédito a las empresas y redistribuyen recursos al sector financiero, aumenta el número de empresas que no pueden cumplir con sus compromisos previos y crece la proporción de empresas que abandonan el mercado. En este sentido, las simulaciones muestran un efecto negativo en la actividad económica cuando los bancos asignan fondos al mercado financiero, es decir, cuando hay una redistribución de recursos de la economía real al sector financiero. Estos resultados son consistentes con lo que se encuentra en la literatura relacionada (Delli Gatti *et al.*, 2010; Riccetti *et al.*, 2016a; Di Guilmi *et al.*, 2020).

Por otro lado, aplicamos herramientas de teoría de redes para estudiar la estructura topológica de la red y mostramos la relevancia de las interconexiones crediticias para la dinámica económica. Los resultados resaltan que cuando los bancos redistribuyen fondos del sector real al financiero, crece la concentración en la red de crédito. Esto tiene un impacto negativo tanto en el sector productivo como en el financiero.

Este estudio contribuye a la literatura de ABM que representan los vínculos entre los sistemas financiero y real de la economía, mediante la construcción de un marco de red para evaluar el papel de los bancos en la propagación del estrés financiero al sector real. En términos de política económica, el modelo permite extraer conclusiones sobre algunos de los factores que afectan la estabilidad financiera. En particular, un requisito de liquidez en economías con mercados financieros de gran tamaño y diversificación puede tener un efecto estabilizador en el sistema

bancario al aumentar la solidez financiera de estas unidades. Pero en aquellas economías con un mercado crediticio pequeño y bajos niveles de acceso al crédito bancario, puede tener efectos negativos en la economía real. Este resultado tiene implicaciones para la formulación de políticas económicas, ya que indica la importancia de considerar las características particulares de las economías al diseñar la regulación financiera: una regla podría ser útil en una economía pero no (e incluso perjudicial) en otra.

Los resultados encontrados plantean nuevas preguntas que pueden pensarse en futuras investigaciones. En primer lugar, dado que encontramos que el comportamiento de los bancos tiene influencia en los resultados agregados, los vínculos entre estas mismas instituciones financieras –por ejemplo, en el mercado interbancario podrían significar un canal adicional de contagio de riesgo sistémico, con potenciales consecuencias sobre la economía real (considerando los canales analizados en este capítulo). En este sentido, se puede considerar la incorporación del mercado interbancario para representar la demanda y oferta de liquidez de los bancos. Este mercado en particular se estudia empíricamente en el capítulo 3 para el caso argentino. En segundo lugar, dado que los resultados encontrados muestran que los vínculos crediticios pueden contribuir a la amplificación y propagación de eventos negativos, para profundizar en el análisis de dichos efectos es necesaria una representación más realista del sector productivo. Esto podría lograrse a partir de la inclusión de los hogares y, por lo tanto, de un mecanismo endógeno de formación de precios en el mercado de bienes y trabajo. Finalmente, si bien no fue abordado en este capítulo dado el objetivo de analizar el efecto del comportamiento de los bancos, surge la pregunta acerca del efecto del comportamiento de las empresas, como se plantea en primera instancia en la HIF. En este sentido, una línea de investigación posible es incorporar opciones de inversión financiera para las empresas productivas, por ejemplo, a través de la inclusión de un mercado de capitales. Esto permitiría analizar no solo los efectos del comportamiento especulativo de los bancos, sino también los del sector corporativo, un elemento no menor en la dinámica de la HIF de Minsky.

2.7 Anexo

2.7.1 Ejemplo numérico reducido

En esta sección se presentará un ejemplo numérico reducido, para ilustrar el funcionamiento del modelo en el escenario base. Supongamos una economía con 3 bancos (z) y 4 firmas (i), los bancos tienen los siguientes patrimonios A_z : $[1, 2, 3] = [20, 30, 40]$; mientras que el patrimonio de las firmas A_i es de $[a, b, c, d] = [5, 10, 15, 20]$. Supongamos a su vez que partimos de una situación donde los bancos y las firmas ya han otorgado/recibido un préstamo, de manera que se encuentran vinculados por vínculos crediticios como indica el cuadro 2.7.

Las firmas tienen un nivel de producción deseada que es una función de su patrimonio: $Y^d = A^{0.15}$.

Cuadro 2.7: Vínculos iniciales, ejemplo numérico reducido.

Banco acreedor	Firma deudora	Monto del préstamo
1	a	4
1	b	6
2	a	4
2	d	7
3	c	4
3	d	7

Cuadro 2.8: Tasa de interés ofrecida, monto disponible para prestar por parte de los bancos y nivel de apalancamiento de las firmas.

Banco	Firmas				Monto disponible
	a	b	c	d	
1	7.79	4.79	3.79	5.09	5
2	7.74	4.74	3.74	5.04	14
3	7.71	4.71	3.71	5.01	25
Apalancamiento	1.60	0.60	0.40	0.70	
Demanda de deuda	3.47	8.30	13.20	18.47	

Para producir, utilizan solo unidades de trabajo y el costo por unidad de trabajo es igual 1. La función de producción está dada por $Y_i = 0.83L$. La demanda de trabajo está dada por: $L_i = 1.2A_i^{0.15} = 1.2Y^d$. De esta manera, cada empresa tiene un nivel de producción deseado y una demanda de trabajo diferente. Para financiar la producción las empresas utilizan sus recursos propios A_i y también pueden solicitar crédito a los bancos, pero priorizan la utilización de sus recursos en primer lugar dado que el crédito tiene un costo. Las empresas requerirán crédito si $W_i > A_i$, siendo $W_i = L_i$ el costo total por la contratación de trabajadores. El monto que solicitarán será igual a la diferencia entre el costo W y sus recursos A . En nuestro ejemplo todas las firmas tendrán demanda positiva de crédito, por un monto igual al que se indica en el cuadro 2.8.

Ahora bien, esto es lo que requiere cada una de las empresas para poder financiar el nivel de producción deseada y van a solicitarlo a los bancos quienes les informarán una tasa de interés que calcularán considerando tanto sus condiciones financieras como las de las empresas: $r_{iz} = 0.03 \cdot \left(\frac{A_z}{B_z}\right)^{-0.03} + 0.03 \cdot \frac{B_i}{A_i}$, donde B_z y B_i corresponden al monto total de préstamos otorgados por z y recibidos por i , respectivamente. El monto disponible que tienen los bancos es igual a $Cred_z = A_z - B_z$.

En este contexto, los bancos ofrecen las tasas de interés a cada empresa como se especifica en el cuadro 2.8 y tienen disponible para prestar el monto que se especifica en la última columna del mismo cuadro. En ausencia de shocks, todas las firmas pueden cubrir sus objetivos de producción porque hay suficientes fondos disponibles en el sector financiero. Por lo tanto, la misma será igual a la suma de las producciones deseadas por parte de las firmas, igual a 93.5.

Ahora supongamos que, en este mismo contexto y previo al otorgamiento de préstamos, hay un shock negativo sobre el patrimonio de las empresas a y d, el cual se reduce en un 50%. Esta

Cuadro 2.9: Tasa de interés ofrecida, monto disponible para prestar por parte de los bancos y nivel de apalancamiento de las firmas. Post shock.

Banco	Firmas				Monto disponible
	a	b	c	d	
1	12.56	4.76	3.76	7.16	5
2	12.53	4.73	3.73	7.13	14
3	12.49	4.69	3.69	7.09	25
Apalancamiento	3.20	0.60	0.40	1.40	
Demanda de deuda	3.47	8.30	13.20	18.47	

situación impacta sobre la capacidad de repago que tienen estas empresas para el préstamo, el cuál vamos a suponer que no pueden afrontar y, por lo tanto, se reduce el patrimonio de los bancos acreedores en un valor correspondiente al monto de la deuda.

Post shock, la situación queda determinada como se indica en el cuadro 2.9. Las empresas a y d no tienen suficientes fondos para repagar el préstamo por lo que el nuevo patrimonio de los bancos que mantenían un vínculo con a y/o d es menor al del momento previo al shock, mientras que el de las firmas b y c se mantiene. Bajo esta configuración las tasas de interés que ofrecen los bancos serán las que indica el cuadro 2.9. Notar que las tasas de interés son más elevadas, no solo para las firmas que vieron afectado su patrimonio, sino para todas ellas, ya que el banco tiene un menor patrimonio y, por lo tanto, traslada el efecto del shock hacia el resto de las firmas mediante un costo más elevado para el crédito.

Así, todas las firmas en el mercado enfrentan un mayor costo para el financiamiento del préstamo, lo que disminuye sus beneficios, su patrimonio y, en consecuencia, su nivel de producción. Asimismo, en el siguiente período, los bancos tendrán un menor monto disponible para préstamos a causa del impacto sobre su patrimonio, por lo que puede tener lugar racionamiento de crédito, lo que impacta sobre el nivel de producción. Este proceso puede repetirse hasta que ya no queden bancos y/o firmas en el mercado y es precisamente este proceso de contagio de dificultades financieras lo que se analiza en el capítulo, representando el comportamiento de los agentes, su interacción en el mercado de crédito y los mecanismos de transmisión de shocks de manera más compleja.

2.7.2 Análisis de robustez

Realizamos 100 simulaciones de Monte Carlo para ambos escenarios, utilizando diferentes semillas. Los cuadros 2.10 y 2.11 muestran los resultados para el escenario base y el escenario alternativo, respectivamente. Observamos una volatilidad aceptable entre los resultados de las diferentes simulaciones. Las medias de las distribuciones de las diferentes variables no presentan desviaciones estándar elevadas. No observamos asimetrías en términos de oferta y demanda de crédito. Esto indica que no hay situaciones en las que los bancos ofrezcan crédito pero las empresas no lo

Cuadro 2.10: Análisis de robustez, escenario 1. Períodos 200-1000.

Variable	Medida	Escenario 1			
		Mediana	Desvío	Mín.	Máx.
Deuda incobrable	Desvío	2.09	0.83	0.41	5.54
Deuda incobrable	Máximo	13.49	5.55	2.50	35.84
Deuda incobrable	Mediana	8.38	3.30	1.55	21.02
Patrimonio Neto bancos	Desvío	7,226.15	4,888.14	774.01	24,442.58
Patrimonio Neto bancos	Máximo	46,026.35	31,959.65	5,080.48	162,494.37
Patrimonio Neto bancos	Mediana	28,752.87	19,181.82	3,029.11	91,518.47
Deuda	Desvío	2,559.97	378.88	1,651.18	4,157.53
Deuda	Máximo	16,782.65	2,429.76	11,058.53	25,761.40
Deuda	Mediana	10,329.79	1,347.03	7,068.05	14,800.87
Deuda	Mínimo	3,869.64	1,202.26	258.83	7,519.20
Patrimonio Neto firmas	Desvío	5,023.49	5,574.14	2,448.20	25,282.05
Patrimonio Neto firmas	Máximo	32,904.53	36,251.30	16,716.57	162,144.92
Patrimonio Neto firmas	Mediana	19,917.58	22,070.88	10,550.34	86,942.40
Producto	Desvío	7,997.82	771.93	5,726.89	11,246.39
Producto	Máximo	52,101.90	4,864.17	40,820.20	71,816.04
Producto	Mediana	32,178.77	2,363.69	26,416.22	40,591.95
Producto	Mínimo	12,632.86	3,513.40	1,418.29	21,524.36
Tasa de interes	Desvío	1.49	0.11	1.15	1.84
Tasa de interes	Máximo	9.68	0.64	7.96	12.18
Tasa de interes	Mediana	5.99	0.19	5.37	6.56
Tasa de interes	Mínimo	2.25	0.65	0.89	3.86
Apalancamiento	Desvío	0.21	0.07	0.06	0.34
Apalancamiento	Máximo	1.33	0.43	0.40	2.24
Apalancamiento	Mediana	0.82	0.26	0.25	1.28
Apalancamiento	Mínimo	0.29	0.12	0.12	0.67
Quiebra bancos (%)	Desvío	0.98	0.31	0.00	1.28
Quiebra bancos (%)	Máximo	12.00	0.21	8.00	18.00
Quiebra bancos (%)	Mediana	0.00	1.26	0.00	10.45
Quiebra firmas (%)	Desvío	1.34	0.26	0.56	2.17
Quiebra firmas (%)	Máximo	8.73	1.70	3.63	13.79
Quiebra firmas (%)	Mediana	5.41	0.98	2.27	8.39

demanden. En resumen, el experimento nos permite concluir que los resultados del modelo son robustos.

2.7.3 Comparación con datos empíricos

Como ejercicio empírico, comparamos los resultados con la economía argentina en el cuadro 2.12. En particular, se espera que el Escenario 1 coincida con períodos de alto crecimiento e inestabilidad (como 2001-2007), mientras que el Escenario 2 coincide con la inestabilidad y la gestión de liquidez por parte del Banco Central como en 2008-2017 para contrarrestar las presiones inflacionarias y de devaluación.

Referencias

Allen, F., & Gale, D. (2000). Bubbles and crises. *Economic Journal*, 110(460), 236-255.

Cuadro 2.11: Análisis de robustez, escenario 2. Períodos 200-1000.

Variable	Medida	Escenario 2			
		Mediana	Desvío	Mín.	Máx.
Deuda incobrable	Desvío	2.20	1.08	0.42	15.71
Deuda incobrable	Máximo	14.50	6.95	3.35	99.88
Deuda incobrable	Mediana	8.91	4.21	2.18	57.68
Patrimonio Neto bancos	Desvío	4,238.61	5,982.15	584.32	26,040.35
Patrimonio Neto bancos	Máximo	27,432.82	39,469.44	4,169.00	158,883.34
Patrimonio Neto bancos	Mediana	16,859.08	24,108.69	2,609.72	96,515.92
Deuda	Desvío	1,311.22	352.34	868.25	2,600.82
Deuda	Máximo	8,490.26	2,303.61	5,521.41	16,573.45
Deuda	Mediana	5,192.19	1,352.22	3,598.06	9,895.13
Deuda	Mínimo	2,051.70	822.64	173.54	4,905.84
Patrimonio Neto firmas	Desvío	4,694.51	3,130.03	2,446.94	14,466.27
Patrimonio Neto firmas	Máximo	30,598.21	20,086.54	17,079.22	89,951.05
Patrimonio Neto firmas	Mediana	18,881.55	12,345.86	11,103.63	53,221.01
Producto	Desvío	5,741.24	865.76	3,967.72	8,671.40
Producto	Máximo	37,680.88	5,466.96	28,019.64	58,280.96
Producto	Mediana	22,917.64	3,207.17	18,531.44	32,924.21
Producto	Mínimo	9,095.66	2,817.19	861.78	17,202.74
Tasa de interes	Desvío	1.53	0.11	1.16	1.90
Tasa de interes	Máximo	9.92	0.68	8.60	13.08
Tasa de interes	Mediana	6.15	0.20	5.53	6.73
Tasa de interes	Mínimo	2.35	0.65	0.81	3.63
Apalancamiento	Desvío	0.27	0.08	0.11	0.46
Apalancamiento	Máximo	1.72	0.51	0.75	3.08
Apalancamiento	Mediana	1.07	0.31	0.46	1.62
Apalancamiento	Mínimo	0.37	0.16	0.00	0.87
Quiebra bancos (%)	Desvío	0.62	0.18	0.43	1.18
Quiebra bancos (%)	Máximo	6.00	0.95	4.00	8.00
Quiebra bancos (%)	Mediana	0.00	0.71	0.00	5.92
Quiebra firmas (%)	Desvío	1.40	0.27	0.53	2.89
Quiebra firmas (%)	Máximo	9.24	1.74	3.45	15.14
Quiebra firmas (%)	Mediana	5.67	1.02	1.99	9.56

Cuadro 2.12: Comparación del output del modelo con variables observables de la economía argentina.

VARIABLES	Escenario 1	Escenario 2	1990-2018	1990-2000	2001-2007	2008-2018
Tasa de crecimiento (%)	4.40	1.97	3.41	2.53	3.68	1.02
Ratio deuda-PBI (%)	26.51	21.56	26.66	27.16	28.76	24.06
Tasa de interés (%)	5.99	6.40	3.57	11.03	4.53	-4.83
Apalancamiento	0.77	1.04				1.40
Crédito irregular (%)	5.43	5.97			4.76	6.01

Notas: La tasa de crecimiento comienza en 1993, fuente INDEC. La tasa de interés comienza en 1994, es la tasa de préstamos ajustada por el deflactor del PIB, fuente FMI. La deuda utilizada para calcular la relación deuda/PBI es la deuda del sector corporativo no financiero provista por los bancos, fuente BIS. La irregularidad del crédito es la proporción de empresas, fuente BCRA (estadísticas publicadas en el informe de estabilidad financiera). El apalancamiento es pasivo / activo, fuente BCRA (estadísticas publicadas en el informe de estabilidad financiera).

- Anufriev, M., & Hommes, C. (2012). Evolutionary selection of individual expectations and aggregate outcomes in asset pricing experiments. *American Economic Journal: Microeconomics*, 4(4), 35-64.
- Arslan, I., Caverzasi, E., Gallegati, M., & Duman, A. (2016). Long term impacts of bank behavior on financial stability. An agent based modeling approach. *Journal of Artificial Societies and Social Simulation*, 19(1), 11.
- Barabási, A.-L., & Albert, R. (1999). Emergence of scaling in random networks. *Science*, 286, 509-512.
- Battiston, S., Delli Gatti, D., Gallegati, M., Greenwald, B., & Stiglitz, J. E. (2012). Default cascades: When does risk diversification increase stability? *Journal of Financial Stability*, 8(3), 138-149.
- Bernanke, B. (1989). Agency Costs, Net Worth and Business Fluctuations. *American Economic Review*, 79(1).
- Bernanke, B. S., & Blinder, A. S. (1988). Is it money or credit, or both, or neither. *American Economic Review*, 78(2), 435-439.
- Bernanke, B. S., Gertler, M., & Gilchrist, S. (1996). The flight to quality and the financial accelerator. *Review of Economics and Statistics*, 78(1), 1-15.
- Bernanke, B., & Blinder, A. S. (1992). The federal funds rate and the transmission of monetary policy. *American Economic Review*, 82(4), 901-921.
- Bernanke, B., & Gertler, M. (1990). Financial fragility and economic performance. *The quarterly journal of economics*, 105(1), 87-114.
- Boneva, L., Cloyne, J., Weale, M., & Wieladek, T. (2020). Firms' price, cost and activity expectations: Evidence from micro data. *The economic journal*, 130(627), 555-586.
- Caverzasi, E. (2014). *Minsky and the subprime mortgage crisis: The financial instability hypothesis in the era of financialization* (Economics Working Paper Archive 796). Levy Economics Institute.
- Céspedes, J., González, M., & Molina Manzano, C. (2010). Ownership and capital structure in Latin America. *Journal of Business Research*, 63(3), 248-254.
- Chen, S.-H., Chang, C.-L., & Du, Y.-R. (2012). Agent-based economic models and econometrics. *The Knowledge Engineering Review*, 27(2), 187-219.
- Chiarella, C., & Di Guilmi, C. (2011). The financial instability hypothesis: A stochastic microfoundation framework. *Journal of Economic Dynamics and Control*, 35(8), 1151-1171.
- Clauset, A., Shalizi, C. R., & Newman, M. E. J. (2009). Power-law distributions in empirical data. *SIAM Review*, 51(4), 661-703.
- Coibion, O., Gorodnichenko, Y., & Kumar, S. (2018). How do firms form their expectations? new survey evidence. *American Economic Review*, 108(9), 2671-2713.
- D'Erasmus, P., Moscoso Boedo, H., Olivero, M. P., & Sangiácomo, M. (2020). Relationship Networks in Banking Around a Sovereign Default and Currency Crisis. *IMF Economic Review*, 0, 1-59.
- Delli Gatti, D., Di Guilmi, C., Gaffeo, E., Giulioni, G., Gallegati, M., & Palestrini, A. (2005). A

- new approach to business fluctuations: heterogeneous interacting agents, scaling laws and financial fragility. *Journal of Economic Behavior & Organization*, 56(4), 489-512.
- Delli Gatti, D., Gaffeo, E., Gallegati, M., Giulioni, G., Kirman, A., Palestrini, A., & Russo, A. (2007). Complex dynamics and empirical evidence. *Information Sciences*, 177(5), 1204-1221.
- Delli Gatti, D., Gallegati, M., Greenwald, B., Russo, A., & Stiglitz, J. E. (2010). The financial accelerator in an evolving credit network. *Journal of Economic Dynamics and Control*, 34(9), 1627-1650.
- Delli Gatti, D., Palestrini, A., Gaffeo, E., Giulioni, G., & Gallegati, M. (2008). *Emergent macroeconomics: An agent-based approach to business fluctuations*. Springer.
- Di Guilmi, C. (2017). The Agent-Based Approach to Post Keynesian Macro-Modeling. *Journal of Economic Surveys*, 31(5), 1183-1203.
- Dosi, G., Faillo, M., & Marengo, L. (2018). *Beyond "bounded rationality": Behaviours and learning in complex evolving worlds*. LEM Working Paper Series.
- Dosi, G., & Roventini, A. (2019). More is different... and complex! The case for agent-based macroeconomics. *Journal of Evolutionary Economics*, 29(1), 1-37. <https://doi.org/10.1007/s00191-019-00609-y>
- Dow, A. C., & Dow, S. C. (1989). Endogenous money creation and idle balances. En *Pheby, J. (Ed.). New directions in post-Keynesian economics*. Edward Elgar Aldershot.
- Eboli, M. (2019). A flow network analysis of direct balance-sheet contagion in financial networks. *Journal of Economic Dynamics and Control*, 103(C), 205-233.
- Epstein, J. M. (2006). Remarks on the foundations of agent-based generative social science. *Handbook of computational economics*, 2, 1585-1604.
- Evans, G. W., & Honkapohja, S. (2001). *Learning and expectations in macroeconomics*. Princeton University Press.
- Gai, P., & Kapadia, S. (2010). Contagion in financial networks. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 466(2120), 2401-2423.
- Gai, P., & Kapadia, S. (2019). Networks and systemic risk in the financial system. *Oxford Review of Economic Policy*, 35(4), 586-613.
- Gallegati, M., Keen, S., Lux, T., & Ormerod, P. (2006). Worrying trends in econophysics. *Physica A: Statistical Mechanics and its Applications*, 370(1), 1-6. <https://doi.org/10.1016/j.physa.2006.04.029>
- Gigerenzer, G. (2015). *Risk savvy: How to make good decisions*. Penguin.
- Gilli, M., & Winker, P. (2003). A global optimization heuristic for estimating agent based models. *Computational Statistics & Data Analysis*, 42(3), 299-312.
- Gourieroux, C., Monfort, A., & Renault, E. (1993). Indirect inference. *Journal of applied econometrics*, 8(S1), S85-S118.
- Greenwald, B. C., & Stiglitz, J. E. (1993). Financial market imperfections and business cycles. *The Quarterly Journal of Economics*, 108(1), 77-114.
- Gusella, F., & Stockhammer, E. (2021). Testing fundamentalist–momentum trader financial cycles: An empirical analysis via the Kalman filter. *Metroeconomica*, 72(4), 758-797.

- Hernán Zeolla, N., & Médici, F. (2022). Desregulación, endeudamiento y fragilidad financiera externa: un enfoque minskiano para la crisis argentina 2018-2019. *Ensayos de Economía*, 32(60).
- Iori, G., Jafarey, S., & Padilla, F. G. (2006). Systemic risk on the interbank market. *Journal of Economic Behavior & Organization*, 61(4), 525-542.
- Keynes, J. M. (1930). *Treatise on money*. MacMillan.
- Keynes, J. M. (1936). *The general theory of interest, employment and money*. MacMillan.
- Kiyotaki, N., & Moore, J. (1997). Credit cycles. *Journal of political economy*, 105(2), 211-248.
- Lavoie, M. (2009). *Introduction to post-Keynesian economics*. Springer.
- Lavoie, M. (2014). *Post-Keynesian economics: new foundations*. Edward Elgar Publishing.
- Lavoie, M., & Seccareccia, M. (2001). Minsky's financial fragility hypothesis: a missing macroeconomic link. *Financial fragility and investment in the capitalist economy: The economic legacy of Hyman Minsky*, 2, 76-96.
- LeBaron, B., & Tesfatsion, L. (2008). Modeling macroeconomies as open-ended dynamic systems of interacting agents. *American Economic Review*, 98(2), 246-250.
- Maquieira, C. P., Preve, L. A., & Sarria-Allende, V. (2012). Theory and practice of corporate finance: Evidence and distinctive features in Latin America. *Emerging markets review*, 13(2), 118-148.
- Mazzarisi, P., Barucca, P., Lillo, F., & Tantari, D. (2020). A dynamic network model with persistent links and node-specific latent variables, with an application to the interbank market. *European Journal of Operational Research*, 281(1), 50-65.
- Minsky, H. P. (1976). *John Maynard Keynes*. Springer.
- Minsky, H. P. (1986). *Stabilizing an unstable economy*. McGraw-Hill Education.
- Minsky, H. P. (2016). *Can it happen again?: Essays on instability and finance*. Routledge. First Edition: 1981.
- Nikolaidi, M. (2014). Margins of safety and instability in a macrodynamic model with Minskyan insights. *Structural Change and Economic Dynamics*, 31, 1-16.
- Nikolaidi, M., & Stockhammer, E. (2017). Minsky models: A structured survey. *Journal of Economic Surveys*, 31(5), 1304-1331.
- Noguera, D., & Montes-Rojas, G. (2022). Fluctuaciones con restricciones de crédito e incertidumbre en una economía de red. *Ensayos Económicos*, 80, 1-48.
- Riccetti, L., Russo, A., & Gallegati, M. (2013). Leveraged network-based financial accelerator. *Journal of Economic Dynamics and Control*, 37(8), 1626-1640.
- Riccetti, L., Russo, A., & Gallegati, M. (2016). Stock market dynamics, leveraged network-based financial accelerator and monetary policy. *International Review of Economics & Finance*, 43(C), 509-524. <https://doi.org/10.1016/j.iref.2016.01.01>
- Russo, A., Catalano, M., Gaffeo, E., Gallegati, M., & Napoletano, M. (2007). Industrial dynamics, fiscal policy and R&D: Evidence from a computational experiment. *Journal of Economic Behavior & Organization*, 64(3-4), 426-447.
- Saunders, A., & Schumacher, L. (2000). The determinants of bank interest rate margins: an

- international study. *Journal of international Money and Finance*, 19(6), 813-832.
- Schularick, M., & Taylor, A. M. (2012). Credit Booms Gone Bust: Monetary Policy, Leverage Cycles, and Financial Crises, 1870-2008. *American Economic Review*, 102(2), 1029-1061.
- Sornette, D. (2017). *Why stock markets crash: critical events in complex financial systems* (Vol. 49). Princeton University Press.
- Stiglitz, J., & Greenwald, B. (2003). *Towards a new paradigm in monetary economics*. Cambridge University Press.
- Tedeschi, G., Recchioni, M. C., & Berardi, S. (2019). An approach to identifying micro behavior: How banks' strategies influence financial cycles. *Journal of Economic Behavior & Organization*, 162, 329-346.
- Tesfatsion, L., & Judd, K. L. (2006). *Handbook of computational economics: agent-based computational economics*. Elsevier.
- Wagner, W. (2011). Systemic liquidation risk and the diversity–diversification trade-off. *Journal of Finance*, 66(4), 1141-1175.

