



UNIVERSIDAD  
DE SANTIAGO  
DE CHILE



**Ignacio Andrés Torres-Ulloa**

itorres@fen.uchile.cl

<sup>1</sup>Departamento de Ingeniería Industrial,  
Facultad de Ciencias Físicas y Matemáticas,  
Universidad de Chile.

<sup>2</sup>Abdul Latif Jameel Poverty Action Lab  
(J-PAL) - Latinoamérica y el Caribe  
<https://orcid.org/0000-0003-2114-3660>

Artículo recibido: 25 de abril de 2021

Artículo aceptado: 12 de julio de 2021

Artículo publicado: 31 de julio de 2021



Artículo de Investigación  
<https://doi.org/10.35588/cc.v2i1.4907>

## Evidencia y explicación en economía: modelos, RCTs y su amalgama

### *Evidence and Explanation in Economics: Models, RCTs and their Amalgamation*

#### **Resumen**

En economía, la investigación se divide en dos grandes metodologías: los modelos teórico-matemáticos y los estudios empíricos. Estudiando modelos teóricos y métodos empíricos (ejemplificados en *Randomized Controlled Trial* (i.e. RCT)) se da cuenta de las limitaciones de ambos métodos. Se concluye que ninguno de estos puede generar explicaciones de cómo en realidad suceden las cosas, sino que solo de cómo *posiblemente* suceden. La razón es que ambos necesitan un enlace interpretativo que permita extrapolar desde su propio sistema (i.e. el del modelo y el del estudio empírico, respectivamente) hacia un sistema objetivo.

Los modelos tienen dominio general y pueden dar cuenta de mecanismos. Los RCTs, al contrario, son válidos internamente (si cumplen ciertas condiciones) y están conectados al mundo real, pero su dominio es muy específico. Aunque ninguno logre responder preguntas amplias de un fenómeno de interés, pueden complementarse para generar extrapolaciones más confiables sobre un sistema objetivo. Sin embargo, esto solo podrá hacerse si se conocen bien los mecanismos y el contexto en que ocurre una evidencia.

**Palabras clave:** Causalidad, Mecanismos, Capacidades, Epistemología de la economía, Generalización de evidencia.

#### **Abstract**

In economics, research is divided into two major methodologies: theoretical-mathematical models and empirical studies. By studying theoretical models and empirical methods (exemplified by Randomized Controlled Trials (i.e. RCT)) we show the limitations of both methods, concluding that neither of these can develop explanations of how things actually happen, but only how possibly happen, since both need an interpretative link that allows extrapolation from their own system (i.e. the one of the model and the one of the empirical study, respectively) to a target system.

Models have a general domain and can account for mechanisms. On the other hand, RCTs are internally valid and connected to the real world, but with a very specific domain. Although neither can answer broad questions about a phenomenon of interest, they can complement each other in order to generate more reliable extrapolations about a target system. Nevertheless, this can only be done if the mechanisms and the context in which an evidence occurs are well known.

**Keywords:** Causality, Mechanisms, Capacities, Epistemology of Economics, Evidence Generalizability.

## 1. Introducción

El estudio de la economía se puede dividir en dos corrientes principales que, en ocasiones, se postulan como contrarias: los estudios teóricos, a través del uso de modelos, y los estudios empíricos, a través del uso de experimentos y cuasi-experimentos. Los primeros comenzaron a desarrollarse a fines del siglo XIX con la llamada “Revolución Marginalista”, en la cual, bajo la pretensión de que la economía puede estudiarse de forma similar a la física (Mirowski, 1992; Hausman y Simon, 1992), la matemática, el cálculo y la maximización se volvieron las herramientas principales del economista (Duran, 2014). Por otro lado, los estudios empíricos comenzaron a extenderse durante la década de los 70’, haciendo un contrapeso a la economía teórica. Esta extensión, que va de la mano de la estadística y los sistemas computacionales, incluso ha sido llamada “Revolución Empírica” (Angrist y Pischke, 2010).