3 Los determinantes del riesgo sistémico en el mercado interbancario argentino.

3.1 Introducción

En este capítulo analizamos los determinantes del riesgo sistémico en el mercado interbancario argentino (2015-2018). En los mercados financieros el riesgo sistémico implica que las interdependencias entre las instituciones financieras pueden crear canales y/o amplificar los mecanismos para que un evento disruptivo, que afecta inicialmente a solo una parte del sistema se propague ampliamente, lo que lleva a pérdidas mucho mayores que las fallas individuales que los inician. En este trabajo, evaluamos el papel desempeñado en la emergencia de este fenómeno por las variables asociadas tanto con las características financieras de los bancos como con la topología de la red interbancaria. Para ello, aproximamos el riesgo sistémico mediante la metodología *Differential DebtRank* y aplicamos tres modelos de aprendizaje automático: Adaptive Boosting (AdaBoost), eXtreme Gradient Boosting (XGBoost) y Random Forest. Estos modelos permiten capturar relaciones no lineales complejas entre las variables en estudio, lo cual es relevante para el fenómeno abordado, ya que diversas contribuciones a la literatura de este campo muestran que los vínculos entre las instituciones pueden contribuir a la amplificación de shocks de manera no lineal (ver, por ejemplo, [Acemoglu et al., 2015b](#); [Battiston et al., 2012a](#); [Iori et al., 2006](#)).

El riesgo sistémico se puede definir como la probabilidad de una caída en el sistema financiero, desencadenada por un evento disruptivo, como el colapso de una institución financiera ([Patro et al., 2013](#)). El estudio del riesgo sistémico en los mercados financieros es relevante para la toma de decisiones asociadas a la regulación financiera, especialmente aquellas que persiguen el objetivo de alcanzar y/o sostener la estabilidad en estos mercados. Muchas normativas, como la Ley Dodd-Frank o el acuerdo de Basilea III, se han centrado en la regulación directa de las instituciones que son sistémicamente más importantes en distintos mercados. En lo que refiere a los mercados interbancarios en particular, en muchos países del mundo desempeñan un papel importante en las decisiones de política monetaria y su transmisión, ya que las tasas de interés interbancarias suelen ser utilizadas como tasas de referencia. En este sentido, tanto las instituciones financieras como las reguladoras requieren comprender y gestionar los riesgos en estos mercados, lo que implica evaluar los posibles escenarios de crisis y desarrollar estrategias de mitigación de riesgos.

Desde una perspectiva de red, el análisis del riesgo sistémico implica evaluar cómo un shock específico se propaga a través de una red de instituciones conectadas por un vínculo de vulnerabilidad –como pueden ser, por ejemplo, las obligaciones de deuda–, lo que resulta en fragilidad agregada –como puede ser el riesgo de liquidez–. El mecanismo a través del cual un shock idiosincrático limitado a un nodo individual podría propagarse por todo el sistema es el contagio (Schwarcz, 2008). El contagio en los mercados financieros se refiere a la propagación de una crisis o evento negativo desde un mercado o institución financiera a otros mercados o instituciones, causando un efecto en cadena. En esencia, es un fenómeno en el que un evento aislado o un shock en un mercado o institución financiera en particular puede extenderse y afectar otros mercados o instituciones, incluso cuando no se encuentran directamente relacionados con el evento original. Específicamente, el contagio hace posible identificar dos dimensiones cuantitativas del riesgo sistémico que son: (1) la difusión del impacto, es decir, el daño potencial que una institución podría causar a la economía y (2) la susceptibilidad al impacto, es decir, la probabilidad de que un shock negativo aleatorio termine causando pérdidas a una institución en particular (Silva *et al.*, 2017a). En consecuencia, la estructura de interconexiones entre las unidades de un sistema financiero es un elemento clave para detectar potenciales riesgos⁴³.

Si bien la literatura que aborda el fenómeno del riesgo sistémico en mercados financieros es de larga data, en los últimos años experimentó un importante crecimiento, y diversos aspectos de este problema se analizan en un número creciente de trabajos⁴⁴. De acuerdo con Gai y Kapadia (2010) los canales de riesgo sistémico se pueden resumir en dos: (1) el riesgo de contagio directo y (2) el riesgo de contagio indirecto. El primero de ellos, surge debido a la red de exposiciones dentro del sistema financiero, lo que puede crear tanto riesgo de liquidez como riesgo de solvencia. El segundo, es provocado por fenómenos de retiro de fondos y ventas forzosas de activos comunes⁴⁵. Si bien hay acuerdo sobre los canales del riesgo sistémico, no existe una única metodología de medición comúnmente aceptada para este fenómeno. En líneas generales, es posible identificar dos enfoques principales: (1) el enfoque de mercado o de mediciones estadísticas y (2) el enfoque de red⁴⁶. El primero postula que los bancos están disciplinados por el mercado y, por lo tanto, existe una relación significativa entre el riesgo sistémico y los valores de mercado. Desde esta perspectiva, el evento desencadenante (o shock) y su impacto en el mercado y la economía en general se analizan en términos de valores de mercado, como pueden ser los precios de las acciones o los CDS (*credit default swap*)⁴⁷. Una medida ampliamente difundida desarrollada desde esta perspectiva, es el *Marginal Expected Shortfall* o MES (Acharya *et al.*, 2017), la cual se define como la tasa neta de retorno de capital esperada de un banco cuando el mercado está en su nivel

⁴³En esta línea, en el capítulo 2 mostramos la relevancia de la topología de interacciones entre firmas (no financieras) y bancos en el mercado de crédito bancario en las fluctuaciones del producto en una economía.

⁴⁴Ver, por ejemplo, Silva *et al.* (2017b) y Benoit *et al.* (2017), para una revisión de esta literatura.

⁴⁵Los retiros bancarios están relacionados con el riesgo de liquidez, mientras que las ventas forzosas de activos comunes causan pérdidas y, por lo tanto, están relacionadas principalmente con el riesgo de solvencia.

⁴⁶Para una revisión más completa acerca de la medición del riesgo sistémico y sus determinantes en mercados financieros, se puede ver Bisias *et al.* (2012); Jackson y Pernoud (2021) y Neveu (2018).

⁴⁷El CDS es un contrato financiero bilateral de acuerdo con el cual un comprador paga una prima fija periódica a un vendedor para cubrirse ante un evento de crédito de una entidad de referencia.

de peor rendimiento en un año. Otra medida es el CoVaR, propuesta por [Adrian y Brunnermeier \(2016\)](#), que mide el valor en riesgo (VaR) del sector financiero dado que un banco ha tenido una pérdida de VaR, mediante regresiones cuantílicas. Otras medidas, incluyen la prima de seguro de crisis o DIP ([Huang et al., 2009](#)), el indicador de Lehar ([Lehar, 2005](#)) y el SRISK ([Brownlees y Engle, 2017](#)).

En síntesis, estas medidas se basan usualmente en los precios de mercado como indicador capaz de abordar los canales de riesgo sistémico. No obstante, como señala [Neveu \(2018\)](#), se centran solo en unos pocos aspectos de estos canales y no tienen en cuenta muchas dimensiones de la complejidad del fenómeno. Por otro lado, hay que tener en cuenta que muchas veces se basan en datos de mercado que no están disponibles para todas las instituciones financieras. Asimismo, algunos autores como [Danielsson et al. \(2016\)](#) señalan que parten de supuestos muy fuertes y/o carecen de robustez ante cambios en dichos supuestos. Finalmente, [Di Iasio et al. \(2015\)](#) señalan que si bien los indicadores basados en los precios funcionan bien como medidas coincidentes o contemporáneas, no lo hacen como indicadores prospectivos o de alerta temprana⁴⁸. La principal desventaja de este enfoque es que no incorpora correctamente el papel de las interconexiones entre las instituciones financieras –es decir, las propiedades topológicas del mercado–, las cuales contribuyen al aumento del riesgo sistémico, como se pudo observar durante la crisis financiera de 2008 ([Battiston et al., 2012b](#); [IMF et al., 2009](#)) y traen consigo potenciales riesgos para el sector real de la economía, como se estudió en el capítulo 2. Asimismo, no se debe perder de vista que, como se mencionó previamente, el mecanismo a través del cual un shock idiosincrásico limitado a un nodo individual podría propagarse por todo el sistema es el contagio, con lo cual las interconexiones entre unidades son relevantes ([Schwarcz, 2008](#)).

Los vínculos entre las instituciones constituyen el foco de análisis en el enfoque de la red. En el mercado interbancario las instituciones financieras están vinculadas entre sí a través de instrumentos financieros, como derivados y acuerdos de recompra (repos). A priori, el efecto de estos vínculos respecto al riesgo sistémico no se encuentra determinado. Por un lado, la interconexión permite la diversificación, lo que favorece la reducción del riesgo de cartera. Por el otro, la existencia de vínculos entre instituciones puede ser una fuente de propagación de shocks. Supongamos que un evento disruptivo afecta negativamente la solvencia de un banco en particular. Este banco puede no llegar a cumplir –ya sea total o parcialmente– con los compromisos de deuda que tiene con otros bancos a los que está conectado en el mercado interbancario. Al no recibir dichos pagos, la solvencia de estos bancos también se verá afectada. Este proceso puede continuar hasta que un gran número de bancos en un sistema financiero se vean afectados. Asimismo, este proceso también puede extenderse fuera del sistema financiero, como se vio en el capítulo 2: la menor solvencia de los bancos puede generar restricciones en el otorgamiento de créditos, lo que lleva a las empresas no financieras frente a la falta de financiamiento a reducir la producción ([Noguera y Montes-Rojas, 2022](#)).

⁴⁸Para una discusión sobre las críticas mencionadas, se puede ver, por ejemplo, [Brogi et al. \(2021\)](#).

En resumen, la diversificación del riesgo de crédito individual tiene el potencial de generar efectos ambiguos a nivel sistémico. El beneficio de mitigar los resultados de los incumplimientos de compromisos de deuda se vería compensado por una situación en la que los agentes están más expuestos a corridas de crédito debido al alto número de contrapartes (Battiston *et al.*, 2012a). Es decir, que las interconexiones constituyen un canal para compartir riesgos pero también pueden contribuir a la propagación y amplificación de shocks. Este *trade-off* entre compartir riesgos y propagar shocks, revela la naturaleza robusta pero frágil de las redes financieras: las interconexiones actúan como absorbentes y como amplificadores de eventos disruptivos (Chinazzi y Fagiolo, 2013). Por lo tanto, como señalan Battiston *et al.* (2012a), la estructura de las interrelaciones y las diferencias en los niveles de solidez financiera deben considerarse al establecer políticas que busquen fortalecer la vitalidad de los mercados financieros.

Las medidas propuestas desde este enfoque, se basan en cuantificar la importancia sistémica de una institución dentro de una red financiera. Gran parte de los estudios que analizan el riesgo sistémico desde un enfoque de redes, simulan lo que ocurre en el sistema financiero⁴⁹, por ejemplo, si un banco quiebra debido a un evento disruptivo exógeno: este evento determina deudas incobrables a otros bancos en los mercados interbancarios, que pueden quebrar con una nueva ronda de pérdidas y así sucesivamente, posiblemente provocando una cascada de impagos bancarios. Simular la dinámica de la red, es una forma factible de abordar la complejidad del contagio en un entorno de agentes heterogéneos interactuantes, dada la presencia de importantes no linealidades. Una de las medidas más populares de este enfoque es el *DebtRank*, un método recursivo propuesto por Battiston *et al.* (2012b) para cuantificar la importancia sistémica de los nodos en términos de las pérdidas que un nodo contribuiría a la pérdida total en una crisis. Es una de las primeras propuestas capaz de abordar el problema de las entidades que incurren en dificultades financieras, pero que no incumplen con sus compromisos. Siguiendo el ejemplo presentado en Di Iasio *et al.* (2015), un banco que sufre grandes pérdidas –pero no incurre en impago– reduce el valor de mercado de sus acciones y bonos. Entonces, otros bancos que poseen estos instrumentos financieros en su cartera tendrán que recortar el valor de mercado con nuevas pérdidas. Por lo tanto, el DebtRank expresa la fracción del valor económico total de la red –excluido el banco *i*– puesta en riesgo por algún evento disruptivo que afecte al banco *i*. Battiston *et al.* (2012b) destacan que la medida tiene dos ventajas en comparación con otros algoritmos: (1) es un posible indicador de alerta temprana porque ofrece una respuesta antes del punto crítico de una crisis, y (2) tiene el significado preciso de la pérdida económica causada por un shock exógeno. Por su parte, Kaushik y Battiston (2013) proponen dos medidas de riesgo sistémico estimadas a partir de la información de los CDS: (1) la centralidad de impacto –que aumenta para las empresas que impactan a muchas empresas de importancia sistémica– y la centralidad de vulnerabilidad –que aumenta cuando una empresa tiene fuertes dependencias de muchos nodos que, a su vez, son altamente vulnerables–. Si bien estas medidas contribuyen a identificar a las instituciones de importancia sistémica, como señalan Battiston *et al.* (2012b), el DebtRank tiene

⁴⁹Para una revisión de la literatura de este enfoque se pueden ver los trabajos mencionados previamente, como Neveu (2018).

la ventaja de poder estimar pérdidas monetarias⁵⁰.

Dados los objetivos del capítulo, la principal ventaja del enfoque de redes para estimar el riesgo sistémico es que permite comprender cómo las características topológicas de la red financiera contribuyen como impulsoras o atenuantes del dicho fenómeno. El consenso general respecto de que las instituciones sistémicamente más importantes no son necesariamente las más grandes, se refleja en el uso –por parte de los reguladores del sistema financiero– de expresiones como “demasiado interconectado para fallar” (*too-interconnected-to-fail*) en paralelo con la expresión “demasiado grande para fallar” (*too-big-to-fail*). La interconexión, además del tamaño, es relevante para evaluar la relevancia sistémica.

Existen numerosas investigaciones dedicadas al diseño de medidas que permitan capturar patrones topológicos de una red a nivel local y global, desarrolladas en el marco de la literatura de redes complejas. En este capítulo utilizamos estas contribuciones para tener una mejor comprensión del vínculo entre la estructura de la red interbancaria y el riesgo sistémico. Específicamente, la importancia o influencia estructural de una institución financiera en el mercado, puede ser capturada mediante el concepto de centralidad. Hay un gran número de medidas o índices de centralidad desarrolladas en la literatura, las consideradas clásicas y generalmente más utilizadas en abordajes empíricos, son el grado –el número de vecinos directos de un nodo i –, la centralidad de intermediación –la fracción de caminos más cortos que pasan por un nodo i – y la centralidad de cercanía –el promedio de la longitud del camino más corto desde un nodo i dado hasta cada otro nodo j en la red–. Otras medidas de centralidad incluyen, por ejemplo, la centralidad de autovector, la centralidad de subgrafo y la centralidad PageRank. Todas estas medidas han sido aplicadas en la identificación de bancos sistémicamente importantes. Por ejemplo, [Martinez-Jaramillo et al. \(2014\)](#) evalúan el mercado interbancario y la red de sistemas de pago de México y encuentran que el contagio y la centralidad están altamente correlacionados en las 15 primeras posiciones del ranking en ambas redes. Por su parte, [Kuzubaş et al. \(2014\)](#) utilizaron las medidas de centralidad grado, intermediación, cercanía y centralidad de Bonacich para identificar instituciones relevantes desde el punto de vista sistémico en el mercado interbancario turco. Finalmente, [Ghanbari et al. \(2018\)](#) encontraron mediante un ejercicio de simulación que el número de nodos impactados como consecuencia de una falla única en uno de los nodos, está correlacionada negativamente con el grado del nodo, y positivamente con la centralidad de intermediación y la jerarquía local.

El presente capítulo pretende contribuir a esta literatura. En específico, forma parte de un grupo de contribuciones recientes que estudian los mercados interbancarios argentinos. En primer lugar, podemos mencionar el trabajo de [Anastasi et al. \(2010\)](#) quienes analizan para el caso del mercado CALL el efecto que tienen las interacciones entre los bancos en el acceso a la liquidez. Centrándose

⁵⁰Más recientemente, han surgido dentro de este enfoque contribuciones que proponen la utilización de modelos basados en agentes para la estimación del riesgo sistémico, marco que permite modelizar explícitamente el comportamiento de los agentes, en particular, la reacción de las instituciones financieras durante momentos de crisis. Esta literatura se encuentra en sus primeras etapas de desarrollo, ver, por ejemplo, [Neveu \(2018\)](#) y [Riccetti \(2022\)](#). Asimismo, ha surgido otra literatura que introduce algoritmos de aprendizaje automático para la estimación del riesgo sistémico, ver [Kou et al. \(2019\)](#).

en el mismo mercado, Forte (2020) analiza sus principales características topológicas y el efecto que tiene la posición de los bancos en el mercado sobre la tasa de interés interbancaria. El trabajo de Elosegui y Montes-Rojas (2020) es el primero en analizar el mercado REPO de Argentina. Los autores analizan el efecto de medidas de centralidad locales y globales en los diferenciales de tasa de interés en los mercados interbancarios CALL y REPO, para los que encuentran efectos heterogéneos. Finalmente, Elosegui *et al.* (2022) analizan las estructuras topológicas de los mercados interbancarios y encuentran evidencia de la existencia de fragmentación al interior del mercado REPO.

La principal contribución del presente trabajo a esta línea de investigación es el análisis del riesgo sistémico y sus determinantes en el mercado interbancario argentino. El objetivo es evaluar el papel que desempeñan tanto las características topológicas como no topológicas (es decir, financieras) de las instituciones financieras como determinantes del riesgo sistémico en el mercado interbancario argentino. En particular, se estudian dos mercados interbancarios: el no garantizado (CALL) y el garantizado (REPO). Calculamos la relevancia sistémica de las instituciones en el mercado bajo análisis a través de la metodología *Differential DebtRank* (Bardoscia *et al.*, 2015), siendo el shock inicial representado mediante pérdidas de capital en una fracción dada para cada institución individual. Simulamos diferentes pérdidas iniciales y analizamos la importancia de las características financieras y topológicas o estructurales para explicar los efectos negativos en el capital resultantes del contagio derivado del evento desencadenante. Analizamos el impacto sistémico, lo que nos permite evaluar la capacidad de contagio de las instituciones, y la vulnerabilidad sistémica, lo que nos permite evaluar la probabilidad de que una institución sea el objetivo de pérdidas iniciadas en otra institución de la red interbancaria. Para el estudio de los determinantes, aplicamos tres modelos de aprendizaje automático: AdaBoost, XGBoost y Random Forest. Esta estrategia tiene la ventaja de poder incorporar la no linealidad de las relaciones entre las variables, una característica clave dada la naturaleza del fenómeno estudiado (Battiston *et al.*, 2012b; IMF *et al.*, 2009).

Podemos clasificar las variables explicativas consideradas en dos grupos: (1) variables financieras y (2) variables topológicas. En este último grupo, incluimos medidas estáticas de centralidad de un nodo en la red interbancaria: grado, coeficiente de agrupamiento, centralidad de cercanía, centralidad de intermediación y PageRank ponderado. En cuanto a las variables financieras, incorporamos la siguiente información que la literatura ha encontrado como relevante y que está disponible en nuestra base de datos: activos totales, patrimonio neto, rentabilidad sobre el capital, nivel de apalancamiento, ratio de activos interbancarios sobre patrimonio y ratio de pasivos interbancarios sobre patrimonio.

Los resultados del trabajo se pueden resumir en lo siguiente. En primer lugar, encontramos que la relevancia de los distintos factores en el impulso del riesgo sistémico varía de acuerdo al tamaño del shock inicial y de si es el impacto o la vulnerabilidad sistémica la dimensión del riesgo bajo análisis. Respecto de los tipos de características que más contribuyen a predecir el

impacto y la vulnerabilidad sistémica, en ambos mercados las características topológicas (de manera agregada) son las más importantes para explicar el impacto sistémico, mientras que las financieras son las que tienen mayor peso como impulsoras de la vulnerabilidad sistémica. En ambos casos, el peso de las mismas crece con el tamaño del shock inicial. No obstante, se encontraron ciertas diferencias en los principales impulsores del riesgo sistémico en los mercados garantizado y no garantizado. En particular, la estructura de interconexiones entre los bancos parece ser más relevante para explicar el riesgo (en sus dos dimensiones) en el mercado REPO respecto del CALL.

En cuanto a las variables que individualmente son más significativas en el impulso de las dimensiones de riesgo sistémico bajo análisis, el PageRank se destaca como la característica más importante en la generación de impacto sistémico, resultado que se mantiene en ambos mercados. El peso de esta variable aumenta a medida que se consideran tamaños de shock inicial más altos. Estos resultados indican que si un shock impacta a una entidad con un alto PageRank se propagará a través de un gran número de instituciones financieras, causando pérdidas en todo el sistema. Respecto a la vulnerabilidad sistémica, el factor más importante es la relación entre activos interbancarios y patrimonio neto, y su relevancia también crece con el tamaño del shock inicial.

La contribución de este trabajo a la literatura es doble. En primer lugar, analizamos los determinantes del riesgo sistémico en el mercado interbancario argentino, lo cual no ha sido explorado previamente en la literatura y suma nueva evidencia acerca de los impulsores de este fenómeno en mercados financieros de economías no desarrolladas. El caso de Argentina es particularmente relevante porque se trata del país que ha experimentado el mayor número de crisis bancarias sistémicas en el mundo en los últimos 50 años (Laeven y Valencia, 2020; Nguyen *et al.*, 2022). El análisis realizado considera distintos tamaños de shock inicial, lo cual es relevante dada la naturaleza del fenómeno estudiado (Acemoglu *et al.*, 2015b). Asimismo, se incluyen dos dimensiones del riesgo sistémico; es decir, analizamos no solo aquellos factores que impulsan la capacidad de una institución financiera de propagar pérdidas, sino también la probabilidad de cada una de ellas de ser receptora de las pérdidas iniciadas por otra institución en la red.

La segunda contribución se relaciona con la aplicación de modelos de aprendizaje automático al estudio de los determinantes del riesgo sistémico en mercados financieros. El uso de estos modelos para la identificación de las entidades sistémicamente más importantes y sus determinantes es relativamente reciente en la literatura. En los últimos años se han desarrollado metodologías que combinan el enfoque de redes con técnicas de aprendizaje automático para analizar el riesgo sistémico, en particular, como medidas que permiten identificar a las unidades financieras más importantes en términos sistémicos⁵¹. Respecto a la aplicación de técnicas de aprendizaje

⁵¹Kou *et al.* (2019) proveen una revisión de la literatura sobre las investigaciones y metodologías existentes para la medición del riesgo sistémico en mercados financieros, incluyendo la integración de técnicas de aprendizaje automático. Más recientemente, Liu y Pun (2022) evalúan el potencial de la integración de algoritmos de aprendizaje automático para mejorar las medidas de riesgo sistémico existentes en la literatura.

automático para la identificación de los determinantes del riesgo sistémico, podemos mencionar al trabajo de [Alexandre *et al.* \(2021\)](#), quienes evalúan el impacto de variables financieras y topológicas en el riesgo sistémico del mercado interbancario brasileiro. Tal como mencionamos previamente, las redes dan forma a relaciones financieras complejas entre las instituciones que forman parte de los distintos mercados. En este sentido, los modelos no lineales permiten mejorar la calidad de las estimaciones, respecto de los modelos microeconómicos que utilizan modelos lineales como mínimos cuadrados ordinarios o efectos fijos de panel, ampliamente utilizados en el estudio de los determinantes del riesgo sistémico.

El capítulo se organiza de la siguiente manera. La sección 3.2 revisa las principales contribuciones sobre los determinantes del riesgo sistémico en mercados financieros. En la sección 3.3 se resumen las principales características de los mercados interbancarios argentinos, CALL y REPO. En la sección 3.4 se describen el conjunto de datos utilizados y el abordaje empírico empleado. En específico, la sección 3.4.1 presenta las características de la red interbancaria construida; la sección 3.4.2 describe a las variables consideradas en este trabajo como potenciales determinantes del riesgo sistémico; la sección 3.4.3 presenta la estimación de las medidas de riesgo sistémico y, finalmente, la sección 3.4.4 describe los modelos aplicados. Luego, la sección 3.5 presenta y analiza los principales resultados encontrados. Por último, la sección 3.6 concluye.

3.2 Los determinantes del riesgo sistémico en mercados financieros: revisión de la literatura

Los mercados financieros pueden volverse inestables debido a la inestabilidad de sus participantes, es decir, las instituciones financieras. Eventos exógenos y disruptivos pueden propagarse a lo largo del mercado y dar lugar a importantes shocks macroeconómicos adversos. Las actividades propias de las instituciones, como su función intermediarios financieros y sus conexiones con la economía real, contribuyen desfavorablemente a la propagación de dificultades, no solo en el mismo mercado sino también al resto de la economía. En este sentido, es importante identificar los factores que impulsan el riesgo sistémico.

Si bien se destacan variables similares desde los dos enfoques mencionados en la sección 3.1, los factores señalados como impulsores del riesgo sistémico de las entidades financieras dependen en cierta medida de la forma en la que se mida el fenómeno. En líneas generales, los estudios que se basan en el enfoque de mercado destacan al tamaño de los activos de los bancos, el capital de los bancos, la participación en actividades bancarias no tradicionales, el grado de apalancamiento, el grado de liquidez y el índice de morosidad (ver, por ejemplo, [Weiß *et al.*, 2014](#); [De Jonghe, 2010](#); [Brunnermeier *et al.*, 2020](#)). Asimismo, señalan que los determinantes del riesgo sistémico específicos de cada banco suelen ser exclusivos de cada crisis y dependen de las características del régimen regulatorio ([Weiß *et al.*, 2014](#)).