La Revolución Empírica, o *Empirical Shift* (i.e. Giro Empírico), está ligada a una *Revolución de Credibilidad* en la disciplina<sup>1</sup>. Esta última pretende, a partir del análisis empírico, responder preguntas prácticas en temas aplicados o “del mundo real”, como lo son la educación, la salud o el empleo (Panhans y Singleton, 2017). Todo esto ha estado ligado a un cambio en la orientación de las publicaciones académicas en revistas especializadas. Si en 1960 un 50% de las publicaciones eran teóricas y el resto empíricas, para 2011 solo un 30% de las publicaciones serían teóricas y el resto empíricas (Hamermesh, 2013). Al mismo tiempo, se ha observado un cambio en el uso de los métodos empíricos, pasando de aquellos cuasi-experimentales a los métodos experimentales (o RCTs). Se ha adjudicado a estos últimos mayor credibilidad en un proceso que ha sido llamado el “Giro Experimental” (Svorenčák, 2015).




Figura 1: Metodología usada en publicaciones económicas 1963-2011 (Hamermesh, 2013).

La rapidez de estos cambios metodológicos, que han sucedido en solo 100 años, ha generado discusión entre los académicos. Sin embargo, no existe claridad sobre qué camino debe tomar la metodología para estudiar los fenómenos económicos, entendiendo por estos últimos los sucesos del ámbito económico que

<sup>1</sup> N. del. E.: La traducción tanto de términos como de párrafos desde el inglés fue realizada por el autor.

pueden ser observados o medidos, tales como la inflación, el empleo, el nivel de aprendizaje o la respuesta a una intervención. Los modelos teóricos son cuestionados al ser poco creíbles, lo que ha llevado al Giro Empírico (Panhans y Singleton, 2017). Al mismo tiempo, los estudios empíricos han sido criticados por ser demasiado locales y poco generalizables para diferentes contextos, haciendo difícil extrapolar los resultados del contexto en que se realiza el estudio a otro en que se desea aplicar una política (Deaton y Cartwright, 2018).

Lo hasta aquí expuesto da cuenta que en la epistemología de la economía hay ciertas preguntas latentes, tales como: ¿cuál de los métodos otorga mejores explicaciones sobre cómo en realidad suceden las cosas?, ¿cuáles son las limitaciones de cada método? y ¿por qué debería preferirse uno por sobre el otro? En este trabajo se pretende aclarar dichas limitaciones y dar indicios de una solución a estas preguntas, una que permita obtener beneficios de ambos métodos comprendiendo, al mismo tiempo, sus limitaciones epistémicas.

Respecto al esquema de trabajo: en la sección (2) se presentan los modelos teóricos, sus limitaciones y su forma de explicación; en la sección (3) se hace lo mismo, pero con los métodos empíricos; en la sección (4) se da indicios de una propuesta de amalgama que permitiría otorgar más confianza a las posibles explicaciones y, finalmente, en la sección (5) se cierra con las conclusiones.

## **2. El rol de los modelos en la ciencia económica**

### **2.1. Uso de modelos**

En el estudio de la economía como ciencia, es comprensible que el acceso epistémico a los fenómenos sea difícil. En estos pueden intervenir una gran cantidad de variables, como la cultura, las preferencias, las motivaciones, las creencias, entre varias otras. En virtud de la dificultad de comprender completamente cómo dichas variables interactúan entre ellas, todos estos elementos dan cuenta de la complejidad que poseen los fenómenos económicos.

Una técnica utilizada en las ciencias para estudiar fenómenos complejos es el uso de modelos. Estos contienen idealizaciones (agregando distorsiones o dejando solo las características más relevantes) que tienen como objetivo permitirnos el acceso a un fenómeno al que no podemos acceder a cabalidad, ya sea por la imposibilidad de manipulación, por limitaciones cognitivas o circunstanciales, como sería la carencia instrumental. Antes de adentrarnos al análisis de los modelos teóricos, debemos diferenciar que en economía la palabra modelo refiere a dos conceptos:

- Modelos teóricos o formales: que son relaciones idealizadas de variables que, de manera matemática, buscan explicar un fenómeno de estudio complejo (Potochnik, 2017).
- Modelos de datos: que son versiones corregidas, ajustadas, rectificadas y muchas veces idealizadas de los datos que obtenemos por la observación (Suppes, 1969).

Los modelos teóricos, al permitir el estudio de un fenómeno de interés de forma indirecta, se consideran modelos subrogados. El uso de modelos subrogados es una actividad que en sí misma podría

considerarse extraña. Intentar analizar un objeto de estudio sin acercarse directamente a él puede ser contraintuitivo. No obstante, el objetivo de los modelos es exactamente ese: lograr solucionar problemas del mundo real o de un sistema objetivo de forma indirecta, ya sea porque es más sencillo, porque es la única forma posible o por cualquier otra razón (Weisberg, 2012). Estos modelos serán cualquier construcción que no represente de manera totalmente exacta y completa el objeto de estudio (o una que no sabemos si lo representa con exactitud), puesto que lo que intentan es identificar las características del objeto que sean de mayor relevancia para la investigación. En otras palabras, contienen idealizaciones sobre el sistema objetivo.

Como los modelos matemáticos no son en realidad el fenómeno de estudio de la economía (como sí podrían serlo la deuda fiscal, los salarios o los ingresos de un hogar), es claro que el cambio en una variable económica no se encontrará exactamente en el mismo modelo. Weisberg (2012) plantea que un modelo, además de una estructura (como la matemática) y una descripción (como sus ecuaciones) necesitará un *construal*, que será el que generará la relación del modelo con el sistema objetivo. Para que dicho *construal* sea adecuado, será necesaria una asignación (i.e. la especificación del fenómeno que se desea estudiar y la coordinación de las partes con el fenómeno), un alcance (i.e. las partes del fenómeno que el modelo intenta representar) y criterios de fidelidad para que el modelo sea considerado una representación adecuada del sistema objetivo.

El modelo matemático, por tanto, es una estructura interpretada a través de la asignación, que potencialmente puede denotar partes de un sistema objetivo especificadas por un alcance y que es evaluado por el criterio de fidelidad del científico (o de quien analice el modelo). Los modelos tienen la ventaja de ser flexibles, ya que podemos cambiar sus variables a voluntad, y nos permiten obtener conclusiones por deducción. Sin embargo, para su aplicación a un sistema objetivo será necesario encontrar un *construal* adecuado, uno que permita saber si puede ser utilizado para un objeto de estudio.

Con esto volvemos al punto inicial, a saber, ¿cómo un modelo, que no es el fenómeno de estudio, puede explicar un fenómeno del sistema objetivo? Según Bokulich (2011), en la literatura habría tres respuestas que no serían totalmente satisfactorias:

1. Los modelos son explicativos si describen mecanismos. El todo es explicado en la operación e interacción de sus partes (Craver, 2006).

Pero, si este fuera el caso, el científico debería complejizar su modelo, acción que no es usual. Según Weisberg (2012), incluso de complejizarlo a la perfección dejaría de ser modelo ya que, por definición, este debe presentar idealizaciones para el estudio indirecto del sistema objetivo.

2. Los modelos son explicativos si contienen leyes causales. El *explanans* debe ser verdadero y, por consiguiente, las idealizaciones no deben formar parte de la explicación en sí misma (Elgin y Sober, 2002).

Sin embargo, las idealizaciones del *explanans* suelen ser falsas. Además, y si este fuera el caso, sería usual que los científicos intentaran demostrar por qué los supuestos no afectan el resultado. Esto último es algo que no suele suceder.

3. Los modelos son explicaciones hipotético-estructurales en que se postula una estructura subyacente del objeto. Son simplificados para facilitar el trabajo y luego se deberían complejizar (McMullin, 1978; 1985).

No obstante, en muchos casos *des-idealizar* ni siquiera es posible (Batterman, 2005). La presunción del uso del modelo es que no es posible explorar el sistema objetivo directamente, por consiguiente, no se podría saber a ciencia cierta qué parte del modelo está idealizada (o cómo está idealizada) ya que implicaría conocer totalmente el sistema objetivo.