Desde el enfoque de red, se destacan como principales impulsores del riesgo sistémico a la topología de la red de exposiciones, las reservas de capital, la liquidez del mercado y la naturaleza de los shocks (ver, por ejemplo, [Gai y Kapadia, 2010](#); [Haldane y May, 2011](#); [Loepfe et al., 2013](#); [Roukny et al., 2013](#)). Respecto al capital de los bancos, valores suficientemente altos protegen a las redes por lo demás frágiles de los riesgos de contagio, mientras que valores suficientemente bajos no logran prevenir el contagio incluso en redes robustas. Las reservas de capital son, por lo tanto, una barrera contra las pérdidas inesperadas y deberían tener intuitivamente una relación inversa con los niveles de riesgo sistémico. El impacto de la topología de la red suele ser objeto más bien de investigaciones teóricas que resaltan características específicas de esta topología. Por ejemplo, la relativa completitud de la red puede contribuir a la diversificación del riesgo ([Acemoglu et al., 2015b](#); [Allen y Gale, 2000](#)), o facilitar la propagación en presencia de mecanismos de amplificación como las ventas forzadas de activos y las retiradas de depósitos ([Battiston et al., 2012a](#)).

En la actualidad, existen dos puntos ampliamente aceptados en la literatura con respecto al efecto de las interconexiones en el riesgo sistémico. En primer lugar, la relación entre interconexión y riesgo sistémico no es lineal. Algunos estudios argumentan que el efecto de la propagación de shocks domina en redes con bajo grado de conectividad, mientras que el efecto de la absorción de shocks domina para una conectividad mayor que un nivel umbral determinado ([Gai y Kapadia, 2010](#)). De esta manera, la relación entre interconexión y riesgo sistémico adquiere la forma de “U” invertida. Por otro lado, la literatura destaca la importancia de otros factores que afectan la relación entre el riesgo sistémico y las interconexiones. Uno de los más señalados es la heterogeneidad que se considera una fuente de inestabilidad y tiene lugar en muchas dimensiones, como el tamaño de los agentes, el grado de conectividad, la probabilidad de incumplimiento, el grado de apalancamiento y el nivel de liquidez ([Iori et al., 2006](#); [Caccioli et al., 2012](#); [Amini et al., 2016](#); [Alexandre et al., 2021](#)). Otro elemento clave es el tamaño del shock inicial. Como muestran [Acemoglu et al. \(2015b\)](#), el aumento de la interconexión tiene un impacto negativo (positivo) en el riesgo sistémico bajo shocks negativos lo suficientemente pequeños (grandes). Por último, hay un conjunto de contribuciones que señalan que algunas suposiciones simplificadoras introducidas en los modelos sobre el riesgo sistémico interfieren en la relación entre los dos fenómenos en cuestión, como puede ser la ausencia de “comportamiento incorrecto” de los agentes ([Brusco y Castiglionesi, 2007](#)) y la existencia de información perfecta ([Battiston et al., 2012a](#)).

Respecto a los principales impulsores del riesgo sistémico en mercados financieros en distintos países del mundo, se ha encontrado una amplia heterogeneidad. En lo que refiere a países con mercados financieros desarrollados, [Boss et al. \(2006\)](#) analizan la dependencia de activos en el sistema bancario de Austria a partir de datos del Registro de Préstamos Principales y combinando la gestión de riesgos estándar con un modelo de red. Encuentran que las exposiciones entre los bancos contribuyen significativamente a incrementar el riesgo sistémico. [Brunnermeier et al. \(2020\)](#) investigan los determinantes de las contribuciones de los bancos de Estados Unidos al riesgo sistémico en el período 1986-2008 y encuentran un efecto desestabilizador de las actividades no crediticias de los bancos en la estabilidad financiera. Centrándose en el mismo mercado,

Hovakimian *et al.* (2012) analizan datos trimestrales de los bancos en el período 1974-2010 e identifican el tamaño del banco, el apalancamiento y el riesgo de activos como determinantes significativos del riesgo sistémico. Finalmente, Weiß *et al.* (2014) estudian los factores que determinan la contribución de los bancos internacionales –con una predominancia en la muestra de entidades estadounidenses y europeas– a los riesgos sistémicos tanto locales como globales, durante episodios de crisis, utilizando la medida MES. A contramano de gran parte de los estudios previos al mismo, no encuentran evidencia empírica respecto de que el tamaño del banco, el apalancamiento, los ingresos no derivados de intereses o la calidad de la cartera de crédito del banco sean determinantes persistentes del riesgo sistémico durante episodios de crisis. Por el contrario, los resultados encontrados por los autores muestran que el riesgo sistémico global en particular está impulsado predominantemente por características del régimen regulatorio.

En lo que hace a estudios en economías no desarrolladas, Foggitt *et al.* (2017) analizan el mercado interbancario sudafricano y evalúan los determinantes del riesgo sistémico –aproximado mediante el indicador SRISK– utilizando un modelo de regresión de panel. Los resultados muestran que el tamaño de los bancos es uno de los factores más importantes en el impulso del riesgo sistémico. Respecto a las condiciones macroeconómicas, encuentran que son más relevantes las condiciones de economías externas (Estados Unidos y Europa) que las mismas condiciones del país bajo análisis. Narayan *et al.* (2023), analizan los factores que impulsan el riesgo sistémico en las instituciones financieras de la India a partir de regresiones de datos de panel. Los autores encuentran que la probabilidad de incumplimiento, el apalancamiento, el préstamo, la liquidez, el tamaño del directorio y las normas de Basilea son factores relevantes para la determinación del riesgo sistémico. Por otro lado, Fang *et al.* (2018) analizan los determinantes del riesgo sistémico en el mercado interbancario chino empleando modelos *Least Absolute Shrinkage and Selection Operator* (LASSO). Los resultados destacan a las interconexiones, que los autores llaman efecto contagio o derrame, como el principal impulsor del riesgo sistémico. Asimismo, encuentran evidencia sobre un efecto menor en el riesgo sistémico de variables relacionadas al contexto macroeconómico y las características de las instituciones financieras.

Respecto a contribuciones que analizan los determinantes del riesgo sistémico en mercados financieros de países de América Latina, Arias *et al.* (2010) analizan el mercado financiero colombiano y encuentran que el tipo de institución financiera es relevante en la determinación del riesgo sistémico. Específicamente, muestran que las corporaciones financieras y las cooperativas financieras contribuyen son las mayores contribuyentes al riesgo sistémico. En un estudio similar para el caso de Brasil, Tabak *et al.* (2013) muestran que el impacto de las 5 principales instituciones financieras en la inestabilidad es aproximadamente el 50% del impacto de todas las instituciones. También para el sector bancario brasileño 2006-2012, Araújo y Leao (2013) encuentran que las instituciones financieras grandes (en términos de activos totales) tienen exposiciones de riesgo individual más bajas, pero plantean riesgos sistémicos más altos. No obstante, también señalan que algunas instituciones más pequeñas son igualmente relevantes en términos sistémicos, mientras que las instituciones públicas son menos importantes. Desde un enfoque de redes, Martínez-Jaramillo

et al. (2010) analizan el riesgo sistémico en el sistema interbancario mexicano, a partir de una medida de riesgo para todo el sistema que se puede descomponer en “impactos base” y “efectos producto del contagio”. Los resultados muestran que la distribución de los shocks podría ser más importante que la topología del sistema en un momento dado. Las simulaciones realizadas proveen evidencia de que incluso con tenencias altamente correlacionadas, los bancos pueden enfrentar un bajo riesgo de un evento sistémico. Para el caso de Colombia, León *et al.* (2011) encuentran resultados un diferentes, ya que enfatizan la importancia de la estructura de interconexiones para explicar el riesgo sistémico, seguida del tamaño de las entidades. Asimismo, encuentran que las instituciones financieras no bancarias también representan un alto riesgo sistémico. Varios de estos estudios encuentran que los determinantes macroeconómicos explican una gran parte del riesgo sistémico de las instituciones financieras individuales en países latinoamericanos (Arias *et al.*, 2010; León *et al.*, 2011, y también Weiß *et al.* (2014) para los países de América Latina incorporados en su muestra).

Finalmente, el antecedente más estrechamente relacionado al presente estudio, es la contribución de Alexandre *et al.* (2021) quienes analizan los determinantes del riesgo sistémico en el mercado interbancario brasilero entre marzo de 2012 y diciembre de 2015 con frecuencia trimestral. Siguen un enfoque de red y, a nuestro conocimiento, constituye el único antecedente que aplica modelos de aprendizaje automático para la identificación de los determinantes del riesgo sistémico⁵². Los autores encuentran que en el mercado brasilero, los factores determinantes del fenómeno en cuestion dependen del tipo de entidad del que se trate. En particular, encuentran que en las cooperativas de crédito la importancia de las características financieras de las instituciones en su conjunto, son las variables más relevantes para explicar el riesgo sistémico, mientras que para los bancos, las medidas de centralidad tienen mayor peso a la hora de predecir el impacto sistémico de los mismos. Asimismo, estos resultados dependen del tamaño del shock inicial: en ambos casos, el principal conjunto de características aumenta su importancia a medida que el tamaño del shock crece.

En este trabajo, adoptamos una estrategia similar a Alexandre *et al.* (2021) y aportamos nueva evidencia acerca de los determinantes del riesgo sistémico en un país latinoamericano, con un sistema financiero basado en bancos, donde los mismos son las instituciones financieras más importantes del sistema y representan la mayor parte de los activos financieros del país. Como destacan Narayan *et al.* (2023), en este tipo de sistemas las características mismas de las instituciones financieras y sus vínculos con el resto de la economía, las vuelven vulnerables a shocks o situaciones de estrés, y su dificultad puede tener efectos significativos para la economía en su conjunto. Esto motiva el análisis de los determinantes del riesgo sistémico en las instituciones financieras de Argentina, como se desarrolla en las siguientes secciones.

⁵²No obstante, como se mencionó previamente, no se trata del primero en integrar la literatura de riesgo sistémico con modelos o técnicas de aprendizaje automático. Ver, por ejemplo, Kou *et al.* (2019).

3.3 Los mercados interbancarios argentinos

Estudiamos el riesgo sistémico en los mercados CALL y REPO el período 2015-2018. Antes de describir más en detalle las características de estos mercados, presentamos algunas características de la economía argentina en el período bajo análisis, relevantes en la dinámica de los mercados financieros.

En primer lugar, cabe mencionar que el período analizado incluye un ciclo económico completo: Argentina atravesó un episodio recesivo 2016, una posterior recuperación con crecimiento económico moderado en 2017 y, luego, nuevamente una caída interanual en el PBI per cápita en 2018. Es importante considerar que a partir de 2016, Argentina tuvo un cambio de gobierno que implicó un giro significativo en las políticas económicas. Durante el primer año de este período (2015) prevalecieron controles tanto sobre las tasas de interés bancarias como al flujo de capitales. A partir de 2016, se liberalizaron ambos controles y comenzó a implementarse una estrategia de metas de inflación. En este marco, se utilizó la tasa de interés de referencia como instrumento de política monetaria. Finalmente, desde octubre de 2018, este esquema se reemplazó por una política monetaria de control de la base monetaria. Estos cambios afectaron la volatilidad de indicadores clave, como el tipo de cambio, las tasas de interés y la inflación.

En este contexto, Argentina atravesó dos crisis cambiarias, una al inicio del período en 2015-2016 y otra en 2018. En lo que refiere al primer período aludido, el peso argentino se devaluó significativamente frente al dólar estadounidense. El tipo de cambio oficial pasó de 13 pesos por dólar en diciembre de 2015 a 20 pesos por dólar en mayo de 2016. La inflación interanual pasó del 24,8% en diciembre de 2015 al 40,7% en mayo de 2016 y el índice de riesgo país de Argentina se disparó a niveles récord. Estos factores llevaron a una escasez de divisas en el mercado argentino, lo que provocó un aumento de las tasas de interés interbancarias (ver, por ejemplo, [Elosegui et al., 2022](#)). En abril de 2018, coincidente con la decisión de los prestamistas internacionales privados de no otorgar un nuevo financiamiento al gobierno argentino, el peso se devaluó un 16%, lo que significó un importante aumento en el ritmo de suba respecto de los meses previos⁵³. Esta situación tuvo efectos diversos en la economía, entre los que se encuentran el comienzo de varias intervenciones de reservas del Banco Central de la República Argentina (BCRA) al tipo de cambio para mantener estable a la moneda local y un acuerdo de financiamiento con el Fondo Monetario Internacional ([Hernán Zeolla y Médici, 2022](#)). El efecto sobre el mercado interbancario fue una caída en los montos operados y aun aumento significativo en la tasa de interés interbancaria, que alcanzó los mayores niveles del período analizado en octubre de 2018 (ver gráfico 3.2).

En síntesis durante el período bajo análisis, Argentina experimentó una serie de shocks económicos y financieros que tuvieron un impacto significativo en los mercados interbancarios, como la crisis de deuda soberana y la devaluación del peso.

⁵³En este año el peso argentino se devaluó un 50% frente al dólar.

A continuación, se describen las principales características de los mercados interbancarios CALL y REPO y la evolución de algunas variables relevantes, como las tasas de interés promedio y los montos operados, en el período bajo análisis.

3.3.1 Los mercados CALL y REPO en el período 2015-2018

En Argentina, el mercado interbancario se compone de dos segmentos: el mercado REPO, que es garantizado y donde interviene el BCRA, y el conocido como mercado CALL, que carece de garantías. El modo de participación del BCRA en el REPO es a través de operaciones de pase, especialmente a través de pases pasivos (llamados Reverse Repos) y, menos usual, de pases activos (llamados Repos)⁵⁴ y con operaciones de mercado abierto (usualmente no sistemáticas). Si bien el BCRA participa de manera directa solo en el mercado REPO, desde el 2002 emite sus propios títulos de deuda mediante los cuales puede absorber o proporcionar liquidez a los mercados financieros, y afectar así las tasas de interés y las condiciones monetarias de la economía⁵⁵.

Estos mercados difieren en su microestructura, en la tecnología que utilizan en sus operaciones y en las reglas de operación (Elosegui y Montes-Rojas, 2020). El mercado CALL funciona como un mercado *over-the-counter* (OTC), sin garantías, en el que los bancos pueden realizar transacciones de manera informal de forma bilateral. Como consecuencia de la interacción sistemática entre las mismas entidades, se generan relaciones directas y de largo plazo (Anastasi *et al.*, 2010). Las operaciones bilaterales se compensan a través del sistema Medio Electrónico de Pagos (MEP)⁵⁶, y no tienen riesgo de compensación. Las operaciones se concentran en préstamos a un día, con un número reducido de transacciones que vencen en más de tres días (generalmente en lo que hace a los fines de semana o feriados extendidos). Gran parte de los bancos que operan en el país participan en este mercado, incluso los de menor tamaño. Algunos de ellos, especialmente en el caso de estos últimos, solo tienen acceso al mercado CALL. Como se mencionó anteriormente, el BCRA no opera en el segmento sin garantía. La tasa promedio ponderada del mercado, conocida como tasa CALL, se publica en el BCRA y es una tasa de referencia tradicional para el mercado financiero (Elosegui *et al.*, 2022).

Por su parte, en el REPO el flujo de fondos está garantizado por un título subyacente, puesto como garantía en la transacción. Se trata de un mercado donde las transacciones tienen lugar de manera descentralizada en una plataforma electrónica ciega (SIOPEL, Sistema de operaciones electrónicas), lo que deja menos espacio para generar interacciones continuas⁵⁷. Las operaciones

⁵⁴Los pases activos son aquellos mediante los cuales el BCRA otorga préstamos a los bancos, mientras que en los pases pasivos se trata de liquidez que los bancos comerciales depositan en el BCRA.

⁵⁵El BCRA comenzó a emitir sus propios títulos de deuda a corto y mediano plazo en el año 2002: las Letras del Banco Central (LEBAC) y las Notas del Banco Central (NOBAC). Las LEBAC fueron utilizadas para la implementación de la política monetaria durante casi la totalidad del período bajo análisis. El BCRA inició un programa de cancelación de LEBAC hacia mediados de agosto de 2018, las cuales reemplazó por NOBAC a un año y Letras de Liquidez (LELIQ) a 7 días para en el caso de las entidades bancarias, por el total del vencimiento. Las LELIQ pueden ser adquiridas únicamente por entidades bancarias, a diferencia de las LEBAC. El proceso de retiro del mercado de las LEBAC finalizó en diciembre del 2018, último período bajo análisis.

⁵⁶El MEP es una plataforma de Liquidación Bruta en Tiempo Real.

⁵⁷La plataforma es anónima y bilateral, con todas las posiciones visibles para los participantes.

se realizan a través del Mercado Abierto Electrónico (MAE)⁵⁸, del cual es necesario ser agente o adherente para poder operar. Se trata de un sistema de orden sin acuerdos de creación de mercado. No existe una contraparte central de compensación a través de la cual se liquidan las operaciones, sino que cada participante establece límites a las contrapartes. No obstante, el riesgo crediticio está limitado por el uso de garantías y recortes. El sistema es libre de riesgo de compensación, ya que existe una validación en línea de los límites de cartera para cada transacción entre partes. Por último, como se mencionó previamente el BCRA participa activamente en este mercado.

En último período bajo análisis (diciembre de 2018), se encuentran activos en el sistema bancario argentino un total de 78 entidades activas, lo que incluye 13 bancos públicos, 50 bancos privados 15 y compañías financieras no bancarias. Se observa una importante concentración en torno a un pequeño grupo de entidades: los cinco bancos principales del sistema explican el 50% del crédito total otorgado. La gran mayoría de los bancos activos en el sistema, participa de los mercados interbancarios, 71 en el CALL y 52 en el REPO.


Respecto al tamaño de estos mercados, tomando en cuenta las transacciones con el BCRA en operaciones de pase en el mercado REPO, el volumen operado (como porcentaje del total de depósitos) es significativamente mayor en el caso del mercado garantizado (ver figura 3.1). Esto se explica centralmente por las operaciones de pase pasivo, ya que esta ventanilla es utilizada por los bancos para depositar la liquidez remanente al final del día (ver [Elosegui y Montes-Rojas, 2020](#)), mientras que las operaciones de pases activos son poco significativas, ya que la participación en estas operaciones por parte de los bancos es interpretada en el mercado como una mala señal ([Elosegui y Montes-Rojas, 2020](#)). No obstante, como se observa en la figura 3.1, al considerar solo las operaciones entre bancos, el volumen sigue siendo más importante en el mercado REPO respecto del CALL en el período bajo análisis. Asimismo, el número de bancos que participan en el mercado REPO es usualmente menor que el número de bancos que participan en el mercado CALL, ya que este último mantiene menores barreras a la entrada. A pesar de ello, se observa generalmente un mayor número de transacciones en el mercado REPO.

Respecto a las tasas de interés interbancarias, vale la pena evaluar su evolución en conjunto con la tasa de política monetaria. Como se observa en la figura 3.2, las tasas REPO y reverse REPO de transacciones con el BCRA definen un corredor de tasas de interés, dentro del cual se posicionan generalmente las tasas interbancarias CALL y REPO. No obstante, en algunos episodios durante el período bajo análisis, las tasas de interés interbancarias superaron los límites de este corredor. Finalmente, cabe señalar que la tasa de interés del mercado REPO es generalmente menor a la correspondiente al mercado CALL, debido centralmente a la naturaleza garantizada de sus transacciones.

Por último, respecto a los activos más utilizados como garantía en las transacciones que tienen lugar en el mercado REPO, son bonos del tesoro y valores del BCRA. Como se puede observar

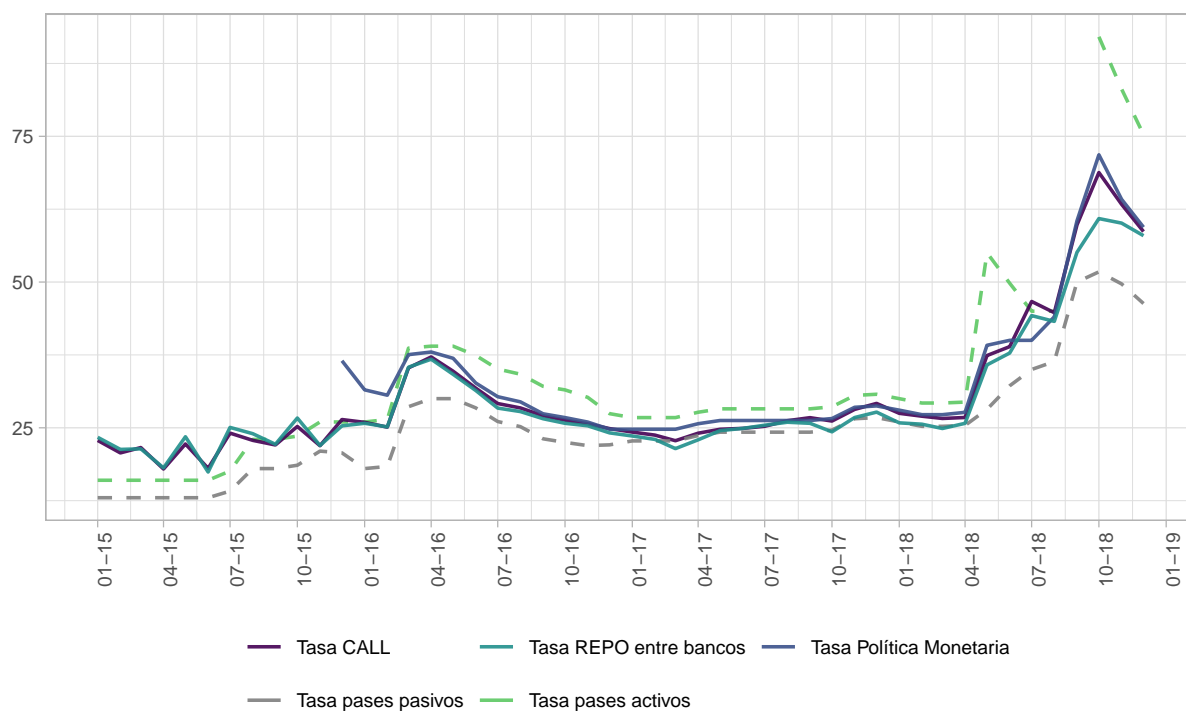
⁵⁸El MAE es el principal mercado electrónico para la negociación de valores, moneda extranjera y repos en Argentina.

Figura 3.1: Montos mensuales operados en los mercados CALL y REPO. Enero 2015-Diciembre 2018. Miles de millones de pesos constantes, a precios de diciembre de 2018.



Fuente: Elaboración con base en BCRA

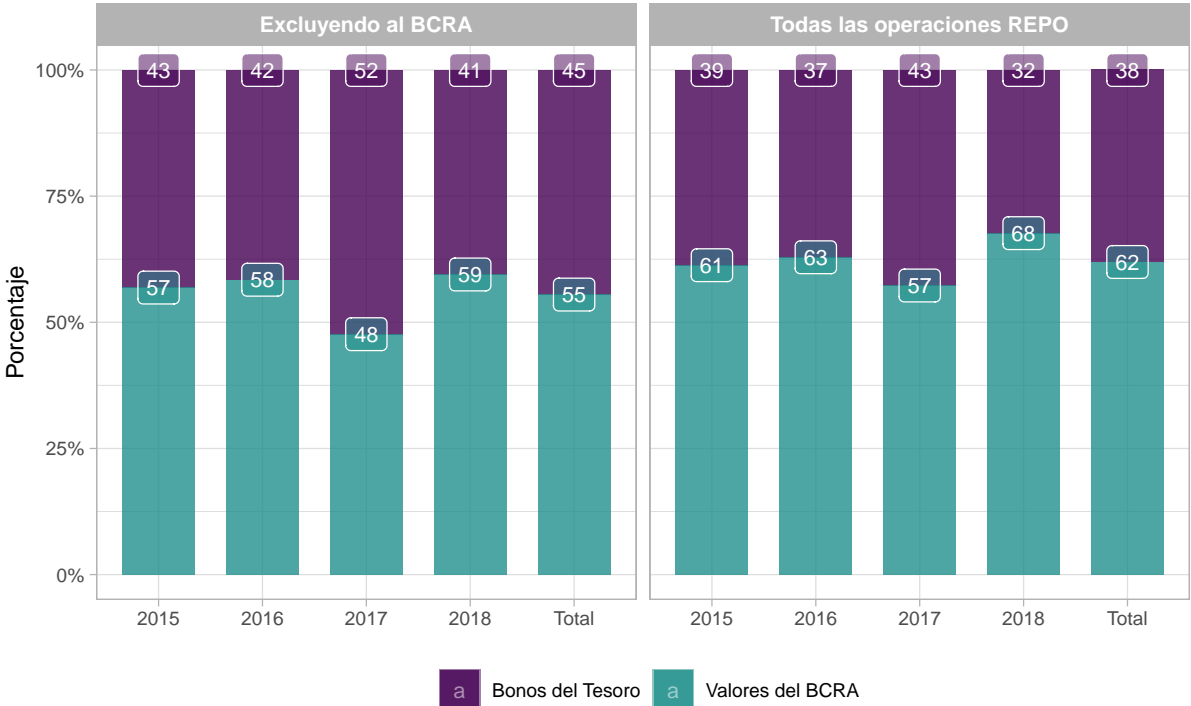
Figura 3.2: Tasas de interés interbancarias y tasa de política monetaria. Enero 2015 - Diciembre 2018.



Fuente: Elaboración con base en BCRA.

en la figura 3.3, el 38% de las operaciones del mercado REPO tenían bonos del Tesoro como colateral, y el 62% restante utilizaba valores del BCRA. No obstante, vale señalar que el BCRA participó en el 14.5% de las transacciones y en la gran mayoría de sus intervenciones utilizó sus propios valores como garantía. Si no se consideran las operaciones con el BCRA la participación de los bonos del Tesoro como colateral sube al 45%, por lo que siguen predominando los valores del BCRA. La predominancia de los valores del Banco Central como el principal instrumento de política monetaria es común en mercados emergentes con mercados locales de deuda poco desarrollados, aunque cabe mencionar que no es la práctica estándar a nivel internacional. En Argentina específicamente, estos valores constituyen una herramienta importante utilizada por los bancos para gestionar sus niveles de liquidez. En el caso de los bonos del Tesoro, se persiguen otros objetivos al negociar con ellos en los mercados interbancarios, como operaciones de arbitraje o para aprovechar oportunidades de *carry trade*. Por lo tanto, casi la mitad de las transacciones entre bancos del mercado REPO se realizan con fines diferentes a la administración de liquidez. Y esta diferencia en los objetivos perseguidos, se traslada a las tasas de interés: las tasas bilaterales de las operaciones respaldadas por bonos del Tesoro tienden a ser, en promedio, más bajas que las transacciones respaldadas por valores del Banco Central, las cuales están más concentradas alrededor de la tasa de interés media (Elosegui *et al.*, 2022).