Bokulich (2003) plantea una cuarta respuesta: los modelos serían estructuras de dependencia contrafactual. La explicación está permitida a través de la posibilidad de intervenir un modelo, deducir el efecto de esa intervención y también a partir de que estos permitan limitar el tipo de objetos, propiedades, estados y comportamientos que son admitidos en el marco de la teoría del modelo. En la explicación, el *explanandum* muestra un patrón de dependencia con los elementos del modelo. Por tanto, los modelos podrán generar explicaciones al permitir contestar preguntas sobre cómo sucederían las cosas si estas fueran diferentes (i.e. *what-if questions*). El modelo, al ser flexible, nos permitirá jugar con él y cumplirá el objetivo de contestar una gran variedad de preguntas (Doganova, 2015).

Son las mismas idealizaciones las que enmarcan las respuestas de los modelos a solo *what-if questions*. Se utilizan idealizaciones para abarcar los fenómenos que interesan al economista dado que estos poseen causalidad compleja (i.e. son fenómenos en los que intervienen múltiples variables) y, por ende, no seríamos capaces de abarcarlos completamente. Las idealizaciones permiten representar los fenómenos complejos, pero como si estos fueran diferentes a como en realidad son (i.e. *what-if*).

De este modo, el uso de modelos no nos permitiría obtener verdades. Su uso no generaría explicaciones, sino que otro tipo de conocimiento que podría ser llamado *entendimiento* (Potochnik, 2017). El entendimiento sería un estado epistémico del investigador sobre si sus instrumentos (e.g. un modelo) se ajustan u otorgan conocimiento sobre un fenómeno de interés. Estos no pueden ser tomados como hechos, ya que estas idealizaciones no se encuentran en el sistema objetivo (o no es posible saber si se encuentran, ya que saberlo implicaría conocer totalmente el sistema objetivo). Las idealizaciones jugarán el rol de entregarnos comprensión, pero solo en forma de entendimiento sobre los fenómenos complejos que interesan al científico.

Es importante aclarar que, aunque podría existir total arbitrariedad en el instrumento que genere confianza sobre un fenómeno, en la práctica los científicos sí prefieren unos modelos sobre otros. Por ejemplo, prefieren los modelos matemáticos por sobre los de la revelación o la astrología (Wimsatt, 1987). Esto podría indicar que los primeros son más exitosos para representar o explicar el fenómeno y que, por consiguiente, existiría un proceso de justificación.

## 2.2. Uso de modelos en economía: The Explanation Paradox

En economía los modelos han sido regularmente criticados. Posiblemente, el proceso más sistemático de recolección de estas críticas es el que realiza Reiss (2012). En este se expone la Paradoja de la explicación [*Explanation Paradox*]. Según Reiss, los economistas suelen defender el valor explicativo de

los modelos, a pesar de que pareciera cumplirse la siguiente paradoja con respecto a los enunciados que hacen los economistas sobre los modelos:

1. Los modelos en economía son altamente idealizados, no representan la realidad.
2. Nuestras mejores teorías de la explicación requieren representación veraz.
3. A pesar de esto, los modelos parecieran explicar los fenómenos (Verreault-Julien, 2019).

Claramente los tres enunciados no pueden ser verdaderos, razón por la cual nos encontramos frente a una paradoja. Teniendo esto en consideración, e intentando responder a la pregunta ¿cómo sería posible solucionarla?, se pueden aventurar tres respuestas.

Una primera respuesta podría ser que los modelos no representen fehacientemente y, aun así, logren capturar componentes reales del objeto de estudio, pudiendo representar correctamente si no existieran interferencias no consideradas (Cartwright, 1989; Mäki, 1992; 2009). Sin embargo, los modelos no solo asumen que el sistema objetivo no tiene accidentes (como una esfera perfectamente lisa), sino que también asumen que tienen una forma específica, sin poder saber qué conjunto de supuestos permite el resultado.

Por otro lado, una segunda respuesta a la pregunta podría ser que las explicaciones no requieran veracidad. Diferentes autores han planteado debilitar este requerimiento (van Frassen, 1980; Kitcher, 1981), pero estos no han sido tan influyentes como la explicación causal (Reutlinger, 2017; Verreault-Julien, 2019). Los modelos podrían ser “mundos creíbles” (Sugden, 2009), que se asimilan al mundo real y que deben unirse a una teoría tanto para responder preguntas del tipo “¿por qué  $p$  en vez de  $q$ ?” como para generar una explicación (Hindriks, 2008). No obstante, para que este fuera el caso los economistas deberían asumir que los modelos creíbles son explicativos (i.e. condición descriptiva) y que tienen buenas razones para mantener la condición descriptiva (i.e. condición prescriptiva). Esta última condición simplemente no se cumple.