Figura 3.3: Porcentaje de las operaciones respaldadas con cada tipo de colateral. 2015-2018.



Fuente: Elaboración con base en BCRA.

En síntesis, gran parte de los bancos participan en ambos mercados de manera simultánea con el objetivo de administrar diariamente su liquidez y activos de inversión, aunque también hay bancos que persiguen otros objetivos, como operaciones de arbitraje. La estructura de red resultante de las interacciones bancarias en ambos mercados puede impactar en las condiciones de acceso a la

liquidez. En este sentido, desde el punto de vista del riesgo sistémico, el análisis de estos dos mercados es relevante: en el caso del mercado CALL por los riesgos asociados a la ausencia de garantías⁵⁹, y en el caso del mercado REPO, por la exposición a posibles shocks de liquidez o caída en el valor de los activos de garantía, elementos no menores en países periféricos y, en particular, en Argentina (Elosegui y Montes-Rojas, 2020). Por lo tanto, ambos mercados conforman una red de relaciones entre entidades capaz de amplificar riesgos y afectar la estabilidad financiera. Es decir, cuando hablamos de riesgo sistémico no nos referimos a inestabilidad financiera que se origina exclusivamente por eventos que tienen inicio en estos mercados, sino que los mismos son relevantes en términos de la transmisión de shocks, los cuales pueden tener un origen diferente, como hemos mencionado para el caso de Argentina.

Desde el punto de vista de la política económica, la relevancia de estos mercados también se puede ver a través del rol que cumple la tasa de interés interbancaria. La interacción entre los bancos y el BCRA determina tasas de interés de referencia relevantes para la economía (la tasa sin garantía o CALL y la tasa con garantía o REPO), la cual se encuentra en profunda interacción con la tasa de interés de política monetaria de BCRA. La tasa promedio ponderada del mercado, conocida como tasa CALL, se publica en el BCRA y es una tasa de referencia tradicional para el mercado financiero (Elosegui *et al.*, 2022). La política monetaria se transmite a través de la tasa de interés interbancaria a todas las tasas de interés del sistema financiero (tasas de depósito, tasas de préstamo y otras), lo que afecta el nivel de actividad económica y/o la tasa de inflación.

En la siguiente sección, se describen el conjunto de datos y la metodología utilizados en el estudio de los determinantes del riesgo sistémico. A su vez, se describen algunas características adicionales de los mercados bajo análisis, especialmente, aquellas que tienen que ver con la estructura de red.

3.4 Datos y metodología

Nuestro conjunto de datos incluye información de instituciones financieras que participan en el mercado interbancario argentino, tanto en el no garantizado (CALL) como en el garantizado (REPO). En el caso del primero, la información proviene de la base SISCEN del BCRA, que incluye las operaciones diarias netas entre los bancos, prestatario y prestamista, volumen neto, vencimiento, tasa de interés (ponderada) y moneda en la que se realizó la transacción. Respecto al mercado REPO, la información proviene del mercado MAE, e incluye datos del volumen, la especie en garantía (vencimiento y colateral específico), el precio pactado o tasa de interés implícita de cada transacción y la fecha y hora de la misma. También utilizamos información proveniente

⁵⁹La importancia de analizar este mercado desde el punto de vista del riesgo sistémico se mantiene, incluso cuando se trata de relaciones estables entre bancos a lo largo del tiempo, porque las mismas constituyen un canal de transmisión de shocks frente a eventos económicos inesperados, crisis financieras que afecten a múltiples bancos simultáneamente o cambios en las condiciones económicas. El análisis de riesgo sistémico puede ayudar a evaluar cómo el sistema financiero en su conjunto está expuesto a estos eventos y cuál sería su impacto.

de los balances de estas instituciones financieras, datos publicados por el Departamento de Estadísticas Monetarias y Financieras del BCRA. El período cubierto es desde el 1 de enero de 2015 al 31 de diciembre de 2018, con una frecuencia mensual.

El número de instituciones financieras en nuestra base de datos fluctúa mensualmente entre 47 y 69 para el caso del mercado CALL y entre 41 y 52 para el REPO. En el último período (diciembre de 2018), se registran un total de 78 entidades activas en la nómina del BCRA, incluyendo bancos públicos (13), bancos privados (50) y compañías financieras no bancarias (15). La base de datos incluye más de 78 mil transacciones diarias no garantizadas (CALL) y más de 150 mil transacciones diarias garantizadas (REPO). Analizamos por separado los instrumentos financieros no garantizados y garantizados registrados en el BCRA (es decir, los mercados CALL y REPO). El tipo de operaciones registradas son préstamos interbancarios a un día de plazo u *overnight*⁶⁰. En el período bajo análisis las operaciones a un día explicaron el 92% de las transacciones interbancarias en el mercado CALL y el 98% en el REPO. Finalmente, el tamaño total de nuestra muestra es de 2,375 y 3,066, para los mercados REPO y CALL, respectivamente.

3.4.1 Red interbancaria

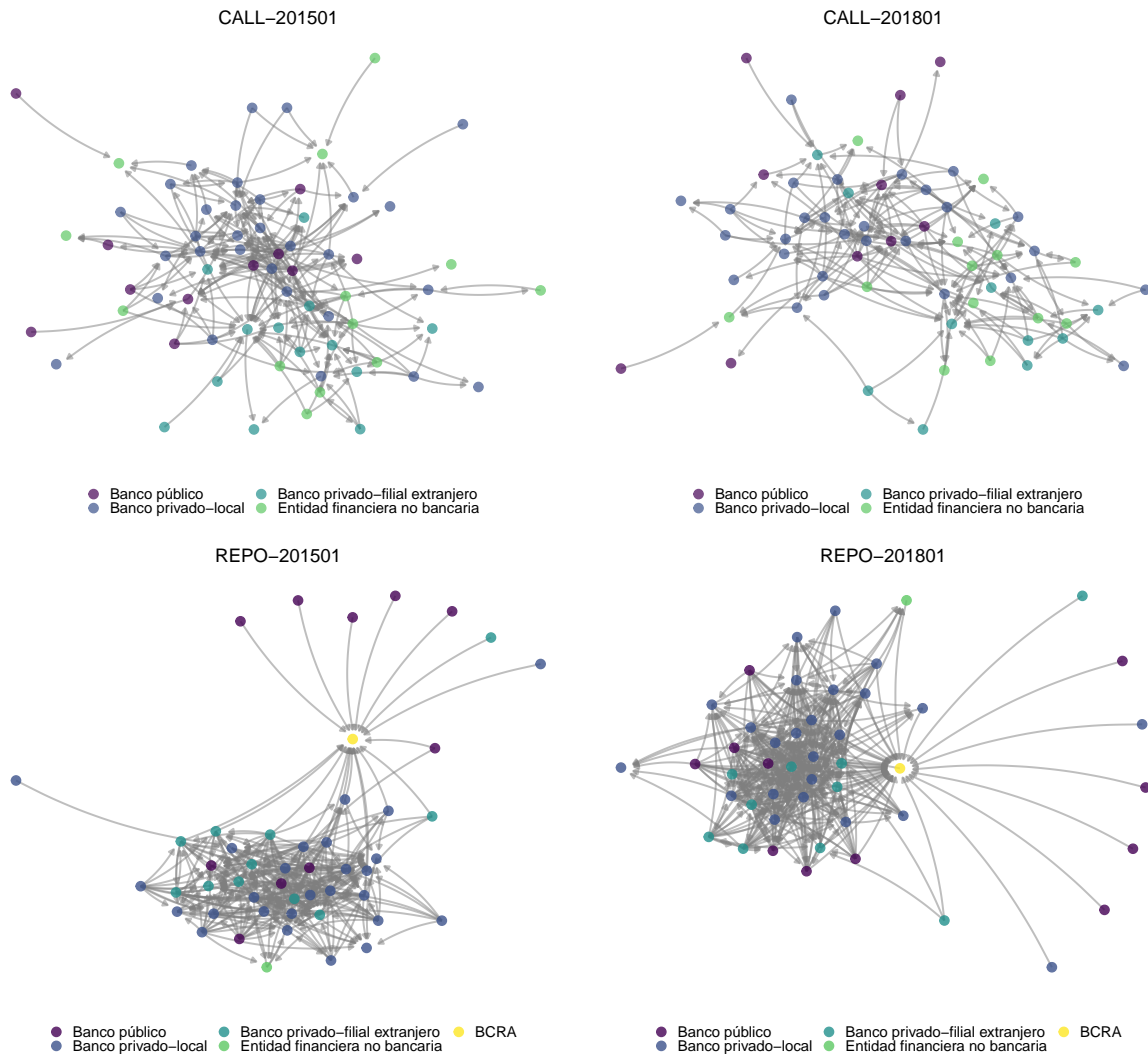
Con la información descrita construimos la red de interacciones cuyos nodos son bancos, compuesta por las exposiciones netas de estas instituciones en el mercado interbancario. Es una red dirigida, porque en cada transacción los bancos toman una posición diferente (prestador y prestatario), y ponderada, porque se pondera por el monto de cada transacción. Los vínculos entrantes (salientes) se refieren a la posición de un banco como prestatario (prestador) en el mercado interbancario. Por lo tanto, un vínculo de peso A_{ij} dirigido desde el nodo i al nodo j corresponde a un préstamo interbancario del banco prestador i al banco prestatario j por un monto de A_{ij} .

Una primera característica a mencionar es que las redes interbancarias CALL y REPO son relativamente pequeñas. Si bien el caso argentino no constituye la red más pequeña estudiada en la literatura, es sustancialmente de menor tamaño que la observada en el caso de Estados Unidos (Bech y Atalay, 2010) o Italia (Kobayashia y Takaguchib, 2017). Como señala Forte (2019), el número de nodos o instituciones financieras no es de los más pequeños, mientras que el número de vínculos si se encuentra un poco más alejado de las redes más voluminosas. La figura 3.4 muestra la estructura de red de los mercados CALL y REPO, para enero de 2015 y 2018, años inicial y final de la muestra. Si bien con el tiempo se observan algunos cambios, la estructura en ambos mercados se mantiene relativamente estable. Por otro lado, se observa en cada mercado (CALL y

⁶⁰Estos préstamos se utilizan para cubrir las necesidades de liquidez a corto plazo de los bancos. Debido a la renovación frecuente de los préstamos, los bancos están continuamente expuestos a riesgos de contraparte en este segmento del mercado interbancario, por lo que una interrupción o estrés adicional en estas transacciones podría propagarse a través del sistema financiero. En este sentido, analizar el riesgo sistémico en préstamos *overnight* proporciona información relevante sobre la estabilidad del sistema financiero y puede ayudar a identificar cómo se propagarían las dificultades financieras en caso de un evento adverso. Asimismo, cabe mencionar que los trabajos presentes en la literatura que analizan la red de transacciones de los mercados interbancarios suelen limitarse a estudiar los préstamos a un día de plazo entre entidades, por lo que focalizar el estudio en este subconjunto de operaciones permite obtener resultados comparables con el resto de la literatura.

REPO) una estructura de red diferente. Las mismas reflejan los resultados descritos por [Elosegui et al. \(2022\)](#), quienes encuentran que en el mercado garantizado las instituciones financieras se encuentran más densamente conectadas que en el no garantizado, a pesar de que la cantidad de participantes sea menor. Asimismo, en el mercado no garantizado las interconexiones exhiben una menor estabilidad, por lo que su estructura muestra mayor volatilidad y vulnerabilidad a shocks negativos.

Figura 3.4: Representación red interbancaria, mercados CALL (panel superior) y REPO (panel inferior), enero de 2015 (izq.) y enero de 2018 (der.).



3.4.2 Variables topológicas y financieras

Teniendo en cuenta las características de la red, calculamos las siguientes medidas de centralidad para cada banco que participa en la red: (1) grado del nodo (entrante y saliente), (2) coeficiente de agrupamiento, (3) centralidad de cercanía (entrante y saliente), (4) centralidad de intermediación

y (5) PageRank ponderado. A continuación se describe brevemente a cada una de ellas⁶¹.


En primer lugar, el grado de un nodo i es el número de conexiones que el mismo tiene con otros nodos de la red, es decir, la cantidad de bancos con la que mantiene un vínculo. Dado que la red interbancaria es dirigida, tenemos el grado de entrada, que es el número de conexiones entrantes (préstamos recibidos, es decir, el número de acreedores), y el grado de salida, que es el número de conexiones salientes (préstamos otorgados, es decir, el número de deudores). El coeficiente de agrupamiento de un nodo es una medida de la densidad de sus conexiones con otros nodos. Un valor alto indica que el banco está conectado a muchos otros bancos. Por su parte, la centralidad de cercanía de un banco es una medida de la distancia promedio entre el banco y todos los demás bancos en el mercado interbancario. Al tratarse de una red dirigida, se puede identificar a la cercanía de entrada (distancia promedio entre el banco y todos los demás bancos acreedores), y la cercanía de salida (distancia promedio entre el banco y todos los demás bancos deudores). La centralidad de intermediación de un nodo es una medida de cuántas rutas cortas pasan a través del mismo. Un nodo con una alta centralidad de intermediación es un nodo a través del cual pasa mucha información. Por último, el PageRank ponderado es una medida de la importancia de un nodo en una red. Se basa en la idea de que los nodos que están vinculados a otros nodos importantes son más importantes que los nodos que no están vinculados.

Además de las medidas de centralidad, seleccionamos un conjunto de variables para representar las condiciones financieras de las instituciones que forman parte de nuestra base de datos. Esta información es proporcionada por el Departamento de Estadísticas Monetarias y Financieras del BCRA. En concreto, consideramos el total de activos, el patrimonio neto, el rendimiento del capital (ROE), el apalancamiento y la relación entre los pasivos y activos interbancarios y el patrimonio.

La figura 3.5 muestra la correlación entre las distintas variables que se explorarán en este trabajo como potenciales determinantes del riesgo sistémico en el mercado interbancario argentino. Como puede observarse, existen correlaciones significativas entre variables topológicas, como por ejemplo entre el grado de entrada y el PageRank en el caso del mercado CALL y el grado de entrada y la centralidad de cercanía, también de entrada, para el caso del mercado REPO. Al mismo tiempo, se observan correlaciones importantes entre variables financieras y también entre variables financieras y topológicas. En el primer caso, podemos mencionar como ejemplo a la relación entre patrimonio y activos totales, cuyo coeficiente de correlación en ambos mercados es igual 1. Para el segundo caso, se observa una correlación alta entre el grado de entrada y los activos interbancarios sobre patrimonio neto.

⁶¹ Hay algunos excelentes libros de texto a los que el/la lector/a que no esté familiarizado/a con los conceptos de redes complejas puede consultar, como por ejemplo, [Barabási \(2016\)](#), [Estrada \(2012\)](#) y [Newman \(2018\)](#).

Figura 3.5: Matriz de correlación entre los potenciales determinantes del riesgo sistémico. Mercados CALL (izq.) y REPO (der.).



3.4.3 Riesgo sistémico


A partir de la red interbancaria descrita en la sección 3.4.1, calculamos los indicadores de riesgo sistémico siguiendo la metodología *Differential DebtRank* propuesta por Bardoscia *et al.* (2015). En el momento $t = 0$ imponemos un shock exógeno en el banco j que afecta negativamente a su patrimonio y lo reduce en una fracción α . En el momento $t = 1$, esto causará una pérdida a sus acreedores –indexados por i – igual a $\mathbf{A}_{ij}\alpha$ y en el siguiente periodo $t = 2$ estos acreedores propagarán su pérdida a sus acreedores, y así sucesivamente.

Por ejemplo, supongamos un red con 5 bancos, como se representa en la figura 3.6. En la representación, las flechas se dirigen desde el banco prestamista hacia el banco prestatario. En $t = 0$ imponemos un shock exógeno en el banco 1 que afecta negativamente a su patrimonio y lo reduce en una fracción α . Luego, en $t = 1$ esto causará una pérdida a sus acreedores porque el banco 1 no va a poder cumplir con sus obligaciones de deuda: estos son los bancos 2, 3 y 5 en nuestro ejemplo de red. En el siguiente período, estos acreedores van a propagar su pérdida a sus acreedores, que son los bancos 2 y 5 para el banco 3, para el banco 5 es el 4 y 2 no tiene acreedores. En el siguiente, tendremos afectados nuevamente al 4 y al 3 y así sucesivamente.

Al final de este proceso, podemos calcular la matriz final de pérdidas de cada banco i después de un shock individual de tamaño α iniciado en el banco j . Este proceso se repite para cada banco j en la red⁶².

⁶²Véase Bardoscia *et al.* (2015) para obtener más detalles sobre la metodología *Differential DebtRank*.

Figura 3.6: Ejemplo de red interbancaria para ilustrar el funcionamiento del algoritmo DebtRank.



Formalmente, la pérdida a la que se ve expuesta la institución financiera i como consecuencia de su vínculo financiero con la entidad j , $P_{ij,t}$, puede representarse como

$$P_{ij,t} = \min \left(A_{ij}, P_{ij,t-1} + \mathbf{A}_{ij} \frac{[P_{j,t-1} - P_{j,t-2}]}{C_j} \right), \quad (3.1)$$

donde $t \geq 0$ representa el período, C_j representa el patrimonio de la entidad financiera j , A_{ij} es el monto del préstamo otorgado por i a j y $P_{j,t-1}$ y $P_{j,t-2}$ son las pérdidas sufridas por i en los dos períodos previos a t . De esta manera, cuando una institución financiera es alcanzada por un shock que provoca una pérdida adicional igual a una fracción α de su patrimonio, generará pérdidas en sus acreedores que dependerá de cuán expuestos están respecto de j ; es decir, del tamaño de los préstamos otorgados a este multiplicado por α . Notar que P_{ij} no puede ser mayor que A_{ij} es decir, que la pérdida impuesta por j a la entidad i no puede superar a las exposiciones que este banco tiene con j . Cuando estos valores se igualan, es decir $P_{ij} = A_{ij}$, j deja de imponer pérdidas a i .

La pérdida total de i en cada período, se corresponde con las exposiciones que dicha entidad tiene con otros bancos que han sufrido una pérdida y, por lo tanto, se la imponen a i . Formalmente, tenemos

$$P_{i,t} = \min \left(C_i, P_{i,t-1} + \sum_j \mathbf{A}_{ij} \frac{[P_{j,t-1} - P_{j,t-2}]}{C_j} \right) \quad (3.2)$$

De manera análoga al caso del vínculo de i con cada banco j , P_i no puede ser mayor que C_i ; es decir, que sus pérdidas no pueden superar a su patrimonio. Cuando estos valores se igualan, es decir, $P_i = C_i$, i deja de propagar pérdidas a otras instituciones financieras.

Respecto al número de períodos en los que la simulación tiene lugar, el sistema converge después de un número $T \gg 1$ lo suficientemente grande. Alcanzado el período $t = T$, se puede computar la matriz de pérdidas mencionada previamente, $\mathbf{P}^{\mathbf{j},\alpha} \in N \times 1$, donde $P_i^{j,\alpha}$ es la pérdida total que sufre la entidad i como consecuencia de un shock negativo sobre el patrimonio de j por una fracción α del mismo.

Cabe mencionar aquí que tanto las posiciones de patrimonio como la red de exposiciones (préstamos interbancarios), se toman como exógenas, por lo que se consideran invariantes en el tiempo. Asimismo, en la metodología *Differential DebtRank* se considera a los diferenciales de estrés, en lugar de los valores absolutos para modelizar la propagación del shock, con el objetivo de evitar la duplicación de efectos.

Con esta información, calculamos las dos métricas de riesgo sistémico: (1) el impacto sistémico y (2) la vulnerabilidad sistémica. El impacto sistémico ($IS_{i,\alpha}$) considera la capacidad de un nodo de provocar pérdidas en otros nodos si el mismo es alcanzado por un shock negativo. Es decir, esta medida permite capturar la influencia ejercida por un nodo en la propagación de impactos en la red y brinda una noción sobre el potencial daño que una institución podría causar a la economía. Formalmente, el impacto sistémico de un banco i puede definirse como

$$IS_{i,\alpha} = \frac{\sum_j [P_j^{i,\alpha} - P_{j,0}^{i,\alpha}]}{\sum_j C_j}, \quad (3.3)$$

donde $P_{j,0}^{i,\alpha} = \alpha C_j$ si $j = i$ y es igual a 0 en cualquier otro caso.

La vulnerabilidad sistémica ($VS_{i,\alpha}$) mide la probabilidad de una institución de ser receptora de pérdidas iniciadas por cualquier otra institución en la red interbancaria. En otras palabras, mide la probabilidad de que eventos negativos aleatorios terminen causando pérdidas a una institución particular. Formalmente, tenemos

$$VS_{i,\alpha} = \frac{1}{N} \sum_j \frac{P_i^{j,\alpha} - P_{i,0}^{j,\alpha}}{C_i} \quad (3.4)$$

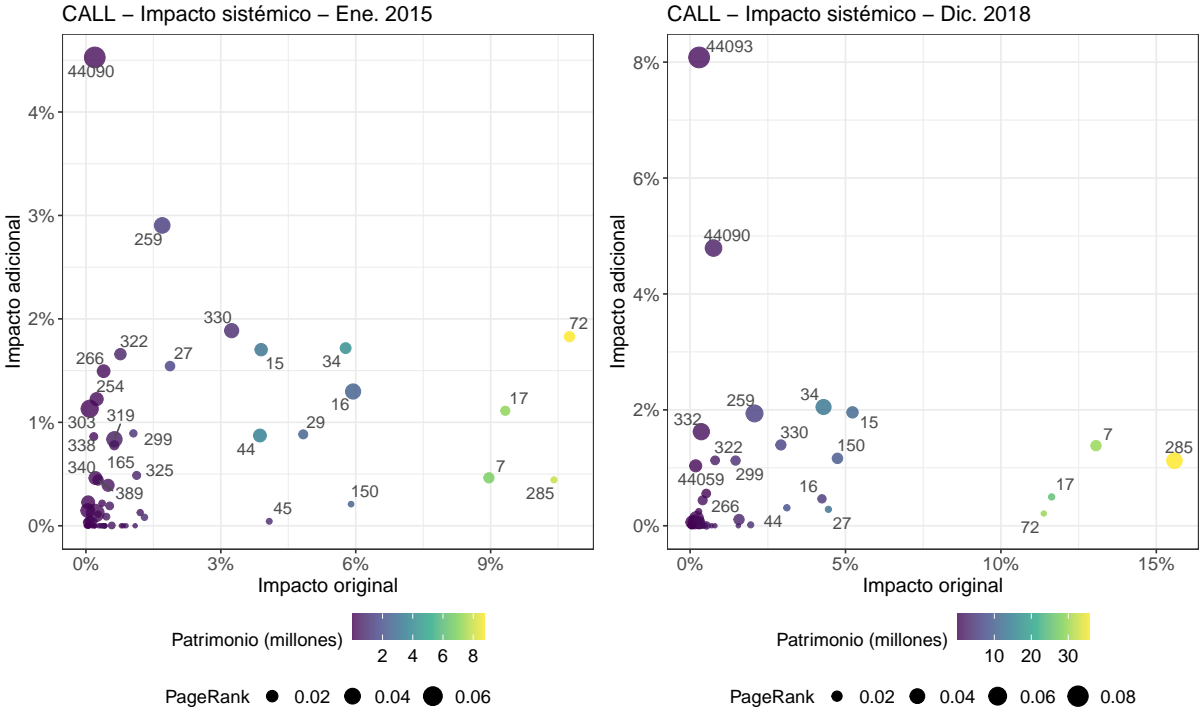
La ecuación (3.4) muestra que $VS_{i,\alpha}$ indica cuál es la fracción del patrimonio agregado de las entidades financieras que se pierde como consecuencia de un shock negativo iniciado en el patrimonio del banco i , en una fracción α del mismo.

Las figuras 3.7 y 3.8 muestran los resultados del cálculo del impacto sistémico para los mercados CALL y REPO, respectivamente, considerando la quiebra de la institución que recibe el shock inicial (es decir, un $\alpha = 1$). El impacto original (eje horizontal) muestra básicamente lo que representa la institución financiera en el sistema, en términos de su tamaño (medido por el patrimonio), mientras que el impacto o estrés adicional (eje vertical) muestra el estrés adicional que provoca un incumplimiento o pérdida sobre dicha entidad en todo el sistema. Dada su definición, es de esperarse encontrar una correlación marcada entre el tamaño de la institución financiera (color de los puntos) y el impacto adicional. Al mismo tiempo, se observa una correlación positiva entre la posición del banco en la red interbancaria, medida por el índice de centralidad PageRank (tamaño de los puntos), y el tamaño del estrés adicional que el mismo es capaz de generar en el sistema. Esta relación se mantiene tanto en el mercado garantizado como en el no garantizado.

Esto es relevante porque estos resultados muestran que la capacidad de transmisión de shocks de una entidad financiera se encuentra relacionada a su grado de conectividad en la red, además de a su tamaño. Por ejemplo, en el caso del mercado CALL la entidad 44090 en el primer período de la muestra (enero de 2015) representa menos del 1% del patrimonio agregado del sistema, pero si consideramos una propagación de un shock inicial, el incumplimiento de esta entidad provoca un estrés adicional del 4.5%, el mayor del período. Por lo tanto,

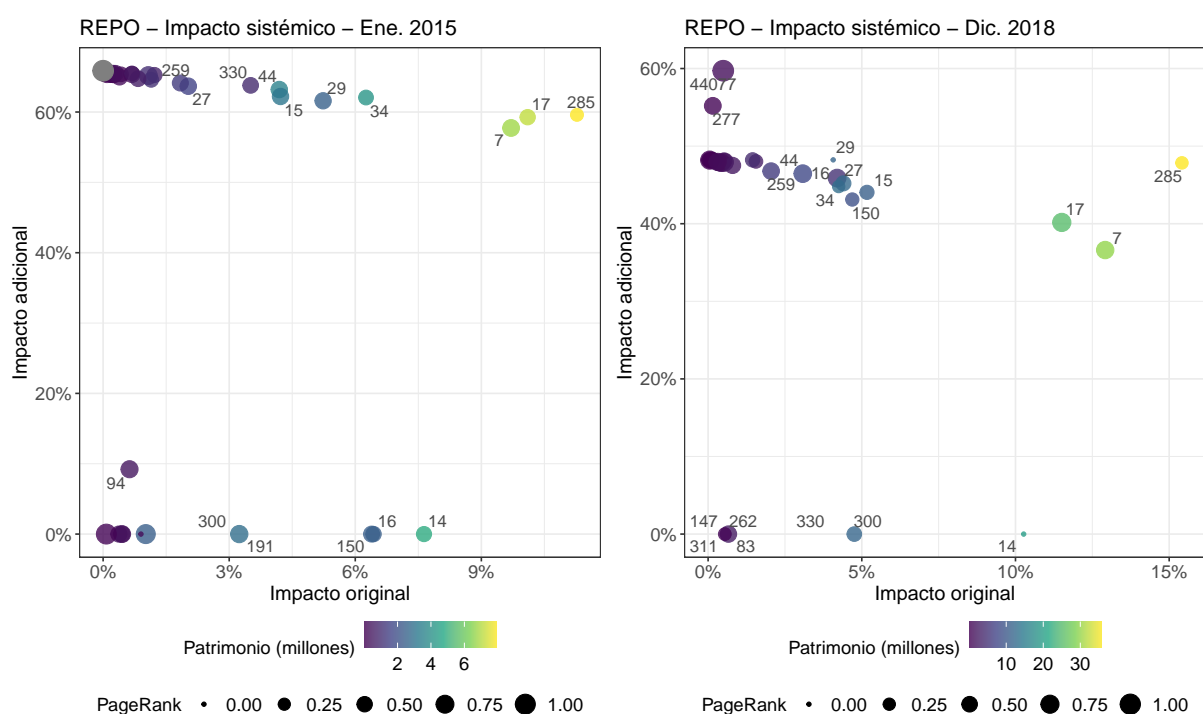
Finalmente, vale la pena mencionar que una vez más los resultados reflejan las diferencias de estructura existentes entre los dos mercados bajo análisis. Dado que el mercado REPO exhibe una mayor densidad en sus conexiones, los bancos son capaces de provocar estrés adicionales mucho mayores que en el caso del mercao CALL, llegando en algunos casos a multiplicar más de diez veces el tamaño del impacto original. De esta manera, es posible apreciar que el riesgo sistémico –en particular, su dimensión de impacto– es más elevado en el caso del mercado garantizado respecto del no garantizado, lo que se encuentra en línea con los hallazgos de [Elosegui et al. \(2022\)](#).

Figura 3.7: Impacto sistémico. Mercado CALL



Dado que nos interesa analizar la propagación de las pérdidas, para el análisis de los determinantes del riesgo sistémico, excluimos lo correspondiente al shock inicial. Asimismo, el impacto sistémico se calcula también para la institución financiera que sufrió el shock inicial, ya que como consecuencia de la ciclicidad de la red, un shock propagado por una determinada institución puede volver a afectarla de manera indirecta.

Figura 3.8: Impacto sistémico. Mercado REPO



3.4.4 Modelos de aprendizaje automático

Finalmente, aplicamos tres modelos o técnicas de aprendizaje automático para analizar los determinantes del riesgo sistémico en los dos mercados interbancarios argentinos bajo análisis: AdaBoost (Freund y Schapire, 1996), Random Forest (Breiman, 2001) y XGBoost (Chen y Guestrin, 2016). Los tres son métodos de aprendizaje conjunto que pueden ser aplicados tanto en análisis de clasificación como en análisis de regresión; en este capítulo los empleamos para el análisis de regresión. El propósito de aplicar estos modelos es estimar un output predicho \hat{y}_i a partir de un output observado y_i y un vector de variables explicativas X_i . En específico, en este capítulo el output a predecir son las medidas de riesgo sistémico $-IS_{i,\alpha}$ y VS_{i,α^-} y las variables explicativas son las mencionadas en la sección 3.4.2 y listadas en el cuadro 3.1, entre las cuales hay de naturaleza topológica y financiera. A continuación, se describen brevemente las características principales de cada uno de los algoritmos utilizados⁶³.

El algoritmo AdaBoost –introducido por Freund y Schapire (1996)– forma parte de la familia de los algoritmos de boosting o “impulso”⁶⁴. Lo que hace este algoritmo es crear árboles de decisión secuencialmente como predictores débiles (*weak learners*)⁶⁵ y penalizar a las muestras

⁶³La siguiente descripción no pretende ser una caracterización comprensiva y completa, sino más bien se pretende brindar una idea del funcionamiento o mecánica de cada algoritmo. Para más detalles sobre cada uno de ellos, el/la lector/a interesado/a puede referir, entre otros, a Lantz (2023) y a los artículos referenciados en cada descripción.

⁶⁴El boosting es una técnica de aprendizaje conjunto que entrena un grupo de modelos individuales de forma secuencial. Cada modelo individual aprende de los errores cometidos por el modelo anterior. Ver, por ejemplo, Freund y Schapire (1997).

⁶⁵Los *weak learners* pueden ser cualquier tipo de modelo de aprendizaje automático, como árboles de decisión, clasificadores lineales, o redes neuronales. Los más utilizados en AdaBoost, XGBoost y Random Forest son los

predichas incorrectamente asignándoles un peso mayor después de cada ronda de predicción. De esta manera, el algoritmo aprende de los errores previos. La predicción final es, en caso de problemas de regresión, la mediana ponderada.

El algoritmo Random Forest –desarrollado por Breiman (2001)– se basa en el enfoque de bagging o bootstrapping⁶⁶. Opera construyendo varios árboles de decisión y devuelve la predicción promedio de los árboles de decisión individuales. Más específicamente, este algoritmo realiza un muestreo de los datos eligiendo aleatoriamente submuestras para cada iteración de los árboles. El crecimiento de los árboles ocurre en paralelo, lo cual lo diferencia del AdaBoost. Random Forest logra reducir el sobreajuste al combinar muchos *weak learners* que subajustan porque solo utiliza un subconjunto de todos los ejemplos de entrenamiento.

Por último, el algoritmo XGBoost –introducido por Chen y Guestrin (2016)– utiliza el concepto de *gradient boosting* o potenciación del gradiente con árboles de decisión (ver, por ejemplo, Friedman, 2001). Se trabaja con un conjunto de predictores débiles para crear un modelo predictor más eficiente. Es decir, en cada etapa de boosting, el algoritmo XGBoost intenta mejorar el rendimiento del modelo predecesor al incluir un nuevo estimador. En el proceso de aprendizaje secuencial como *weak learners*, los árboles potenciados por gradiente utilizan árboles de regresión, los cuales –si bien son similares a los árboles de decisión– utilizan un puntaje continuo asignado a cada “hoja”⁶⁷, que se suma y proporciona la predicción final. El algoritmo incrementa secuencialmente los árboles y aprende de las iteraciones anteriores. Respecto a los modelos previos, el XGBoost incrementa la velocidad y el rendimiento en la estimación, al tiempo que introduce parámetros de regularización para reducir el sobreajuste.

El proceso seguido para entrenar y validar a los tres modelos implementados es el conocido como validación cruzada⁶⁸ *k-fold* repetido (ver, por ejemplo, Kuhn y Johnson, 2013). En este proceso, el output observado y las variables explicativas que conforman el conjunto de datos, se dividen en k partes diferentes –denominados comúnmente como “pliegues”–, y el modelo se entrena y evalúa k veces. En cada paso, un pliegue diferente se utiliza como conjunto de prueba, mientras que los otros $k - 1$ pliegues se utilizan para entrenar el modelo. Los k resultados diferentes de rendimiento del modelo (como error) que se obtienen luego de realizar las iteraciones, se promedian para obtener una medida general. Es decir, el output predicho \hat{y}_i y el output observado y_i de la parte utilizada como conjunto de prueba, se utilizan para calcular medidas de puntuación, como el

árboles de decisión, como haremos en este capítulo. Por sí solos, los predictores débiles no son muy precisos, por lo que es necesario combinar muchos *weak learners* para crear un modelo de aprendizaje automático que sea preciso.

⁶⁶El bagging es una técnica de aprendizaje conjunto que entrena un grupo de modelos individuales de forma paralela. Cada modelo se entrena con un subconjunto aleatorio de los datos. Ver, por ejemplo, Dietterich (2000).

⁶⁷Es decir, al último nodo una vez que el árbol ha terminado de crecer.

⁶⁸La validación cruzada es un método para entrenar a un modelo de manera de evitar el sobreajuste. El sobreajuste ocurre cuando un modelo se adapta demasiado a los datos de entrenamiento y no es capaz de generalizar bien a los datos nuevos. El objetivo de la implementación de este método es que el modelo no experimente una degradación del rendimiento en los nuevos inputs que provienen de la misma distribución de los datos de entrenamiento.

error cuadrático medio⁶⁹. En este capítulo, aplicamos una validación cruzada *k-fold* repetido con $k = 10$ y 10 repeticiones⁷⁰. De esta manera, se ejecutan un total de 100 regresiones por modelo para entrenar a los algoritmos.

Utilizamos el error cuadrático medio para ajustar el número de estimadores en los tres métodos. En AdaBoost el número de estimadores es el número de iteraciones que se realizan en el algoritmo. En Random Forest, el número de estimadores es la cantidad de árboles de decisión en cada bosque. En XGBoost, este es el número de etapas de refuerzo que se deben realizar. Ajustamos el número de estimadores dentro de una cuadrícula de valores ascendentes; es decir, que el número de estimadores se prueba en una serie de valores diferentes, y el valor que proporciona el mejor rendimiento se utiliza para el modelo final. El número de estimadores se probó en la cuadrícula⁷¹ [10, 30, 50, 70, 100, 200, 300]. Para cada uno de estos valores, se ejecutan las regresiones y se calcula la puntuación promedio. El número de estimadores se elige de manera que al aumentarlo no mejore el rendimiento del método. Después de este procedimiento, el valor de los tres parámetros se estableció en 50⁷².

Finalmente, aplicamos el método SHAP (SHapley Additive exPlanations) (Lundberg y Lee, 2017) para profundizar en la interpretación de los resultados de los modelos de aprendizaje automático⁷³. El método SHAP se basa en los valores Shapley, provenientes de la teoría de juegos cooperativos (Shapley, 1953). La aplicación de este marco permite obtener más evidencia sobre el peso de las características financieras y topológicas en el impulso del riesgo sistémico y brinda información acerca del signo de su relación. En particular, aplicamos el algoritmo TreeSHAP, que fue desarrollado recientemente por Lundberg *et al.* (2020) junto con el grupo de algoritmos TreeExplainer, diseñados específicamente para modelos de aprendizaje automático basados en árboles, como árboles de decisión, Random Forest y árboles potenciados por gradiente.

El objetivo del método SHAP es explicar la predicción de un registro x mediante el cálculo de la contribución de cada característica a la predicción, para lo que calcula los valores Shapley. Los valores de las características de un registro de datos actúan como jugadores en una coalición. Los valores Shapley indican cómo distribuir de manera justa el pago (es decir, la predicción) entre las características. En datos tabulares, como es el caso de este trabajo, un jugador puede ser el valor

⁶⁹El error cuadrático medio se define como la suma de los cuadrados de las diferencias entre las predicciones del modelo y los valores reales.

⁷⁰La elección de k y el número de repeticiones depende centralmente del tamaño del conjunto de datos, de cuánta precisión y/o estabilidad se requiera en el modelo y sus resultados y del tiempo disponible para el cómputo. En la literatura, usualmente los valores de k oscilan entre 5 y 10 y las repeticiones entre 1 y 10. Cuánto más alto es el valor de k y de repeticiones, mayor será la precisión del modelo, pero también mayor será el requerimiento computacional y el tiempo de cómputo. Para más detalles se puede ver, por ejemplo, Berrar (2019).

⁷¹Este proceso es lo que se conoce como optimización de hiperparámetros e implica probar diferentes combinaciones de valores para los hiperparámetros del modelo y evaluar qué combinación proporciona el mejor rendimiento en función de una métrica específica, como la precisión, el error cuadrático medio, el F1-score, etc.

⁷²Un número mayor de estimadores puede mejorar la precisión del modelo, pero también puede aumentar el tiempo de entrenamiento y el riesgo de sobreajuste. Un número menor de estimadores puede reducir el tiempo de entrenamiento y el riesgo de sobreajuste, pero también puede reducir la precisión del modelo.

⁷³La explicabilidad o interpretabilidad de los modelos de aprendizaje automático es la capacidad de entender cómo un modelo llega a una determinada predicción. Existe un amplio conjunto de métodos que permiten profundizar en el entendimiento de los resultados. Para una revisión ver, por ejemplo, Molnar *et al.* (2020).

individual de una característica. Lundberg y Lee (2017) proponen un modelo explicativo g con el objetivo de predecir un output utilizando un conjunto de M características como input. Estas características son lo que en Lundberg y Lee (2017) llaman *simplified inputs*. Estos modelos suelen utilizar *simplified inputs* x' que mapean a los input originales a través de una función de mapeo específica $x = h_x(x')$. Se especifica la explicación de la siguiente manera:

$$g(z') = \phi_0 + \sum_{i=1}^M \phi_i z'_i, \quad (3.5)$$

donde $z' \in \{0, 1\}^M$. z'_i es una variable binaria que indica si la característica i se incluyó o no en el modelo. El valor SHAP ϕ_i indica en qué medida y en qué sentido la característica i desplaza el valor predicho desde un valor inicial medio ϕ_0 . Como señalan Lundberg y Lee (2017) –para el caso general del método SHAP– y Lundberg *et al.* (2020) –para los algoritmos TreeExplainer–, si se cumplen ciertas propiedades⁷⁴ ϕ_i se corresponde con el valor Shapley. El valor SHAP está dado por:

$$\phi_i(f, x) = \sum_{z' \subseteq x'} \frac{|z'|!(M - |z'| - 1)!}{M!} [f_x(z') - f_x(z' \setminus i)], \quad (3.6)$$

donde $|z'|$ es el número de entradas distintas de cero en z' y $z' \subseteq x'$ representa todos los vectores z' cuyas entradas distintas de cero son un subset de las entradas distintas de cero en x' . f es la predicción original del modelo a ser explicado y $z' \setminus i$ indica que $z'_i = 0$. Por lo tanto, el valor SHAP ϕ_i para un registro de datos dado, se obtiene a partir de la diferencia entre el valor predicho del registro de datos utilizando todas las características en z' incluida la característica i ($f_x(z')$) y la predicción excluyendo a la característica i ($f_x(z' \setminus i)$). Esto se pondera y suma sobre todas las posibles combinaciones de vectores de características de todos los subconjuntos posibles z' . Para más detalles sobre el algoritmo implementado, ver Lundberg y Lee (2017) y Lundberg *et al.* (2020).

Los valores SHAP se calculan utilizando los tres modelos descritos previamente –AdaBoost, Random Forest y XGBoost– con las dos dimensiones de riesgo sistémico como el output a predecir. Los tres modelos se entrenan con una validación cruzada *k-fold* repetido, con $k = 10$ y 10 repeticiones, como mencionamos previamente. Como en Alexandre *et al.* (2021), una vez obtenido el valor para cada registro, se calcula el valor SHAP absoluto promedio, que brinda información sobre el tamaño de la importancia de la característica en la predicción. Finalmente, se multiplica el valor SHAP absoluto promedio por el signo de la correlación entre el valor de la característica y el valor SHAP, lo que indica si la característica está correlacionada positiva o negativamente con la variable a predecir.

En la siguiente sección se presentan los resultados.

⁷⁴Esta son precisión local, sin datos faltantes y consistencia, ver Lundberg y Lee (2017), página 4, para una definición de cada una.

3.5 Resultados: los determinantes del riesgo sistémico en los mercados CALL y REPO

Los indicadores de riesgo sistémico, $IS_{i,\alpha}$ y $VS_{i,\alpha}$, se computaron con diferentes valores de α o tamaño del shock inicial. Específicamente, asignamos valores en el intervalo $(0.1; 1]$ con saltos discretos de 0.1. De esta manera, hay 20 variables dependientes en cada modelo y para cada mercado, CALL y REPO.

Realizamos el análisis por separado para los mercados CALL y el REPO. Como mencionamos previamente, estos mercados se diferencian en su microestructura, en la tecnología que utilizan en sus operaciones y en el modo de operar. Estas diferencias se describen en la sección 3.3 y se pueden observar en el cuadro 3.1. Los bancos más pequeños y las compañías financieras no bancarias participan generalmente en el mercado CALL y no en el REPO. Esto se refleja en la media de los activos y patrimonio de las instituciones que participan en cada mercado. Asimismo, los montos transados en el mercado REPO son muy superiores a aquellos transados en el mercado CALL, sobre todo si se tiene en cuenta la relación con el patrimonio de las entidades.

Un punto relevante a considerar para nuestro análisis es que en el mercado garantizado los niveles de conectividad son significativamente más altos respecto del mercado CALL. El grado total promedio de los nodos en el REPO (16.4) es mucho mayor al valor registrado para el mercado no garantizado (6.8). Es decir, que a pesar de tener más participantes el mercado CALL no está tan bien conectado como el REPO. Si observamos el coeficiente de agrupamiento, para el caso del REPO promedió el 64%, un valor muy por encima del registrado para el mercado CALL (18%). Vale la pena señalar que, en el caso de este último, el coeficiente de agrupamiento cayó abruptamente en 2018, lo que coincidió temporalmente con la crisis que experimentó Argentina ese año. Por lo tanto, se puede decir que la estructura de interrelaciones en el mercado no garantizado es menos estable que en el mercado REPO, especialmente durante momentos de crisis. Este resultado podría indicar una menor resistencia a los shocks negativos en el mercado CALL respecto del REPO. Finalmente, cabe mencionar que si bien el grado de salida y el grado de entrada son similares en ambos mercados, los bancos más pequeños y las entidades financieras no bancarias actúan centralmente como prestatarias, mientras que los bancos más grandes actúan como prestamistas.

A continuación, se presentan y describen los resultados de las estimaciones para los tres modelos utilizados.

3.5.1 Mercado CALL

Las figuras 3.9 y 3.10 muestran los resultados de la aplicación de los modelos de aprendizaje automático para el análisis de los determinantes del impacto sistémico y vulnerabilidad sistémica, respectivamente, en el mercado CALL. Se muestra el cambio en los resultados a medida que se

Cuadro 3.1: Potenciales determinantes del riesgo sistémico estudiados y sus valores medios para los mercados CALL y REPO.

Variable	Símbolo	Media CALL	Media REPO
Financieras			
Activos	A	35664641.23	41014337.41
Activos interbancarios sobre PN	AIPN	2.01	2.84
Apalancamiento (en veces)	Ap	6.87	6.99
Pasivos interbancarios sobre PN	PIPN	2.08	6.51
Patrimonio	P	4016960.26	4619504.30
Retorno sobre capital (%)	ROE	22.87	23.72
Topológicas			
Cercanía - entrada	C(in)	0.50	0.51
Cercanía - salida	C(out)	0.49	0.56
Agrupamiento	Ag	0.18	0.64
Intermediación	In	0.01	0.03
PageRank	PR	0.02	0.19
Grado - total	G(tot)	6.82	16.36

aumenta el tamaño del shock inicial, α . En ambos casos, en una gama de colores violeta-azul se representan las variables topológicas, mientras que en la paleta de colores verde-amarillo se grafican las variables de naturaleza financiera.

El panel superior de la figura 3.9 muestra la importancia agregada de los factores topológicos y financieros en el impulso del riesgo sistémico. Como puede observarse, las características topológicas son las impulsoras del impacto sistémico en el mercado CALL y su importancia crece con el tamaño del shock inicial. Para los niveles iniciales de α , la participación de ambos tipos de variables se encuentra relativamente balanceada, pero una vez que el tamaño del shock inicial supera el 50%, la importancia de las variables topológicas crece considerablemente. Estos resultados se replican en los tres modelos aplicados, con algunas diferencias asociadas principalmente al cambio de las participaciones cuando α crece. En promedio, la relevancia de las variables topológicas como impulsoras del impacto sistémico es del 63%, 58% y 57%, para los modelos XGBoost, Random Forest y AdaBoost, respectivamente, alcanzando un valor máximo de 76%, 69% y 63% en cada caso respectivo.

El panel medio de la figura 3.9 muestra a los factores impulsores de manera desagregada. Como puede observarse, el impacto sistémico en el mercado CALL está principalmente impulsado por el índice de centralidad PageRank. El PageRank es una medida de centralidad que fue diseñada específicamente para redes dirigidas y se calcula de manera recursiva. Para entender un poco más cómo funciona esta medida, el PageRank de una institución financiera i será mayor cuanto mayor sea su grado de entrada –es decir, el número de prestamistas de i y cuanto mayor sea el grado de entrada de sus vecinos directos e indirectos, ponderado por un factor de amortiguamiento. Este factor de amortiguamiento hace que cuanto más lejos esté el vecino, menor será su impacto en el PageRank de la institución financiera i . De esta manera, lo que indican los resultados es que un shock en una institución financiera con un alto PageRank puede propagarse a través de un número de otras instituciones financieras.


Las principales variables que siguen inmediatamente luego del PageRank son de tipo financiero. Cabe destacar al total de activos y a los pasivos interbancarios sobre patrimonio neto, como los principales elementos de la estructura financiera de las instituciones en impulsar el impacto sistémico en el mercado interbancario no garantizado. Para los valores iniciales de α , estas dos variables poseen una importancia relativamente considerable, pero la misma disminuye a medida que crece el tamaño del shock inicial y, al mismo tiempo, la importancia del PageRank. Finalmente, cabe mencionar que los tres métodos utilizados –XGBoost, AdaBoost y Random Forest– proporcionan resultados similares, por lo que no cambian las conclusiones principales al analizar uno u otro modelo.

Finalmente, el panel inferior de la figura 3.9 presenta los resultados de los valores SHAP absolutos promedio, multiplicados por el signo de la correlación entre el valor de la característica y el valor SHAP. El tamaño de los puntos se corresponde con el tamaño del shock inicial. En líneas generales, estos resultados corroboran los descritos en los párrafos previos. El impacto sistémico en el mercado CALL está determinado principalmente por el PageRank. Este efecto es positivo y tiene una relación no lineal con el tamaño del shock inicial. El impacto máximo de PageRank en el impacto sistémico se observa en el máximo valor de α . La importancia de los pasivos interbancarios sobre patrimonio neto y de los activos interbancarios sobre patrimonio neto, disminuye con el tamaño del shock inicial. La primera afecta al impacto sistémico de manera positiva mientras que la segunda lo hace de manera negativa.

Contrario a lo que sucede en el caso del impacto sistémico, la vulnerabilidad sistémica está centralmente impulsada por variables financieras, como puede observarse en el panel superior de la figura 3.10. La importancia relativa del conjunto de variables financieras crece a medida que aumenta el valor de α , aunque a una tasa relativamente pequeña. Una vez más, los resultados son relativamente similares para los tres métodos implementados, siendo un poco menor la importancia de las variables financieras en la predicción realizada por el algoritmo AdaBoost. La relevancia de las variables financieras como impulsoras de la vulnerabilidad sistémica es, en promedio, del 75%, 79% y 66%, para los modelos XGBoost, Random Forest y AdaBoost, respectivamente. Los valores máximos –registrados para un valor de $\alpha = 1$ –, son 81%, 83% y 71% en cada caso respectivo.

Al analizar específicamente cuáles son las variables que impulsan a la vulnerabilidad sistémica de las entidades financieras en el mercado CALL, se destaca a los activos interbancarios (en relación con el patrimonio neto), lo cual se aprecia claramente en el panel inferior de la figura 3.10. No obstante, para valores pequeños de *alpha* esta característica por sí sola no es suficiente para predecir la vulnerabilidad sistémica, dado que el resto de las variables –tanto topológicas como financieras– tomadas de manera agregada poseen una importancia considerable. Los resultados para XGBoost y Random Forest son similares, mientras que el algoritmo AdaBoost asigna una importancia menor tanto a los activos interbancarios como a las características financieras en general, respecto a los otros dos métodos.

Figura 3.9: Mercado CALL. Importancia de las variables topológicas y financieras en la predicción del impacto sistémico.



Respecto a los valores SHAP, en líneas generales se mantienen los resultados descritos. El ratio de activos interbancarios a patrimonio es la principal variable para explicar la vulnerabilidad sistémica de las instituciones financieras en el mercado CALL. El efecto es positivo e incrementa de manera no lineal con el tamaño del shock inicial. La siguiente variable financiera más importante son los activos totales, los cuales tienen un efecto negativo sobre la vulnerabilidad sistémica. Al contrario de lo que sucedía con los activos interbancarios, su importancia se reduce con el tamaño del shock inicial. Finalmente, cabe mencionar el caso de la centralidad de intermediación, que es la principal variable topológica para explicar la vulnerabilidad sistémica. Como era de esperarse su efecto es positivo, y su importancia se reduce con el tamaño del shock inicial, aunque a una tasa reducida. Este resultado se repite en los tres modelos de aprendizaje automático aplicados.

Si comparamos las figuras 3.9 y 3.10 –en particular, los paneles superiores–, podemos observar cierta asimetría. La importancia agregada (promedio) de las características topológicas en la conducción del impacto sistémico varía entre 57% y 63%; mientras que la importancia agregada de las características financieras en la conducción de la vulnerabilidad sistémica es mayor, en el rango de 67%-79%, dependiendo del algoritmo de aprendizaje automático utilizado.


3.5.2 Mercado REPO

Los resultados para el mercado REPO se presentan de manera análoga al mercado no garantizado: las figuras 3.11 y 3.12 muestran los resultados para el análisis de los determinantes del impacto sistémico y vulnerabilidad sistémica, respectivamente. En todos los gráficos, se pueden visualizar los resultados para los distintos tamaños del shock inicial, α . En ambas figuras, las variables topológicas se presentan en una gama de colores violeta-azul, y las variables de naturaleza financiera se grafican en la paleta de colores verde-amarillo.

El impacto sistémico en el mercado REPO está impulsado principalmente por factores asociados a la topología de la red interbancaria, similar a lo que se observó para el caso del mercado no garantizado (figura 3.11, panel superior). No obstante, estos factores parecen ser más relevantes en el caso del mercado garantizado respecto de lo observado para el mercado CALL. En promedio, el peso de las variables topológicas en la predicción del impacto sistémico para el mercado REPO es del 64%, 73% y 68%, para los modelos XGBoost, Random Forest y AdaBoost, respectivamente (contra un rango comprendido entre 57% y 63% para el CALL). Los valores máximos alcanzados en cada uno de estos métodos es de 70%, 81% y 76, por lo que XGBoost es el algoritmo que asigna la menor relevancia a las variables topológicas. Finalmente, cabe señalar que la importancia de las variables topológicas, de manera agregada, crece a medida que consideramos valores de α más altos.