Una tercera forma de solucionar la paradoja es que los modelos en realidad no tengan como función explicar. Hausman y Simon (1992) proponen que los modelos sirven solo como exploración conceptual, definiendo predicados. Solo las hipótesis del tipo “El sistema objetivo  $O$  es como el modelo  $M$ ” son las que dicen algo acerca del mundo. Alexandrova junto con Northcott (Alexandrova, 2008; Alexandrova y Northcott, 2009) proponen que los modelos solo cumplen un rol heurístico, haciendo formulaciones abiertas sobre el mundo (i.e. *open formulae*) que, posteriormente, deberían ser evaluadas empíricamente. Los modelos solo realizarían afirmaciones modales, planteando hipótesis posibles (Grüne-Yanoff, 2009). Aprenderíamos de los modelos al exponer que existen otros mundos posibles en que ciertas creencias modales realizadas por los modelos no son verdaderas. Según Reiss, esta no sería una respuesta satisfactoria, ya que esto no responde a por qué los modelos son defendidos por los economistas como mecanismos explicativos.

Según Reiss, no sería posible solucionar la paradoja de la explicación por estas vías. No obstante, para solucionarla quizás requerimos de un concepto ya utilizado. Uno que ha sido reducido a la epistemología de la explicación (Hempel y Oppenheim, 1948): El *entendimiento*.

### 2.3. La solución a la paradoja de la explicación: El entendimiento

Se ha planteado previamente en la literatura que la explicación causal no es la única forma legítima de explicación (Reutlinger, 2017; Lange, 2016; Verreault-Julien, 2019). En secciones anteriores ya se expresó la visión de Potochnik sobre el entendimiento, pero este concepto usualmente se encuentra supeditado a la explicación causal (Trout, 2002; De Regt, 2004; De Regt y Dieks, 2005).

Si el rol de los modelos no es explicar (posición que se encuentra en la negación del tercer enunciado de la paradoja de la explicación): ¿qué rol jugaría el entendimiento? Según Verreault-Julien (2019), primero habría que diferenciar entre dos tipos de explicaciones. En primer lugar, las explicaciones de cómo en realidad suceden las cosas (i.e. *How Actually Explanations* o HAE en inglés) y las explicaciones de cómo es probable que sucedan las cosas (i.e. *How Possibly Explanations* o HPE en inglés) (Grüne-Yanoff, 2013). Las primeras requieren un *explanans* verdadero (o aproximadamente verdadero) para un *explanandum*, mientras que las segundas no requieren veracidad, sino que solo son explicaciones posibles que podrían ser reales. Según Verreault-Julien, las primeras serían las requeridas para la explicación causal, mientras que las segundas estarían presentes en el entendimiento. Según el autor, no es que los economistas comenten erradamente que los modelos son explicativos, sino más bien que utilizan el concepto de explicación tanto para la explicación de cómo en realidad ocurren las cosas como para la explicación posible.

¿Ocurren este tipo de explicaciones no causales a partir de los modelos? El problema de los puentes de Königsberg (Euler, 1741) es un ejemplo de explicación no causal (Pincock, 2007; Lange, 2013; Reutlinger, 2016; Verreault-Julien, 2019). Euler plantea una solución matemática a la pregunta sobre si es posible cruzar todos los puentes de Königsberg usando una sola ruta y sin pasar dos veces por el mismo puente. Entendiendo cada uno de los puentes como un nodo, él demuestra matemáticamente que ello sería imposible. Esta explicación no se relaciona con una causa, pero logra demostrar la imposibilidad de realizar dicha acción. Un segundo ejemplo sería el modelo de segregación de Schelling (2006), en el cual se propone que la segregación racial urbana podría ocurrir en una ciudad incluso si las personas no fueran racistas y solo tuvieran leves preferencias por similitud. Esto generó un contraejemplo a la creencia a la fecha, de que la segregación racial urbana solo podía ocurrir porque las personas eran racistas.