La principal variable impulsora del impacto sistémico es el PageRank, similar a lo observado en el mercado CALL pero con un peso algo mayor en este mercado. Las interconexiones en este mercado son más importantes para determinar la capacidad de impacto que tienen las distintas

Figura 3.10: Mercado CALL. Importancia de las variables topológicas y financieras en la predicción de la vulnerabilidad sistémica.




entidades que participan del mismo, lo que se encuentra en línea con el hecho de que el mercado REPO muestra un mayor número de interacciones respecto al CALL, a pesar de tener un menor número de participantes. La siguiente variable topológica más relevante es la centralidad de cercanía y, solo para el caso de los valores más elevados de α , el coeficiente de agrupamiento. La centralidad de cercanía está relacionada en cierta medida con la proximidad física: los nodos con alta centralidad de cercanía son aquellos que poseen la distancia promedio más corta a todos los demás nodos en la red. La siguiente variable en importancia como impulsora del impacto sistémico, son los activos totales, resultado que se repite en todos los modelos de aprendizaje automático. En el caso del XGBoost asigna una importancia significativa también a los pasivos interbancarios en relación al patrimonio de las entidades y su peso se incrementa (a una tasa pequeña) a medida que crece el tamaño del shock inicial, a contramano de lo que sucede con las variables topológicas de manera agregada.

Respecto a los valores SHAP, muestran que la principal variable para predecir el impacto sistémico de las instituciones en el mercado REPO, y su importancia se incrementa con el tamaño del shock inicial de manera no lineal. Este incremento se sostiene centralmente para valores más pequeños de α , mientras que para valores mayores el crecimiento es mucho menor. La siguiente variable topológica más importante es el coeficiente de agrupamiento, centralmente para valores más altos del shock inicial. Su efecto sobre el impacto sistémico es negativo y crece (en términos absolutos) de manera monótona con el tamaño del shock inicial. Las variables financieras más importantes para predecir el riesgo sistémico son el total de activos y el ratio de pasivos interbancarios a patrimonio. La primera tiene un efecto positivo en el impacto sistémico, cuánto mayor sea el tamaño de la entidad mayor será su capacidad de contagio. La importancia de esta variable se reduce con el tamaño del shock inicial. Respecto al ratio de pasivos interbancarios a patrimonio, los modelos Random Forest y AdaBoost predicen un efecto para valores altos de α , mientras que el XGBoost indica un efecto positivo de esta variable sobre el impacto sistémico para cualquier tamaño del shock inicial.

La vulnerabilidad sistémica en el mercado garantizado está impulsada por variables financieras (figura 3.12, panel superior). A medida que el valor de α crece el peso del conjunto de variables que comparten esta característica aumenta, resultado que se mantiene con los tres algoritmos aplicados. Similar a lo observado para el mercado CALL, el método AdaBoost le asigna una menor importancia agregada a las variables financieras como impulsoras de la vulnerabilidad sistémica, en comparación con los otros dos métodos. En promedio, el peso de las variables financieras como predictoras de la vulnerabilidad sistémica en el mercado bajo análisis es 65%, 69% y 58%, para los modelos XGBoost, Random Forest y AdaBoost, respectivamente. Los valores máximos –registrados en todos los casos para el máximo valor de α –, son 72%, 74% y 64% en cada caso.

Si analizamos individualmente cuánto contribuye cada variable como impulsora de la vulnerabilidad sistémica, se puede observar en el panel inferior de la figura 3.12 que la principal

Figura 3.11: Mercado REPO. Importancia de las variables topológicas y financieras en la predicción del impacto sistémico.



predictora es la relación entre activos interbancarios y patrimonio neto. No obstante, su importancia es bastante menor a aquella otorgada en el caso del mercado CALL. Su peso máximo –alcanzado para un valor de α igual a 1 en los tres métodos– se ubica en un rango de 36%-68%, lo que implica que por sí sola, esta característica financiera de las entidades no es suficiente para predecir la vulnerabilidad sistémica. La siguiente variable más relevante, es la centralidad de intermediación, una variable de naturaleza topológica. Un banco con una alta centralidad de intermediación está más expuesto al riesgo de contagio porque está conectado a muchos otros bancos. Si uno de estos bancos se encuentra en problemas, puede afectar negativamente al banco con alta centralidad de intermediación. Si bien las principales conclusiones se mantienen para los tres métodos aplicados, el algoritmo AdaBoost le asigna una menor importancia a los activos interbancarios sobre patrimonio neto, y un mayor peso a la centralidad de intermediación, los activos y la centralidad de cercanía (salida).

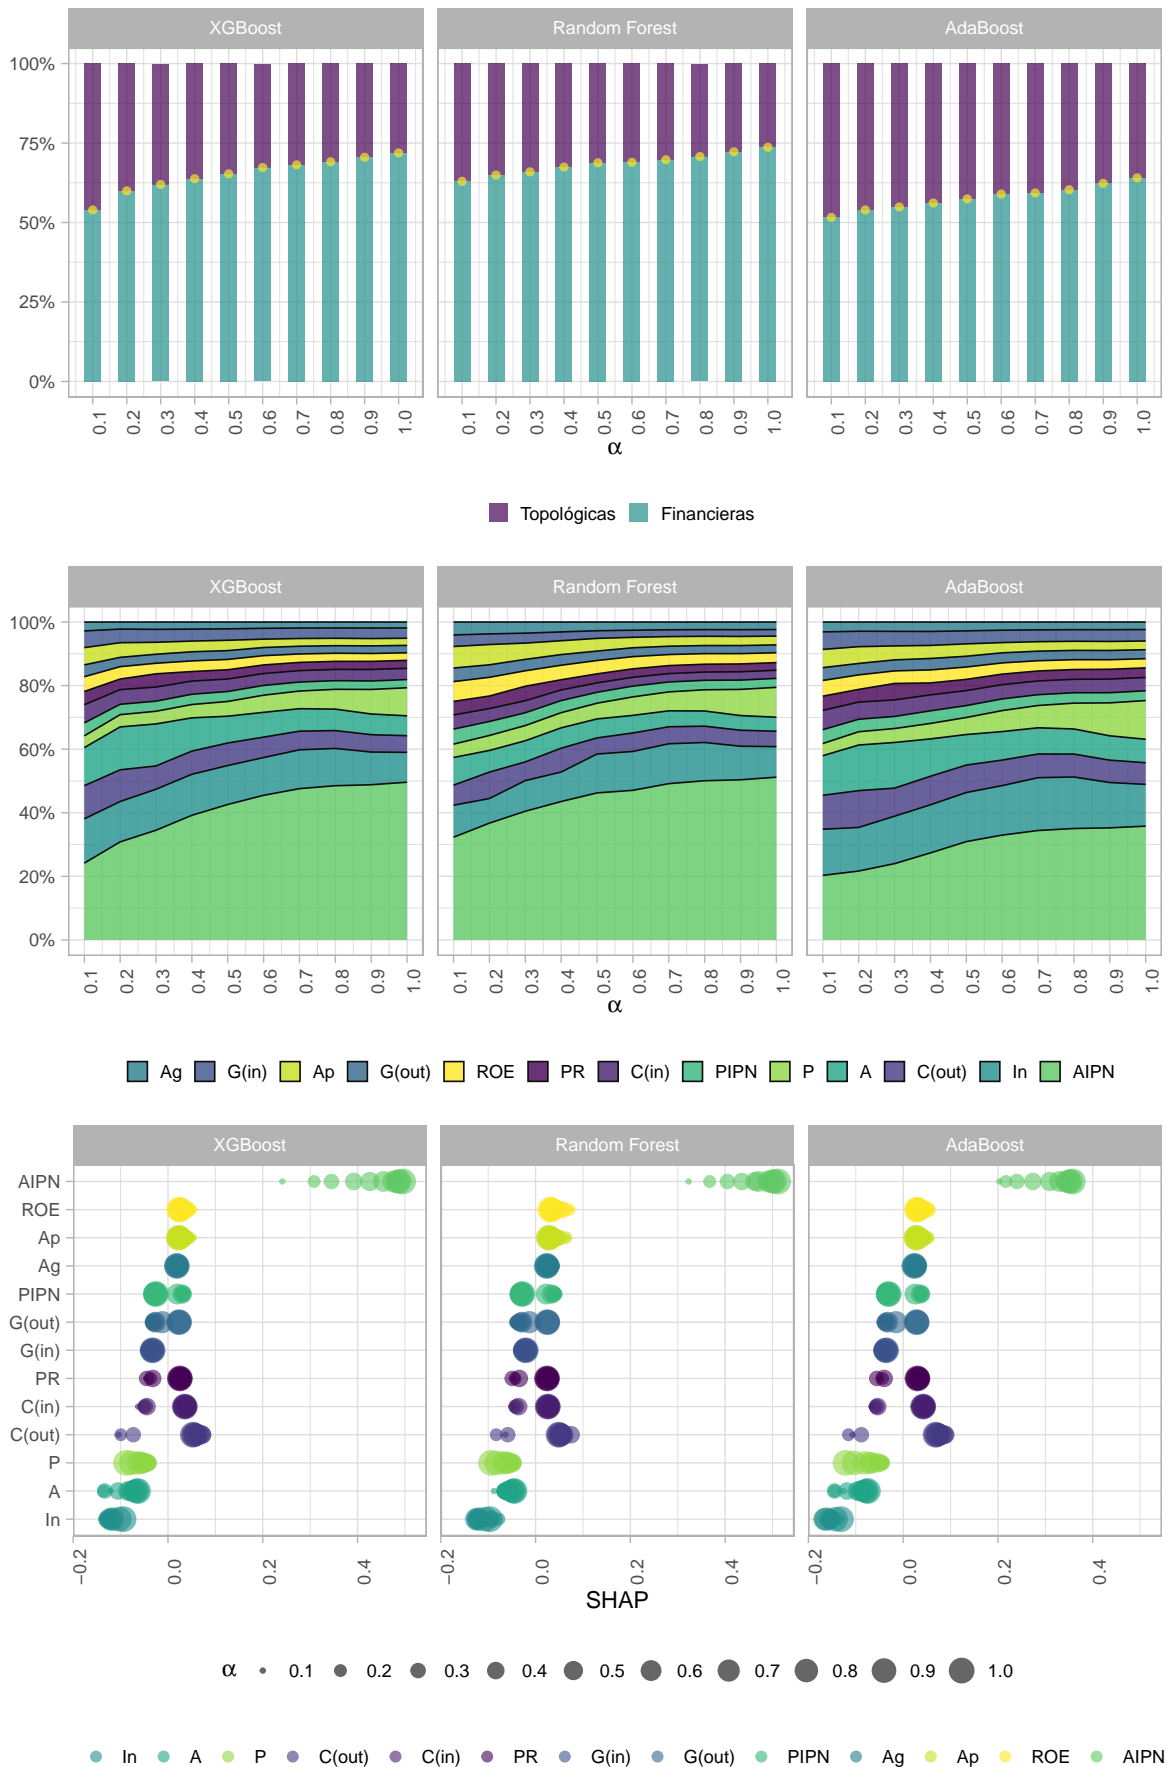
Los valores SHAP confirman en líneas generales lo descrito en los párrafos previos. La variable más importante para predecir la vulnerabilidad sistémica en el mercado REPO es el ratio de activos interbancarios a patrimonio. Su efecto es positivo y su importancia crece con el tamaño del shock inicial, a una tasa más elevada para valores bajos de α en el caso de XGBoost y Random Forest, y para valores medios de α en el caso del AdaBoost. La siguiente variable financiera más importante son los activos, los cuales tienen un efecto negativo sobre la vulnerabilidad sistémica de las entidades. La importancia de esta variable decrece levemente (en términos absolutos) con el tamaño del shock inicial. Por su parte, la variable topológica de mayor peso en el impulso de la vulnerabilidad sistémica es la centralidad de intermediación. Su efecto es negativo y pareciera no haber una relación con el tamaño del shock inicial, resultado que se repite en los tres modelos de aprendizaje automático. Finalmente, cabe mencionar los casos de la centralidad de cercanía –de entrada y salida–, del PageRank y del grado –de entrada y salida–. En los tres modelos estudiados, el efecto de estas variables es negativo para tamaños pequeños de α , pero positivo para valores de α mayores.

Al comparar las figuras 3.11 y 3.12 para los resultados agregados por tipo de variable, no se observan asimetrías significativas. La importancia agregada de las características topológicas como impulsoras del impacto sistémico varía entre 64% y 73%; mientras que para las características financieras en la predicción de la vulnerabilidad sistémica el rango de valores se ubica entre 58% y 69%; valores menores, pero cercanos. Sin embargo, si miramos a las variables desagregadas, el peso del principal factor es sensiblemente mayor para el caso del PageRank como impulsor del impacto sistémico, respecto de los activos interbancarios sobre patrimonio neto.

3.6 Comentarios finales

La identificación de las instituciones financieras que son sistémicamente importantes es relevante no solo desde un punto de vista metodológico, sino también para la toma de decisiones asociadas

Figura 3.12: Mercado REPO. Importancia de las variables topológicas y financieras en la predicción de la vulnerabilidad sistémica.



a la regulación financiera. De hecho, generalmente los instrumentos de política que abordan el riesgo sistémico se dirigen hacia las instituciones financieras más importantes sistémicamente, con el objetivo de minimizar la probabilidad de ocurrencia y/o los costos de una crisis financiera⁷⁵. Para el diseño de medidas efectivas en la disipación del riesgo sistémico, es necesario contar con información acerca de los factores que lo impulsan. En este sentido, la identificación de las instituciones de importancia sistémica y sus determinantes son tareas clave para lograr y mantener la estabilidad financiera.

En este capítulo, analizamos el riesgo sistémico y sus determinantes en el mercado interbancario de Argentina. Consideramos dos conjuntos de características, clasificadas en financieras –es decir, aquellas variables que reflejan la estructura o condiciones financieras de las entidades en el mercado– y topológicas –es decir, aquellas variables que dan cuenta de la posición de una entidad en la estructura de interrelaciones–. El conjunto de datos utilizado incluye información mensual sobre las instituciones financieras que participaron de los mercados interbancarios CALL (no garantizado) y REPO (garantizado) y las transacciones entre ellas en dichos mercados, para el período entre 2015 y 2018. A partir de la metodología *Differential DebtRank* estimamos el riesgo sistémico de las entidades financieras en los dos mercados por separado y en dos de sus dimensiones, vulnerabilidad e impacto sistémico. Finalmente, aplicamos tres técnicas de aprendizaje automático –AdaBoost, Random Forest y XGBoost– para evaluar cuáles son los principales factores o características que impulsan el fenómeno bajo análisis. También aplicamos la metodología TreeSHAP empleando estas tres técnicas como modelos explicativos, para mejorar la interpretabilidad de los resultados. Esto no solo informa sobre el tamaño del efecto de una característica dada en el riesgo sistémico, sino también sobre la dirección de este efecto, es decir, si la característica está correlacionada positiva o negativamente con la medida de riesgo.

Encontramos que el peso de las distintas características en el impulso del riesgo sistémico en el mercado interbancario argentino, depende centralmente de dos factores: el tamaño del shock inicial, y la dimensión del riesgo sistémico que se esté evaluando (impacto o vulnerabilidad). También afecta la naturaleza de las transacciones, es decir, si se trata de un mercado con operaciones garantizadas o no garantizadas.

Las características topológicas en su conjunto son los principales determinantes del impacto sistémico, con el PageRank como variable clave; mientras que las características financieras son las más relevantes, en su conjunto, para explicar la vulnerabilidad sistémica de las instituciones financieras, con la relación activos interbancarios-patrimonio neto como principal variable. Esto nos permite decir que en el mercado interbancario argentino la capacidad de contagio de pérdidas de una institución financiera está impulsado por su centralidad o posición en el entramado de relaciones interbancarias, mientras que su vulnerabilidad depende de cuán expuesta esté a otras

⁷⁵A modo de ejemplo, se puede mencionar la Ley Dodd-Frank que regula de manera directa a empresas y sectores económicos de importancia sistémica (Evanoff y Moeller, 2012) y las normas de Basilea III, que exigen un cargo de capital adicional a los bancos que son más importantes sistémicamente a nivel nacional y mundial (BCBS, 2012).

instituciones financieras en el mercado (es decir, a cuántas unidades prestó dinero y por qué monto). Si bien este resultado se mantiene para ambos mercados, la estructura de interconexiones entre los bancos resulta ser más relevante para explicar el riesgo sistémico –en sus dos dimensiones estudiadas– en el mercado REPO respecto del CALL. Finalmente, cabe mencionar que en ambos casos el peso del conjunto de características más relevantes crece con el tamaño del shock inicial. No obstante, se observa cierta heterogeneidad en la evolución de las variables al interior de cada grupo de características.

Los resultados de este capítulo descritos en los párrafos previos se encuentran en línea con los hallazgos de otras contribuciones en la literatura (Alexandre *et al.*, 2021; Narayan *et al.*, 2023) y aportan nueva evidencia para un país en desarrollo. En particular, se trabaja sobre un mercado donde las crisis bancarias sistémicas han sido más recurrentes que en cualquier otra economía del mundo en los últimos 50 años. En este sentido, el capítulo proporciona información que puede ser de utilidad para el diseño de políticas cuyo objetivo final sea alcanzar y sostener la estabilidad financiera. En particular, se abordan los determinantes del riesgo sistémico en los mercados garantizado y no garantizado de manera separada, considerando las diferencias que poseen en términos de microestructura, reglas de operación y tecnología. En relación a este último punto, futuras investigaciones podrían considerar también a las interacciones en los mercados CALL y REPO como diferentes capas en una red multinivel, para evaluar también la transmisión de pérdidas de un mercado a otro. Asimismo, como señalan Elosegui *et al.* (2022) se podría incorporar el tipo de colateral utilizado en las transacciones del mercado garantizado, y evaluar si existen diferencias en los factores que impulsan el riesgo sistémico en los diferentes segmentos de este mercado.

Referencias

- Acemoglu, D., Ozdaglar, A., & Tahbaz-Salehi, A. (2015). Systemic risk and stability in financial networks. *American Economic Review*, 105(2), 564-608.
- Acharya, V. V., Pedersen, L. H., Philippon, T., & Richardson, M. (2017). Measuring systemic risk. *The review of financial studies*, 30(1), 2-47.
- Adrian, T., & Brunnermeier, M. K. (2016). CoVaR. *The American Economic Review*, 106(7), 1705.
- Alexandre, M., Silva, T. C., Connaughton, C., & Rodrigues, F. A. (2021). The drivers of systemic risk in financial networks: a data-driven machine learning analysis. *Chaos, Solitons & Fractals*, 153, 111588.
- Allen, F., & Gale, D. (2000). Bubbles and crises. *Economic Journal*, 110(460), 236-255.
- Amini, H., Cont, R., & Minca, A. (2016). Resilience to contagion in financial networks. *Mathematical finance*, 26(2), 329-365.
- Anastasi, A., Elosegui, P., & Sangiácomo, M. (2010). Determinantes de la tasa interbancaria de préstamos en Argentina. *Ensayos Económicos*, 60, 137-209.

- Araújo, G. S., & Leao, S. (2013). *Risco sistêmico no mercado bancário brasileiro-uma abordagem pelo método CoVaR*.
- Arias, M., Mendoza-Gutiérrez, J. C., & Pérez-Reyna, D. (2010). Applying cov ar to measure systemic market risk: the colombian case. *Temas de Estabilidad Financiera*, 47.
- Barabási, A.-L. (2016). *Network Science*. Cambridge University Press.
- Bardoscia, M., Battiston, S., Caccioli, F., & Caldarelli, G. (2015). DebtRank: A microscopic foundation for shock propagation. *PloS one*, 10(6), e0130406.
- Battiston, S., Delli Gatti, D., Gallegati, M., Greenwald, B., & Stiglitz, J. E. (2012). Default cascades: When does risk diversification increase stability? *Journal of Financial Stability*, 8(3), 138-149.
- Battiston, S., Puliga, M., Kaushik, R., Tasca, P., & Caldarelli, G. (2012). Debtrank: Too central to fail? financial networks, the fed and systemic risk. *Scientific reports*, 2(1), 541. <https://doi.org/10.1038/srep00541>
- BCBS. (2012). Global systemically important banks: updated assessment methodology and the higher loss absorbency requirement. *Bank for International Settlements*.
- Bech, M. L., & Atalay, E. (2010). The topology of the federal funds market. *Physica A: Statistical mechanics and its applications*, 389(22), 5223-5246.
- Benoit, S., Colliard, J.-E., Hurlin, C., & Pérignon, C. (2017). Where the risks lie: A survey on systemic risk. *Review of Finance*, 21(1), 109-152.
- Berrar, D. (2019). Cross-Validation. En S. Ranganathan, M. Gribskov, K. Nakai, & C. Schönbach (Eds.), *Encyclopedia of Bioinformatics and Computational Biology* (pp. 542-545). Academic Press. <https://doi.org/10.1016/B978-0-12-809633-8.20349-X>
- Bisias, D., Flood, M., Lo, A. W., & Valavanis, S. (2012). A survey of systemic risk analytics. *Annu. Rev. Financ. Econ.*, 4(1), 255-296.
- Boss, M., Krenn, G., Pühr, C., & Summer, M. (2006). Systemic risk monitor: A model for systemic risk analysis and stress testing of banking systems. *Financial Stability Report*, 11(June), 83-95.
- Breiman, L. (2001). Random forests. *Machine learning*, 45, 5-32.
- Brogi, M., Lagasio, V., & Riccetti, L. (2021). Systemic risk measurement: bucketing global systemically important banks. *Annals of Finance*, 17(3), 319-351.
- Brownlees, C., & Engle, R. F. (2017). SRISK: A conditional capital shortfall measure of systemic risk. *The Review of Financial Studies*, 30(1), 48-79.
- Brunnermeier, M. K., Dong, G. N., & Palia, D. (2020). Banks' noninterest income and systemic risk. *The Review of Corporate Finance Studies*, 9(2), 229-255.
- Brusco, S., & Castiglionesi, F. (2007). Liquidity coinsurance, moral hazard, and financial contagion. *The Journal of Finance*, 62(5), 2275-2302.
- Caccioli, F., Catanach, T. A., & Farmer, J. D. (2012). Heterogeneity, correlations and financial contagion. *Advances in Complex Systems*, 15(supp02), 1250058.
- Chen, T., & Guestrin, C. (2016). Xgboost: A scalable tree boosting system. *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*, 785-794.

- Chinazzi, M., & Fagiolo, G. (2013). *Systemic Risk, Contagion, and Financial Networks: A Survey*. Institute of Economics, Scuola Superiore Sant'Anna, Laboratory of Economics; Management (LEM) Working Paper Series No. 2013/08.
- Danielsson, J., James, K. R., Valenzuela, M., & Zer, I. (2016). Model risk of risk models. *Journal of Financial Stability*, 23, 79-91.
- De Jonghe, O. (2010). Back to the basics in banking? A micro-analysis of banking system stability. *Journal of financial intermediation*, 19(3), 387-417.
- Di Iasio, G., Battiston, S., Infante, L., & Pierobon, F. (2015). Capital and contagion in financial networks, IFC Bulletins Chapters. En *Indicators to support monetary and financial stability analysis: data sources and statistical methodologies* (Vol. 39, pp. 1-23). Bank for International Settlements (Ed).
- Dietterich, T. G. (2000). An experimental comparison of three methods for constructing ensembles of decision trees: Bagging, boosting, and randomization. *Machine learning*, 40, 139-157.
- Elosegui, P., Forte, F. D., & Montes-Rojas, G. (2022). Network structure and fragmentation of the Argentinean interbank markets. *Latin American Journal of Central Banking*, 3(3), 100066.
- Elosegui, P., & Montes-Rojas, G. (2020). Network effects in interbank markets of Call and Repo in Argentina. *Ensayos Económicos*, 1(75), 50-81.
- Estrada, E. (2012). *The structure of complex networks: theory and applications*. Oxford University Press, USA.
- Evanoff, D. D., & Moeller, W. F. (2012). Dodd–Frank: Content, purpose, implementation status, and issues. *Economic Perspectives*, 36(Q III), 75-84.
- Fang, L., Sun, B., Li, H., & Yu, H. (2018). Systemic risk network of Chinese financial institutions. *Emerging Markets Review*, 35, 190-206.
- Foggitt, G. M., Heymans, A., Vuuren, G. W. van, & Pretorius, A. (2017). Measuring the systemic risk in the South African banking sector. *South African Journal of Economic and Management Sciences*, 20(1), 1-9.
- Forte, F. D. (2019). *Network Topology of the Argentine Interbank Money Market*. Economic Research Working Papers N 87, Banco Central de la República Argentina.
- Forte, F. D. (2020). Network topology of the Argentine interbank money market. *Journal of Complex Networks*, 8(4), cnaa039.
- Freund, Y., & Schapire, R. E. (1996). Experiments with a new boosting algorithm. *Machine Learning: Proceedings of the Thirteenth International Conference*, 96, 148-156.
- Freund, Y., & Schapire, R. E. (1997). A decision-theoretic generalization of on-line learning and an application to boosting. *Journal of computer and system sciences*, 55(1), 119-139.
- Friedman, J. H. (2001). Greedy function approximation: a gradient boosting machine. *Annals of statistics*, 1189-1232.
- Gai, P., & Kapadia, S. (2010). Contagion in financial networks. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 466(2120), 2401-2423.
- Ghanbari, R., Jalili, M., & Yu, X. (2018). Correlation of cascade failures and centrality measures

- in complex networks. *Future generation computer systems*, 83, 390-400.
- Haldane, A. G., & May, R. M. (2011). Systemic risk in banking ecosystems. *Nature*, 469(7330), 351-355.
- Hernán Zeolla, N., & Médici, F. (2022). Desregulación, endeudamiento y fragilidad financiera externa: un enfoque minskiano para la crisis argentina 2018-2019. *Ensayos de Economía*, 32(60).
- Hovakimian, A., Kane, E. J., & Laeven, L. (2012). *Tracking variation in systemic risk at us banks during 1974-2013*. National Bureau of Economic Research.
- Huang, X., Zhou, H., & Zhu, H. (2009). A framework for assessing the systemic risk of major financial institutions. *Journal of Banking & Finance*, 33(11), 2036-2049.
- IMF, BIS, & FSB. (2009). Guidance to assess the systemic importance of financial institutions, markets and instruments: initial considerations. En *Report to G20 finance ministers and governors*. <https://www.bis.org/publ/othp07.htm>
- Iori, G., Jafarey, S., & Padilla, F. G. (2006). Systemic risk on the interbank market. *Journal of Economic Behavior & Organization*, 61(4), 525-542.
- Jackson, M. O., & Pernoud, A. (2021). Systemic risk in financial networks: A survey. *Annual Review of Economics*, 13, 171-202.
- Kaushik, R., & Battiston, S. (2013). Credit default swaps drawup networks: too interconnected to be stable? *PloS one*, 8(7), e61815.
- Kobayashia, T., & Takaguchib, T. (2017). *Understanding the fundamental dynamics of interbank networks*. Discussion Papers 1711. Graduate School of Economics, Kobe University.
- Kou, G., Chao, X., Peng, Y., Alsaadi, F. E., & Herrera Viedma, E. (2019). Machine learning methods for systemic risk analysis in financial sectors. *Technological and Economic Development of Economy*, 25, 716-742.
- Kuhn, M., & Johnson, K. (2013). *Applied predictive modeling* (Vol. 26). Springer.
- Kuzubaş, T. U., Ömercikoğlu, I., & Saltoğlu, B. (2014). Network centrality measures and systemic risk: An application to the Turkish financial crisis. *Physica A: Statistical Mechanics and its Applications*, 405, 203-215.
- Laeven, L., & Valencia, F. (2020). Systemic banking crises database II. *IMF Economic Review*, 68, 307-361.
- Lantz, B. (2023). *Machine learning with R: expert techniques for predictive modeling*. Packt publishing ltd.
- Lehar, A. (2005). Measuring systemic risk: A risk management approach. *Journal of Banking & Finance*, 29(10), 2577-2603.
- León, C., Machado, C., Cepeda, F., & Sarmiento, M. (2011). Too-connected-to-fail institutions and payments system's stability: Assessing challenges for financial authorities. *Borradores de Economía*, 644.
- Liu, R., & Pun, C. S. (2022). Machine-Learning-enhanced systemic risk measure: A Two-Step supervised learning approach. *Journal of Banking & Finance*, 136, 106416.
- Loepfe, L., Cabrales, A., & Sánchez, A. (2013). Towards a proper assignment of systemic risk:

- the combined roles of network topology and shock characteristics. *PloS one*, 8(10), e77526.
- Lundberg, S. M., Erion, G., Chen, H., DeGrave, A., Prutkin, J. M., Nair, B., Katz, R., Himmelfarb, J., Bansal, N., & Lee, S.-I. (2020). From local explanations to global understanding with explainable AI for trees. *Nature machine intelligence*, 2(1), 56-67.
- Lundberg, S. M., & Lee, S.-I. (2017). A unified approach to interpreting model predictions. *Advances in neural information processing systems*, 30.
- Martinez-Jaramillo, S., Alexandrova-Kabadjova, B., Bravo-Benitez, B., & Solórzano-Margain, J. P. (2014). An empirical study of the Mexican banking system's network and its implications for systemic risk. *Journal of Economic Dynamics and Control*, 40, 242-265.
- Martínez-Jaramillo, S., Pérez, O. P., Embriz, F. A., & Dey, F. L. G. (2010). Systemic risk, financial contagion and financial fragility. *Journal of Economic Dynamics and Control*, 34(11), 2358-2374.
- Molnar, C., Casalicchio, G., & Bischl, B. (2020). Interpretable machine learning: a brief history, state-of-the-art and challenges. *Joint European conference on machine learning and knowledge discovery in databases*, 417-431.
- Narayan, S., Kumar, D., & Bouri, E. (2023). Systemically important financial institutions and drivers of systemic risk: Evidence from India. *Pacific-Basin Finance Journal*, 82, 102155.
- Neveu, A. R. (2018). A survey of network-based analysis and systemic risk measurement. *Journal of Economic Interaction and Coordination*, 13, 241-281. <https://doi.org/10.1007/s11403-016-0182-z>
- Newman, M. (2018). *Networks*. Oxford university press.
- Nguyen, T. C., Castro, V., & Wood, J. (2022). A new comprehensive database of financial crises: Identification, frequency, and duration. *Economic Modelling*, 108, 105770.
- Noguera, D., & Montes-Rojas, G. (2022). Fluctuaciones con restricciones de crédito e incertidumbre en una economía de red. *Ensayos Económicos*, 80, 1-48.
- Patro, D. K., Qi, M., & Sun, X. (2013). A simple indicator of systemic risk. *Journal of Financial Stability*, 9(1), 105-116.
- Riccetti, L. (2022). Agent-based Multi-layer Network Simulations for Financial Systemic Risk Measurement: A Proposal for Future Developments. *The International Journal of Microsimulation*, 15, 44-61.
- Roukny, T., Bersini, H., Pirotte, H., Caldarelli, G., & Battiston, S. (2013). Default cascades in complex networks: Topology and systemic risk. *Scientific reports*, 3(1), 2759.
- Schwarz, S. L. (2008). Systemic risk. *Geo. Lj*, 97, 193.
- Shapley, L. S. (1953). A value for n-person games. *Contributions to the Theory of Games*, 2. <https://doi.org/10.1515/9781400881970-018>
- Silva, T. C., Souza, S. R. S., & Tabak, B. M. (2017). Monitoring vulnerability and impact diffusion in financial networks. *Journal of Economic Dynamics and Control*, 76, 109-135.
- Silva, W., Kimura, H., & Sobreiro, V. A. (2017). An analysis of the literature on systemic financial risk: A survey. *Journal of Financial Stability*, 28, 91-114.
- Tabak, B. M., Souza, S. R., & Guerra, S. M. (2013). Assessing systemic risk in the Brazilian

interbank market. *Banco Central do Brasil Working Papers*, 318, 89.

Weiß, G. N., Bostandzic, D., & Neumann, S. (2014). What factors drive systemic risk during international financial crises? *Journal of Banking & Finance*, 41, 78-96.

Comentarios finales

A lo largo de esta tesis, contribuimos al estudio del contagio y el riesgo sistémico en distintas redes económicas. El riesgo sistémico es el riesgo de que un evento adverso que tiene lugar en una parte del sistema económico se propague a otras provocando una crisis generalizada, y el contagio es el mecanismo por el cual este riesgo se propaga a través de las redes económicas. Como se argumentó en los distintos capítulos, los eventos disruptivos pueden propagarse mediante redes económicas de diferentes maneras, como a través de los vínculos establecidos entre agentes en mercados financieros, las cadenas de suministro o las relaciones comerciales. Un mejor entendimiento de las estructuras de interacción entre los agentes y de cómo se propagan distintos shocks económicos a través de ellas puede ayudar a las autoridades a diseñar políticas dirigidas a su prevención y/o a mitigar su impacto.

En líneas generales, a lo largo de los distintos capítulos mostramos que las características de la estructura de interacciones en sistemas económicos complejos pueden tener efectos significativos –tanto cualitativos como cuantitativos– en la dinámica de contagio y, por lo tanto, en los resultados económicos. En otras palabras, mostramos que los eventos en red tienen consecuencias para el riesgo general en una economía. Si los agentes (empresas, bancos, sectores productivos) están desconectados y son independientes, sus altibajos se compensan entre sí, por lo que la posibilidad de que un evento negativo a nivel de un agente individual pueda desencadenar el colapso de la economía es relativamente baja. Pero cuando los agentes están conectados en redes de dependencia –sea financiera, productiva, comercial, entre otras– esto cambia, ya que el sistema en general puede verse amenazado o colapsar como consecuencia del contagio. En este sentido, las contribuciones realizadas permiten ampliar el conocimiento acerca de cómo se comportan los sistemas económicos utilizando modelos simples que capturan las no linealidades de las interacciones entre agentes. De esta manera, tal como señala [Arthur \(2021\)](#), el campo de los sistemas complejos provee a la economía de un potente enfoque, con métodos para pensar la toma de decisiones bajo incertidumbre y abordar dinámicas y procesos estocásticos no lineales.

En específico, en el capítulo 1 estudiamos la red insumo producto a nivel global y local para analizar cómo un shock económico con un origen en particular se propaga a través de la misma, pudiendo trascender las fronteras nacionales. El enfoque propuesto integra las dimensiones sectorial, espacial (países) y temporal en un modelo insumo-producto que permite analizar distintos aspectos de la dinámica de contagio. Asimismo, se buscó trabajar con un modelo simple, intuitivo y flexible, tanto en lo que hace a los supuestos de comportamiento de los agentes como

en los requerimientos de información para su estimación. En el modelo considerado los sectores productivos (incluso en diferentes localizaciones geográficas) están conectados entre sí a través de relaciones de suministro y demanda. Cuando un sector experimenta un shock puede afectar al resto de los sectores y países con los que está conectado. El trabajo muestra que la magnitud del contagio depende en gran medida de la forma que adquiere la estructura de relaciones sectoriales productivas, tanto a nivel local como global. En este sentido, los resultados encontrados destacan la necesidad de considerar en el análisis de los efectos de políticas que afectan a la producción o demanda sectoriales, a las interrelaciones entre ramas y la posición que ocupa cada una en las redes productivas.

En el capítulo 2 nos centramos en estudiar el rol en la propagación de eventos adversos –que tienen lugar inicialmente en el sector real– de un sector específico –el financiero– en una economía nacional, a través de los vínculos crediticios entre firmas productivas y bancos. Estudiamos el contagio de dificultades financieras en una red de crédito bancario, en línea con la HIF de Minsky (1976; 1986; 2016). El modelo planteado considera que empresas y bancos están conectados entre sí de manera directa a través de relaciones de préstamos. Cuando una empresa experimenta un shock negativo, es posible que no pueda pagar sus préstamos y los bancos reaccionan incrementando la tasa ofrecida al resto de las empresas y/o racionando el crédito. Esto puede llevar a una cascada de incumplimientos y provocar una crisis financiera. A diferencia de gran parte de los aportes que modelizan formalmente la HIF de Minsky, el capítulo se centró en analizar el rol que cumple el comportamiento de las instituciones bancarias y, a su vez, destaca el valor añadido de un enfoque de agentes heterogéneos que, como señalan Nikolaidi y Stockhammer (2017), no ha sido ampliamente explorado en la literatura. Los resultados muestran que el contagio es más rápido cuando se incorporan mecanismos de racionamiento de crédito impulsados por la preferencia por la liquidez de las instituciones financieras. El trabajo muestra que el contagio es un mecanismo importante para la propagación de las crisis financieras y que las redes de crédito en evolución son más susceptibles a este fenómeno.

Finalmente, en el capítulo 3 ponemos el foco en los vínculos existentes –y el fenómeno de contagio– al interior del sistema financiero, lo cual tiene potenciales implicancias negativas para la economía real, como se estudió en el capítulo 2. En específico, estudiamos los factores que impulsan el riesgo sistémico en el mercado interbancario argentino. A nuestro conocimiento, se trata de la primera contribución que analiza el fenómeno en este mercado para el caso de Argentina, país que ha experimentado el mayor número de crisis bancarias sistémicas en los últimos 50 años a nivel mundial. Asimismo, contribuye a la emergente literatura que aplica métodos de aprendizaje automático para la evaluación del riesgo sistémico. En síntesis, encontramos que los factores impulsores del riesgo sistémico en estos mercados dependen centralmente del tamaño del shock inicial, de la naturaleza de las transacciones (garantizadas o no garantizadas) y de la dimensión cuantitativa del riesgo bajo análisis. Los resultados muestran la importancia de las características topológicas de la estructura de conexiones entre los bancos en la emergencia de este fenómeno. En particular, las medidas de centralidad –que expresan la importancia de un banco en la red

interbancaria en función de su conexión con el resto– explican en gran medida la capacidad de una institución financiera de propagar pérdidas o dificultades financieras a lo largo y ancho del mercado.

El factor común en los hallazgos de los tres capítulos se refiere a la relevancia tanto de la estructura de interacciones como de las heterogeneidades o asimetrías observadas en las variables estudiadas –ya sea el tamaño de los activos de un agente, las pérdidas sufridas por un sector, los bienes y servicios insumo-producto que fluyen a través de un sector productivo, entre otras– en la determinación del alcance y efectos de un evento adverso. Como señala Gallegati (2018), esta característica está presente en gran parte de los fenómenos económicos reales, ya que el sistema económico está compuesto por millones de agentes que interactúan, cuya distribución dista de ser normal. En este sentido, los ABM de agentes heterogéneos e interactivos parecen ser una herramienta particularmente adecuada para ampliar el conocimiento acerca de los temas cubiertos en la presente investigación. Una línea de trabajo particularmente interesante y asociada a la emergente literatura sobre la interacción entre las redes de producción insumo-producto, las redes financieras y los ABM (Baqae y Farhi, 2018), es considerar el papel de las redes productiva y financiera tanto como propagadoras de shocks –como hemos hecho–, como también el papel que desempeñan en otros procesos económicos relevantes como la innovación tecnológica (Gualdi y Mandel, 2019), la creación de nuevos productos (Cristelli *et al.*, 2017) y la dinámica en el mercado de trabajo (Dosi *et al.*, 2018b), lo que permitiría integrar los diferentes aspectos del sistema económico abordados en esta tesis.

Bibliografía

- Acemoglu, D., Akcigit, U., y Kerr, W. (2016). Networks and the macroeconomy: An empirical exploration. *Nber macroeconomics annual*, 30(1):273–335.
- Acemoglu, D., Carvalho, V. M., Ozdaglar, A., y Tahbaz-Salehi, A. (2012). The network origins of aggregate fluctuations. *Econometrica*, 80(5):1977–2016.
- Acemoglu, D., Ozdaglar, A., y Tahbaz-Salehi, A. (2015a). Networks, shocks, and systemic risk. En Bramoullé, Y., Galeotti, A., y Rogers, B., editores, *The oxford handbook on the economics of networks*. Oxford University Press, Oxford.
- Acemoglu, D., Ozdaglar, A., y Tahbaz-Salehi, A. (2015b). Systemic risk and stability in financial networks. *American Economic Review*, 105(2):564–608.
- Acharya, V. V., Pedersen, L. H., Philippon, T., y Richardson, M. (2017). Measuring systemic risk. *The review of financial studies*, 30(1):2–47.
- Adrian, T. y Brunnermeier, M. K. (2016). Covar. *The American Economic Review*, 106(7):1705.
- Alatríste Contreras, M. y Fagiolo, G. (2014). Propagation of economic shocks in input-output networks: A cross-country analysis. *Physical Review E*, 90(6):062812.
- Alexandre, M., Silva, T. C., Connaughton, C., y Rodrigues, F. A. (2021). The drivers of systemic risk in financial networks: a data-driven machine learning analysis. *Chaos, Solitons & Fractals*, 153:111588.
- Allen, F. y Gale, D. (2000). Bubbles and crises. *Economic Journal*, 110(460):236–255.
- Amini, H., Cont, R., y Minca, A. (2016). Resilience to contagion in financial networks. *Mathematical finance*, 26(2):329–365.
- Anastasi, A., Elosegui, P., y Sangiácomo, M. (2010). Determinantes de la tasa interbancaria de préstamos en argentina. *Ensayos Económicos*, 60:137–209.
- Anufriev, M. y Hommes, C. (2012). Evolutionary selection of individual expectations and aggregate outcomes in asset pricing experiments. *American Economic Journal: Microeconomics*, 4(4):35–64.

- Anufriev, M., Hommes, C., y Makarewicz, T. (2019). Simple forecasting heuristics that make us smart: Evidence from different market experiments. *Journal of the European Economic Association*, 17(5):1538–1584.
- Araújo, G. S. y Leao, S. (2013). Risco sistémico no mercado bancário brasileiro-uma abordagem pelo método covar. Technical report.
- Arestis, P. (2019). Critique of the new consensus macroeconomics and a proposal for a more keynesian macroeconomic model. En *Arestis P., Sawyer M. (eds). Frontiers of Heterodox Macroeconomics*, pp. 1–44. Springer.
- Arias, M., Mendoza-Gutiérrez, J. C., y Pérez-Reyna, D. (2010). Applying cov ar to measure systemic market risk: the colombian case. *Temas de Estabilidad Financiera*, (47).
- Arslan, I., Caverzasi, E., Gallegati, M., y Duman, A. (2016). Long term impacts of bank behavior on financial stability. an agent based modeling approach. *Journal of Artificial Societies and Social Simulation*, 19(1):11.
- Arthur, W. B. (2021). Foundations of complexity economics. *Nature Reviews Physics*, 3(2):136–145.
- Arto, I., Dietzenbacher, E., y Rueda-Cantuche, J. (2019). *Measuring bilateral trade in terms of value added*. Publications Office of the European Union.
- Assenza, T., Heemeijer, P., Hommes, C. H., y Massaro, D. (2019). Managing self-organization of expectations through monetary policy: A macro experiment. *Journal of Monetary Economics*, 117(1):170–186.
- Baptista, R., Farmer, J. D., Hinterschweiger, M., Low, K., Tang, D., y Uluc, A. (2016). Macroprudential policy in an agent-based model of the uk housing market.
- Baqae, D. R. y Farhi, E. (2018). Macroeconomics with heterogeneous agents and input-output networks. Technical report, National Bureau of Economic Research.
- Baqae, D. R. y Farhi, E. (2019). The macroeconomic impact of microeconomic shocks: Beyond hulten’s theorem. *Econometrica*, 87(4):1155–1203.
- Baqae, D. R. y Farhi, E. (2020). Productivity and misallocation in general equilibrium. *The Quarterly Journal of Economics*, 135(1):105–163.
- Barabási, A.-L. (2016). *Network Science*. Cambridge University Press.
- Barabási, A.-L. y Albert, R. (1999). Emergence of scaling in random networks. *Science*, 286:509–512.
- Bardoscia, M., Battiston, S., Caccioli, F., y Caldarelli, G. (2015). Debtrank: A microscopic foundation for shock propagation. *PloS one*, 10(6):e0130406.

- Barrera Insua, F. y Noguera, D. (2023). Determinantes salariales intersectoriales en la argentina: un modelo de análisis para las dinámicas desiguales del capital y el trabajo. *Cuadernos de economía*, 42(90).
- Barrot, J.-N. y Sauvagnat, J. (2016). Input specificity and the propagation of idiosyncratic shocks in production networks. *The Quarterly Journal of Economics*, 131(3):1543–1592.
- Battiston, S., Delli Gatti, D., Gallegati, M., Greenwald, B., y Stiglitz, J. E. (2007). Credit chains and bankruptcy propagation in production networks. *Journal of Economic Dynamics and Control*, 31(6):2061–2084.
- Battiston, S., Delli Gatti, D., Gallegati, M., Greenwald, B., y Stiglitz, J. E. (2012a). Default cascades: When does risk diversification increase stability? *Journal of Financial Stability*, 8(3):138–149.
- Battiston, S., Puliga, M., Kaushik, R., Tasca, P., y Caldarelli, G. (2012b). Debtrank: Too central to fail? financial networks, the fed and systemic risk. *Scientific reports*, 2(1):541.
- BCBS (2012). Global systemically important banks: updated assessment methodology and the higher loss absorbency requirement. *Bank for International Settlements*.
- BCBS, B. (2014). Capital requirements for bank exposures to central counterparties. *Basel Committee on Banking Supervision*.
- Bech, M. L. y Atalay, E. (2010). The topology of the federal funds market. *Physica A: Statistical mechanics and its applications*, 389(22):5223–5246.
- Bellingeri, M., Bevacqua, D., Scotognella, F., Alfieri, R., y Cassi, D. (2020). A comparative analysis of link removal strategies in real complex weighted networks. *Scientific reports*, 10(1):1–15.
- Bems, R., Johnson, R. C., y Yi, K.-M. (2010). Demand spillovers and the collapse of trade in the global recession. *IMF Economic review*, 58(2):295–326.
- Benoit, S., Colliard, J.-E., Hurlin, C., y Pérignon, C. (2017). Where the risks lie: A survey on systemic risk. *Review of Finance*, 21(1):109–152.
- Bernanke, B. (1989). Agency costs, net worth and business fluctuations. *American Economic Review*, 79(1).
- Bernanke, B. y Blinder, A. S. (1992). The federal funds rate and the transmission of monetary policy. *American Economic Review*, 82(4):901–21.
- Bernanke, B. y Gertler, M. (1990). Financial fragility and economic performance. *The quarterly journal of economics*, 105(1):87–114.

- Bernanke, B. S. y Blinder, A. S. (1988). Is it money or credit, or both, or neither. *American Economic Review*, 78(2):435–439.
- Bernanke, B. S., Gertler, M., y Gilchrist, S. (1996). The flight to quality and the financial accelerator. *Review of Economics and Statistics*, 78(1):1–15.
- Berrar, D. (2019). Cross-validation. En Ranganathan, S., Gribskov, M., Nakai, K., y Schönbach, C., editores, *Encyclopedia of Bioinformatics and Computational Biology*, pp. 542–545. Academic Press, Oxford.
- Bisias, D., Flood, M., Lo, A. W., y Valavanis, S. (2012). A survey of systemic risk analytics. *Annu. Rev. Financ. Econ.*, 4(1):255–296.
- Boneva, L., Cloyne, J., Weale, M., y Wieladek, T. (2020). Firms’ price, cost and activity expectations: Evidence from micro data. *The economic journal*, 130(627):555–586.
- Boss, M., Krenn, G., Pühr, C., y Summer, M. (2006). Systemic risk monitor: A model for systemic risk analysis and stress testing of banking systems. *Financial Stability Report*, 11(June):83–95.
- Bouwmeester, M. C. y Oosterhaven, J. (2017). Economic impacts of natural gas flow disruptions between russia and the eu. *Energy Policy*, 106:288–297.
- Breiman, L. (2001). Random forests. *Machine learning*, 45:5–32.
- Brogi, M., Lagasio, V., y Riccetti, L. (2021). Systemic risk measurement: bucketing global systemically important banks. *Annals of Finance*, 17(3):319–351.
- Brownlees, C. y Engle, R. F. (2017). Srisk: A conditional capital shortfall measure of systemic risk. *The Review of Financial Studies*, 30(1):48–79.
- Brunnermeier, M. K., Dong, G. N., y Palia, D. (2020). Banks’ noninterest income and systemic risk. *The Review of Corporate Finance Studies*, 9(2):229–255.
- Brusco, S. y Castiglionesi, F. (2007). Liquidity coinsurance, moral hazard, and financial contagion. *The Journal of Finance*, 62(5):2275–2302.
- Cabrales, A., Gottardi, P., y Vega-Redondo, F. (2017). Risk sharing and contagion in networks. *The Review of Financial Studies*, 30(9):3086–3127.
- Caccioli, F., Catanach, T. A., y Farmer, J. D. (2012). Heterogeneity, correlations and financial contagion. *Advances in Complex Systems*, 15(supp02):1250058.
- Caiani, A., Godin, A., Caverzasi, E., Gallegati, M., Kinsella, S., y Stiglitz, J. E. (2016). Agent based-stock flow consistent macroeconomics: Towards a benchmark model. *Journal of Economic Dynamics and Control*, 69:375–408.
- Carvalho, V. y Gabaix, X. (2013). The great diversification and its undoing. *American Economic Review*, 103(5):1697–1727.

- Caverzasi, E. (2014). Minsky and the subprime mortgage crisis: The financial instability hypothesis in the era of financialization. *Economics Working Paper Archive 796*, Levy Economics Institute.
- Chen, S.-H., Chang, C.-L., y Du, Y.-R. (2012). Agent-based economic models and econometrics. *The Knowledge Engineering Review*, 27(2):187–219.
- Chen, T. y Guestrin, C. (2016). Xgboost: A scalable tree boosting system. En *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*, pp. 785–794.
- Chiarella, C. y Di Guilmi, C. (2011). The financial instability hypothesis: A stochastic microfoundation framework. *Journal of Economic Dynamics and Control*, 35(8):1151–1171.
- Chinazzi, M. y Fagiolo, G. (2013). Systemic risk, contagion, and financial networks: A survey. Technical report, Institute of Economics, Scuola Superiore Sant’Anna, Laboratory of Economics and Management (LEM) Working Paper Series No. 2013/08.
- Christ, C. F. (1955). A review of input-output analysis. *Input-output analysis: An appraisal*, pp. 137–182.
- Clauset, A., Shalizi, C. R., y Newman, M. E. J. (2009). Power-law distributions in empirical data. *SIAM Review*, 51(4):661–703.
- Cochrane, J. (2009). *Asset pricing: Revised edition*. Princeton university press.
- Coibion, O., Gorodnichenko, Y., y Kumar, S. (2018). How do firms form their expectations? new survey evidence. *American Economic Review*, 108(9):2671–2713.
- Conley, T. G. y Dopor, B. (2003). A spatial analysis of sectoral complementarity. *Journal of political Economy*, 111(2):311–352.
- Cortes, G. S., Silva, T. C., y Doornik, B. F. N. V. (2019). Credit Shock Propagation in Firm Networks: evidence from government bank credit expansions. Working Papers Series 507, Central Bank of Brazil, Research Department.
- Costa, L. d. F., Oliveira Jr, O. N., Travieso, G., Rodrigues, F. A., Villas Boas, P. R., Antiqueira, L., Viana, M. P., y Correa Rocha, L. E. (2011). Analyzing and modeling real-world phenomena with complex networks: a survey of applications. *Advances in Physics*, 60(3):329–412.
- Costa, S., Sallusti, F., y Vicarelli, C. (2022). Trade networks and shock transmission capacity: a new taxonomy of italian industries. *Journal of Industrial and Business Economics*, 49(1):133–153.
- Costa, S., Sallusti, F., Vicarelli, C., y Zurlo, D. (2021). From micro to macro: Micro-foundations of the italian business cycle co-movements during the crises. *Italian Economic Journal*, pp. 1–24.

- Cresti, L., Dosi, G., y Fagiolo, G. (2023). Technological interdependencies and employment changes in european industries. *Structural Change and Economic Dynamics*, 64:41–57.
- Cristelli, M. C. A., Tacchella, A., Cader, M. Z., Roster, K. I., y Pietronero, L. (2017). On the predictability of growth. *World Bank Policy Research Working Paper*, (8117).
- Céspedes, J., González, M., y Molina Manzano, C. (2010). Ownership and capital structure in Latin America. *Journal of Business Research*, 63(3):248–254.
- Danielsson, J., James, K. R., Valenzuela, M., y Zer, I. (2016). Model risk of risk models. *Journal of Financial Stability*, 23:79–91.
- D’Anieri, P. (2023). *Ukraine and Russia*. Cambridge University Press.
- Dawid, H. y Delli Gatti, D. (2018). Agent-based macroeconomics. En *Handbook of computational economics*, volumen 4, pp. 63–156. Elsevier.
- De Jonghe, O. (2010). Back to the basics in banking? a micro-analysis of banking system stability. *Journal of financial intermediation*, 19(3):387–417.
- De Masi, G., Fujiwara, Y., Gallegati, M., Greenwald, B., y Stiglitz, J. E. (2015). An analysis of the japanese credit network. *Evolutionary and Institutional Economics Review*, 7(2):209–232.
- De Masi, G. y Gallegati, M. (2012). Bank–firms topology in italy. *Empirical Economics*, 43(2):851–866.
- del Rio-Chanona, R. M., Mealy, P., Pichler, A., Lafond, F., y Farmer, J. D. (2020). Supply and demand shocks in the covid-19 pandemic: an industry and occupation perspective. *Oxford Review of Economic Policy*, 36(S1):S94–S137.
- Delli Gatti, D., Desiderio, S., Gaffeo, E., Cirillo, P., y Gallegati, M. (2011). *Macroeconomics from the Bottom-up*, volumen 1. Springer Science & Business Media.
- Delli Gatti, D., Di Guilmi, C., Gaffeo, E., Giulioni, G., Gallegati, M., y Palestrini, A. (2005). A new approach to business fluctuations: heterogeneous interacting agents, scaling laws and financial fragility. *Journal of Economic Behavior & Organization*, 56(4):489–512.
- Delli Gatti, D., Fagiolo, G., Gallegati, M., Richiardi, M., y Russo, A. (2018). *Agent-based models in economics: a toolkit*. Cambridge University Press.
- Delli Gatti, D., Gaffeo, E., Gallegati, M., Giulioni, G., Kirman, A., Palestrini, A., y Russo, A. (2007). Complex dynamics and empirical evidence. *Information Sciences*, 177(5):1204–1221.
- Delli Gatti, D., Gallegati, M., Greenwald, B., Russo, A., y Stiglitz, J. E. (2010). The financial accelerator in an evolving credit network. *Journal of Economic Dynamics and Control*, 34(9):1627–1650.

- Delli Gatti, D., Palestrini, A., Gaffeo, E., Giulioni, G., y Gallegati, M. (2008). *Emergent macroeconomics: An agent-based approach to business fluctuations*. Springer.
- Delli Gatti, D. y Reissl, S. (2022). Agent-based covid economics (abc): Assessing non-pharmaceutical interventions and macro-stabilization policies. *Industrial and Corporate Change*, 31(2):410–447.
- DePaolis, F., Murphy, P., y De Paolis Kaluza, M. C. (2022). Identifying key sectors in the regional economy: a network analysis approach using input–output data. *Applied Network Science*, 7(1):86.
- D’Erasmus, P., Moscoso Boedo, H., Olivero, M. P., y Sangiácomo, M. (2020). Relationship networks in banking around a sovereign default and currency crisis. *IMF Economic Review*, 0:1–59.
- Di Giovanni, J., Levchenko, A. A., y Mejean, I. (2014). Firms, destinations, and aggregate fluctuations. *Econometrica*, 82(4):1303–1340.
- Di Giovanni, J., Levchenko, A. A., y Mejean, I. (2018). The micro origins of international business-cycle comovement. *American Economic Review*, 108(1):82–108.
- Di Guilmi, C. (2017). The agent-based approach to post keynesian macro-modeling. *Journal of Economic Surveys*, 31(5):1183–1203.
- Di Guilmi, C., Gallegati, M., Landini, S., y Stiglitz, J. (2020). An analytical solution for network models with heterogeneous and interacting agents. *Journal of Economic Behavior & Organization*, 171:189–220.
- Di Iasio, G., Battiston, S., Infante, L., y Pierobon, F. (2015). Capital and contagion in financial networks, IFC Bulletins Chapters. En *Indicators to support monetary and financial stability analysis: data sources and statistical methodologies*, volumen 39, pp. 1–23. Bank for International Settlements (Ed).
- Dietterich, T. G. (2000). An experimental comparison of three methods for constructing ensembles of decision trees: Bagging, boosting, and randomization. *Machine learning*, 40:139–157.
- Dosi, G., Fagiolo, G., y Roventini, A. (2006). An evolutionary model of endogenous business cycles. *Computational Economics*, 27:3–34.
- Dosi, G., Faillo, M., y Marengo, L. (2018a). Beyond "bounded rationality": Behaviours and learning in complex evolving worlds. Technical report, LEM Working Paper Series.
- Dosi, G., Napoletano, M., Roventini, A., Stiglitz, J. E., y Treibich, T. (2020). Rational heuristics? expectations and behaviors in evolving economies with heterogeneous interacting agents. *Economic Inquiry*, 58(3):1487–1516.

- Dosi, G., Pereira, M. C., Roventini, A., y Virgillito, M. E. (2018b). The effects of labour market reforms upon unemployment and income inequalities: an agent-based model. *Socio-Economic Review*, 16(4):687–720.
- Dosi, G. y Roventini, A. (2019). More is different... and complex! the case for agent-based macroeconomics. *Journal of Evolutionary Economics*, 29(1):1–37.
- Dow, A. C. y Dow, S. C. (1989). Endogenous money creation and idle balances. En *Pheby, J. (Ed.). New directions in post-Keynesian economics*. Edward Elgar Aldershot.
- Duchin, F. (1983). The world model: An interregional input-output model of the world economy. *Contributions to Economic Analysis*, 147:167–182.
- Durán Lima, J. E. y Banacloche, S. (2021). Análisis económicos a partir de matrices de insumo-producto: definiciones, indicadores y aplicaciones para américa latina.
- Eboli, M. (2019). A flow network analysis of direct balance-sheet contagion in financial networks. *Journal of Economic Dynamics and Control*, 103(C):205–233.
- Elosegui, P., Forte, F. D., y Montes-Rojas, G. (2022). Network structure and fragmentation of the argentinean interbank markets. *Latin American Journal of Central Banking*, 3(3):100066.
- Elosegui, P. y Montes-Rojas, G. (2020). Network effects in interbank markets of call and repo in Argentina. *Ensayos Económicos*, 1(75):50–81.
- Emmert-Streib, F., Tripathi, S., Yli-Harja, O., y Dehmer, M. (2018). Understanding the world economy in terms of networks: a survey of data-based network science approaches on economic networks. *Frontiers in Applied Mathematics and Statistics*, 4:37.
- Epstein, J. M. (2006). Remarks on the foundations of agent-based generative social science. *Handbook of computational economics*, 2:1585–1604.
- Estrada, E. (2012). *The structure of complex networks: theory and applications*. Oxford University Press, USA.
- Evanoff, D. D. y Moeller, W. F. (2012). Dodd–frank: Content, purpose, implementation status, and issues. *Economic Perspectives*, 36(Q III):75–84.
- Evans, G. W. y Honkapohja, S. (2001). *Learning and expectations in macroeconomics*. Princeton University Press.
- Fagiolo, G., Reyes, J., y Schiavo, S. (2009). World-trade web: Topological properties, dynamics, and evolution. *Physical Review E*, 79(3):036115.
- Fang, L., Sun, B., Li, H., y Yu, H. (2018). Systemic risk network of chinese financial institutions. *Emerging Markets Review*, 35:190–206.

- Farmer, J. D. y Foley, D. (2009). The economy needs agent-based modelling. *Nature*, 460(7256):685–686.
- Fernandez-Stark, K. y Gereffi, G. (2019). Global value chain analysis: A primer. En *Handbook on global value chains*, pp. 54–76. Edward Elgar Publishing.
- Foggitt, G. M., Heymans, A., van Vuuren, G. W., y Pretorius, A. (2017). Measuring the systemic risk in the south african banking sector. *South African Journal of Economic and Management Sciences*, 20(1):1–9.
- Forte, F. D. (2019). Network topology of the argentine interbank money market. Technical report, Economic Research Working Papers N 87, Banco Central de la República Argentina.
- Forte, F. D. (2020). Network topology of the argentine interbank money market. *Journal of Complex Networks*, 8(4):cnaa039.
- Freund, Y. y Schapire, R. E. (1996). Experiments with a new boosting algorithm. En *Machine Learning: Proceedings of the Thirteenth International Conference*, volumen 96, pp. 148–156.
- Freund, Y. y Schapire, R. E. (1997). A decision-theoretic generalization of on-line learning and an application to boosting. *Journal of computer and system sciences*, 55(1):119–139.
- Friedman, J. H. (2001). Greedy function approximation: a gradient boosting machine. *Annals of statistics*, pp. 1189–1232.
- Gabaix, X. (2011). The granular origins of aggregate fluctuations. *Econometrica*, 79(3):733–772.
- Gai, P. y Kapadia, S. (2010). Contagion in financial networks. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 466(2120):2401–2423.
- Gai, P. y Kapadia, S. (2019). Networks and systemic risk in the financial system. *Oxford Review of Economic Policy*, 35(4):586–613.
- Galbusera, L. y Giannopoulos, G. (2018). On input-output economic models in disaster impact assessment. *International journal of disaster risk reduction*, 30:186–198.
- Gallegati, M. (2018). *Complex agent-based models*. Springer.
- Gallegati, M., Keen, S., Lux, T., y Ormerod, P. (2006). Worrying trends in econophysics. *Physica A: Statistical Mechanics and its Applications*, 370(1):1 – 6. Econophysics Colloquium.
- Ghanbari, R., Jalili, M., y Yu, X. (2018). Correlation of cascade failures and centrality measures in complex networks. *Future generation computer systems*, 83:390–400.
- Gigerenzer, G. (2015). *Risk savvy: How to make good decisions*. Penguin.
- Gilli, M. y Winker, P. (2003). A global optimization heuristic for estimating agent based models. *Computational Statistics & Data Analysis*, 42(3):299–312.

- Giuliani, E. (2013). Network dynamics in regional clusters: Evidence from Chile. *Research Policy*, 42(8):1406–1419.
- Gomes, O. y Gubareva, M. (2021). Complex systems in economics and where to find them. *Journal of Systems Science and Complexity*, 34:314–338.
- Gourieroux, C., Monfort, A., y Renault, E. (1993). Indirect inference. *Journal of applied econometrics*, 8(S1):S85–S118.
- Grazzini, J. y Richiardi, M. (2015). Estimation of ergodic agent-based models by simulated minimum distance. *Journal of Economic Dynamics and Control*, 51:148–165.
- Greenwald, B. C. y Stiglitz, J. E. (1993). Financial market imperfections and business cycles. *The Quarterly Journal of Economics*, 108(1):77–114.
- Gualdi, S. y Mandel, A. (2019). Endogenous growth in production networks. *Journal of Evolutionary Economics*, 29:91–117.
- Guilhoto, J., Webb, C., y Yamano, N. (2022). Guide to oecd tiva indicators, 2021 edition. Working Paper 2022/02, OECD Science, Technology and Industry Working Papers.
- Gusella, F. (2022). Detecting and measuring financial cycles in heterogeneous agents models: An empirical analysis. *Advances in Complex Systems*.
- Gusella, F. y Stockhammer, E. (2021). Testing fundamentalist–momentum trader financial cycles: An empirical analysis via the kalman filter. *Metroeconomica*, 72(4):758–797.
- Haldane, A. G. y May, R. M. (2011). Systemic risk in banking ecosystems. *Nature*, 469(7330):351–355.
- Hernán Zeolla, N. y Médici, F. (2022). Desregulación, endeudamiento y fragilidad financiera externa: un enfoque minskiano para la crisis argentina 2018-2019. *Ensayos de Economía*, 32(60).
- Hommes, C., He, M., Poledna, S., Siqueira, M., y Zhang, Y. (2022). Canvas: A canadian behavioral agent-based model. Technical report, Bank of Canada.
- Hovakimian, A., Kane, E. J., y Laeven, L. (2012). Tracking variation in systemic risk at us banks during 1974-2013. Technical report, National Bureau of Economic Research.
- Huang, X., Zhou, H., y Zhu, H. (2009). A framework for assessing the systemic risk of major financial institutions. *Journal of Banking & Finance*, 33(11):2036–2049.
- Iliopoulos, P. T., Galanis, G., Kumar, A., y Popoyan, L. (2022). Sectoral market power in global production: a theoretical and observational study. *Advances in Complex Systems*, 25(02n03):2240005.

- IMF, BIS, y FSB (2009). Guidance to assess the systemic importance of financial institutions, markets and instruments: initial considerations. Technical report.
- Iori, G., Jafarey, S., y Padilla, F. G. (2006). Systemic risk on the interbank market. *Journal of Economic Behavior & Organization*, 61(4):525–542.
- Jackson, M. O. y Pernoud, A. (2021). Systemic risk in financial networks: A survey. *Annual Review of Economics*, 13:171–202.
- Jackson, M. O. y Watts, A. (2002). The evolution of social and economic networks. *Journal of economic theory*, 106(2):265–295.
- Kaushik, R. y Battiston, S. (2013). Credit default swaps drawup networks: too interconnected to be stable? *PloS one*, 8(7):e61815.
- Keynes, J. M. (1930). *Treatise on money*. MacMillan.
- Keynes, J. M. (1936). *The general theory of interest, employment and money*. MacMillan.
- Kirman, A. (2010). The economic crisis is a crisis for economic theory. *CESifo Economic Studies*, 56(4):498–535.
- Kiyotaki, N. y Moore, J. (1997). Credit cycles. *Journal of political economy*, 105(2):211–248.
- Kleinberg, J. M. (1999). Authoritative sources in a hyperlinked environment. *Journal of the ACM (JACM)*, 46(5):604–632.
- Kobayashia, T. y Takaguchib, T. (2017). Understanding the fundamental dynamics of interbank networks. Technical report, Discussion Papers 1711. Graduate School of Economics, Kobe University.
- Koks, E., Pant, R., Husby, T., Többen, J., y Oosterhaven, J. (2019). Multiregional disaster impact models: Recent advances and comparison of outcomes. *Advances in spatial and economic modeling of disaster impacts*, pp. 191–218.
- Kou, G., Chao, X., Peng, Y., Alsaadi, F. E., y Herrera Viedma, E. (2019). Machine learning methods for systemic risk analysis in financial sectors. *Technological and Economic Development of Economy*, 25:716–742.
- Kuhn, M. y Johnson, K. (2013). *Applied predictive modeling*, volumen 26. Springer.
- Kukacka, J. y Barunik, J. (2017). Estimation of financial agent-based models with simulated maximum likelihood. *Journal of Economic Dynamics and Control*, 85:21–45.
- Kuzubaş, T. U., Ömercikoğlu, I., y Saltoğlu, B. (2014). Network centrality measures and systemic risk: An application to the turkish financial crisis. *Physica A: Statistical Mechanics and its Applications*, 405:203–215.

- Laeven, L. y Valencia, F. (2020). Systemic banking crises database ii. *IMF Economic Review*, 68:307–361.
- Lamperti, F. (2018). An information theoretic criterion for empirical validation of simulation models. *Econometrics and Statistics*, 5:83–106.
- Lantz, B. (2023). *Machine learning with R: expert techniques for predictive modeling*. Packt publishing ltd.
- Lavoie, M. (2009). *Introduction to post-Keynesian economics*. Springer.
- Lavoie, M. (2014). *Post-Keynesian economics: new foundations*. Edward Elgar Publishing.
- Lavoie, M. y Seccareccia, M. (2001). Minsky’s financial fragility hypothesis: a missing macroeconomic link. *Financial fragility and investment in the capitalist economy: The economic legacy of Hyman Minsky*, 2:76–96.
- LeBaron, B. y Tesfatsion, L. (2008). Modeling macroeconomies as open-ended dynamic systems of interacting agents. *American Economic Review*, 98(2):246–50.
- Lehar, A. (2005). Measuring systemic risk: A risk management approach. *Journal of Banking & Finance*, 29(10):2577–2603.
- León, C., Machado, C., Cepeda, F., y Sarmiento, M. (2011). Too-connected-to-fail institutions and payments system’s stability: Assessing challenges for financial authorities. *Borradores de Economía*, (644).
- Leontief, W. (1986). *Input-output economics*. Oxford University Press.
- Leontief, W. W. (1936). Quantitative input and output relations in the economic systems of the united states. *The review of economic statistics*, pp. 105–125.
- Liu, R. y Pun, C. S. (2022). Machine-learning-enhanced systemic risk measure: A two-step supervised learning approach. *Journal of Banking & Finance*, 136:106416.
- Loepfe, L., Cabrales, A., y Sánchez, A. (2013). Towards a proper assignment of systemic risk: the combined roles of network topology and shock characteristics. *PloS one*, 8(10):e77526.
- Long, J. B. y Plosser, C. I. (1983). Real business cycles. *Journal of political Economy*, 91(1):39–69.
- Lundberg, S. M., Erion, G., Chen, H., DeGrave, A., Prutkin, J. M., Nair, B., Katz, R., Himmelfarb, J., Bansal, N., y Lee, S.-I. (2020). From local explanations to global understanding with explainable ai for trees. *Nature machine intelligence*, 2(1):56–67.
- Lundberg, S. M. y Lee, S.-I. (2017). A unified approach to interpreting model predictions. *Advances in neural information processing systems*, 30.

- Maquieira, C. P., Preve, L. A., y Sarria-Allende, V. (2012). Theory and practice of corporate finance: Evidence and distinctive features in latin america. *Emerging markets review*, 13(2):118–148.
- Martinez-Jaramillo, S., Alexandrova-Kabadjova, B., Bravo-Benitez, B., y Solórzano-Margain, J. P. (2014). An empirical study of the mexican banking system’s network and its implications for systemic risk. *Journal of Economic Dynamics and Control*, 40:242–265.
- Martínez-Jaramillo, S., Pérez, O. P., Embriz, F. A., y Dey, F. L. G. (2010). Systemic risk, financial contagion and financial fragility. *Journal of Economic Dynamics and Control*, 34(11):2358–2374.
- Martinez Peria, M. S. y Mody, A. (2004). How foreign participation and market concentration impact bank spreads: Evidence from Latin America. *Journal of Money, Credit and Banking*, 36(3):511–537.
- Mazzarisi, P., Barucca, P., Lillo, F., y Tantari, D. (2020). A dynamic network model with persistent links and node-specific latent variables, with an application to the interbank market. *European Journal of Operational Research*, 281(1):50–65.
- Miller, R. E. y Blair, P. D. (2009). *Input-output analysis: foundations and extensions*. Cambridge university press.
- Minsky, H. P. (1976). *John Maynard Keynes*. Springer.
- Minsky, H. P. (1986). *Stabilizing an unstable economy*. McGraw-Hill Education.
- Minsky, H. P. (2016). *Can it happen again?: Essays on instability and finance*. Routledge. First Edition: 1981.
- Miyazawa, K. (1968). Input-output analysis and interrelational income multiplier as a matrix. *Hitotsubashi Journal of Economics*, 8(2):39–58.
- Molnar, C., Casalicchio, G., y Bischl, B. (2020). Interpretable machine learning: a brief history, state-of-the-art and challenges. En *Joint European conference on machine learning and knowledge discovery in databases*, pp. 417–431. Springer.
- Mottaleb, K. A., Kruseman, G., y Snapp, S. (2022). Potential impacts of ukraine-russia armed conflict on global wheat food security: A quantitative exploration. *Global Food Security*, 35:100659.
- Narayan, S., Kumar, D., y Bouri, E. (2023). Systemically important financial institutions and drivers of systemic risk: Evidence from india. *Pacific-Basin Finance Journal*, 82:102155.
- Neveu, A. R. (2018). A survey of network-based analysis and systemic risk measurement. *Journal of Economic Interaction and Coordination*, 13:241–281.
- Newman, M. (2018). *Networks*. Oxford university press.

- Nguyen, T. C., Castro, V., y Wood, J. (2022). A new comprehensive database of financial crises: Identification, frequency, and duration. *Economic Modelling*, 108:105770.
- Nikolaïdi, M. (2014). Margins of safety and instability in a macrodynamic model with minskyan insights. *Structural Change and Economic Dynamics*, 31:1–16.
- Nikolaïdi, M. y Stockhammer, E. (2017). Minsky models: A structured survey. *Journal of Economic Surveys*, 31(5):1304–1331.
- Noguera, D. y Montes-Rojas, G. (2022). Fluctuaciones con restricciones de crédito e incertidumbre en una economía de red. *Ensayos Económicos*, 80:1–48.
- Noguera, D. y Montes-Rojas, G. (2023). Los efectos directos e indirectos de un shock sectorial asimétrico a nivel global. un análisis dinámico de las relaciones insumo-producto. Technical Report 111, Banco Central de la República Argentina.
- Okuyama, Y. (2007). Economic modeling for disaster impact analysis: past, present, and future. *Economic Systems Research*, 19(2):115–124.
- Oosterhaven, J. y Bouwmeester, M. C. (2016). A new approach to modeling the impact of disruptive events. *Journal of Regional Science*, 56(4):583–595.
- Patro, D. K., Qi, M., y Sun, X. (2013). A simple indicator of systemic risk. *Journal of Financial Stability*, 9(1):105–116.
- Perdana, S., Vielle, M., y Schenckery, M. (2022). European economic impacts of cutting energy imports from russia: A computable general equilibrium analysis. *Energy Strategy Reviews*, 44:101006.
- Pichler, A., Pangallo, M., del Rio-Chanona, R. M., Lafond, F., y Farmer, J. D. (2022). Forecasting the propagation of pandemic shocks with a dynamic input-output model. *Journal of Economic Dynamics and Control*, 144:104527.
- Reissl, S. (2021). Heterogeneous expectations, forecasting behaviour and policy experiments in a hybrid agent-based stock-flow-consistent model. *Journal of Evolutionary Economics*, 31(1):251–299.
- Reissl, S., Caiani, A., Lamperti, F., Guerini, M., Vanni, F., Fagiolo, G., Ferraresi, T., Ghezzi, L., Napoletano, M., y Roventini, A. (2022). Assessing the economic impact of lockdowns in italy: A computational input–output approach. *Industrial and Corporate Change*, 31(2):358–409.
- Riccetti, L. (2022). Agent-based multi-layer network simulations for financial systemic risk measurement: A proposal for future developments. *The International Journal of Microsimulation*, 15:44–61.
- Riccetti, L., Russo, A., y Gallegati, M. (2013). Leveraged network-based financial accelerator. *Journal of Economic Dynamics and Control*, 37(8):1626–1640.

- Riccetti, L., Russo, A., y Gallegati, M. (2016a). Stock market dynamics, leveraged network-based financial accelerator and monetary policy. *International Review of Economics & Finance*, 43(C):509–524.
- Riccetti, L., Russo, A., y Gallegati, M. (2016b). Stock market dynamics, leveraged network-based financial accelerator and monetary policy. *International Review of Economics & Finance*, 43:509–524.
- Romanoff, E. y Levine, S. H. (1986). Capacity limitations, inventory, and time-phased production in the sequential interindustry model. *Papers in Regional Science*, 59(1):73–91.
- Roukny, T., Bersini, H., Pirotte, H., Caldarelli, G., y Battiston, S. (2013). Default cascades in complex networks: Topology and systemic risk. *Scientific reports*, 3(1):2759.
- Russo, A., Catalano, M., Gaffeo, E., Gallegati, M., y Napoletano, M. (2007). Industrial dynamics, fiscal policy and r&d: Evidence from a computational experiment. *Journal of Economic Behavior & Organization*, 64(3-4):426–447.
- Saunders, A. y Schumacher, L. (2000). The determinants of bank interest rate margins: an international study. *Journal of international Money and Finance*, 19(6):813–832.
- Schmitt, N. y Westerhoff, F. (2021). Trend followers, contrarians and fundamentalists: Explaining the dynamics of financial markets. *Journal of Economic Behavior & Organization*, 192:117–136.
- Schularick, M. y Taylor, A. M. (2012). Credit booms gone bust: Monetary policy, leverage cycles, and financial crises, 1870-2008. *American Economic Review*, 102(2):1029–1061.
- Schwarcz, S. L. (2008). Systemic risk. *Geo. Lj*, 97:193.
- Schweitzer, F., Fagiolo, G., Sornette, D., Vega-Redondo, F., y White, D. R. (2009). Economic networks: What do we know and what do we need to know? *Advances in Complex Systems*, 12(04n05):407–422.
- Shapley, L. S. (1953). A value for n-person games. *Contributions to the Theory of Games*, 2.
- Shea, J. (2002). Complementarities and comovements. *Journal of Money, Credit, and Banking*, 34(2):412–433.
- Silva, T. C., da Silva, M. A., y Tabak, B. M. (2016). Modeling Financial Networks: a feedback approach. Working Papers Series 438, Central Bank of Brazil, Research Department.
- Silva, T. C., Souza, S. R. S., y Tabak, B. M. (2017a). Monitoring vulnerability and impact diffusion in financial networks. *Journal of Economic Dynamics and Control*, 76:109–135.
- Silva, W., Kimura, H., y Sobreiro, V. A. (2017b). An analysis of the literature on systemic financial risk: A survey. *Journal of Financial Stability*, 28:91–114.

- Sornette, D. (2017). *Why stock markets crash: critical events in complex financial systems*, volumen 49. Princeton University Press.
- Sraffa, P. (1960). *Production of Commodities by Means of Commodities: Prelude to a Critique of Economic Theory*. Cambridge University Press.
- Stiglitz, J. y Greenwald, B. (2003). *Towards a new paradigm in monetary economics*. Cambridge University Press.
- Stiglitz, J. E. (2018). Where modern macroeconomics went wrong. *Oxford Review of Economic Policy*, 34(1-2):70–106.
- Tabak, B. M., Souza, S. R., y Guerra, S. M. (2013). Assessing systemic risk in the brazilian interbank market. *Banco Central do Brasil Working Papers*, (318):89.
- Tedeschi, G., Recchioni, M. C., y Berardi, S. (2019). An approach to identifying micro behavior: How banks' strategies influence financial cycles. *Journal of Economic Behavior & Organization*, 162:329–346.
- Tesfatsion, L. y Judd, K. L. (2006). *Handbook of computational economics: agent-based computational economics*. Elsevier.
- Turrell, A. (2016). Agent-based models: understanding the economy from the bottom up. *Bank of England Quarterly Bulletin*, p. Q4.
- Umar, Z., Polat, O., Choi, S.-Y., y Teplova, T. (2022). The impact of the russia-ukraine conflict on the connectedness of financial markets. *Finance Research Letters*, 48:102976.
- Wagner, W. (2011). Systemic liquidation risk and the diversity–diversification trade-off. *Journal of Finance*, 66(4):1141–1175.
- Weiß, G. N., Bostandzic, D., y Neumann, S. (2014). What factors drive systemic risk during international financial crises? *Journal of Banking & Finance*, 41:78–96.