Estos ejemplos dan cuenta de la relevancia epistémica que pueden tener las explicaciones no causales, ya que parecieran dar información a través de la limitación de las propiedades y objetos que son considerados en el problema. Estas permitirían tener más información o comprensión relevante (aunque no causal), lo que ha generado que otros autores ajusten sus criterios de la explicación que podrían ser compatibles con explicaciones posibles (Woodward, 2003; Strevens, 2008).

Para aceptar la flexibilidad de las explicaciones posibles, es necesario flexibilizar la relación entre conocimiento y entendimiento. Verreault-Julien (2019)<sup>2</sup> conceptualiza como “Concepción del entendimiento en términos de conocimiento estrecho” [*The Narrow Knowledge account of Understanding*

---

<sup>2</sup> Los conceptos de N-KnUn y de B-KnUn, mencionados en este y los párrafos siguientes, son desarrollados en Verreault-Julien (2019). Especialmente en el capítulo 4 de la tesis del autor titulado: "Understanding does not depend on (causal) explanation".

o N-KnUn] a la idea de que para lograr el entendimiento de un fenómeno se requiere conocer sus causas y que el conocimiento se logra si se tienen explicaciones causales. En otras palabras, la idea de que el entendimiento está supeditado a la explicación causal. No obstante, ejemplos como los anteriores dan cuenta de explicaciones no causales que, aun así, tienen valor epistémico al entregar beneficios cognitivos (Lipton, 2009). Estas nos mantienen en un estado epistémico que parece ser más satisfactorio que simplemente no tener información. De acuerdo con Lipton, las explicaciones posibles serían las que juegan el rol de proveernos de entendimiento y que otorgan este beneficio epistémico sin requerir estar supeditadas a la explicación causal.

Si la definición estrecha del entendimiento en términos de conocimiento requiere de las HAE, pero estas no dan cuenta de otras formas de conocimiento (como las explicaciones posibles y el entendimiento), sería necesario liberar este criterio. Verrault-Julien (2019) pasa de la concepción del entendimiento en términos de conocimiento estrecho a una amplia [*The Broad Knowledge account of Understanding* o B-KnUn], en la que no sería necesaria la confirmación de los elementos del *explanans* o el *explanandum*, sino solo que estos sean posibles según la interpretación modal relevante o los objetivos epistémicos.

El conocimiento causal no genera el entendimiento, sino que este se podría conseguir con el conocimiento de posibilidades de causas para un fenómeno. El entendimiento cumpliría una función epistémica propia, sin requerir conocimiento de causas. Los modelos matemáticos plantean respuestas posibles a fenómenos, al responder preguntas sobre cómo serían las cosas si fueran diferentes a través de la intervención del modelo o demarcando los objetos y propiedades a los que refiere. De este modo, el modelo permite obtener respuestas sobre cómo es posible que ocurran las cosas en el sistema objetivo. Las explicaciones no causales podrían jugar diferentes roles como, por ejemplo, expandir nuestro menú de posibles explicaciones (Ylikoski y Aydinonat, 2014), generar inferencias acerca de un fenómeno (Kuorikoski y Ylikoski, 2015) o contradecir imposibilidades que la gente o los científicos mantienen (Grüne-Yanoff, 2009).

Por último, cabe preguntarse cuál sería la diferencia entre una HAE y una HPE en términos formales. Debemos identificar entonces dos condiciones: en primer lugar, las condiciones internas, que están relacionadas con la estructura o forma de la explicación; en segundo lugar, las condiciones externas, que se relacionan con la correspondencia de la explicación con el mundo. Si existe una diferencia entre HAE y HPE, entonces esta debe encontrarse en alguna de estas dos condiciones. Aunque existen diversas posturas (e.g. Dray, 1968; Hempel, 1970), Verreault-Julien expone que existen tanto diferencias en las condiciones internas como en las externas. En el caso de las internas, pareciera haber algo de consenso en que una HAE no tiene la misma estructura que una HPE. Dicho de manera simple, si podemos estructurar una HAE como (“p porque q”), entonces, la diferencia pareciera encontrarse en que las HPE presentan un operador modal de tal forma que puedan escribirse como  $\diamond$  (“p porque q”).

En términos de las condiciones externas, la discusión mantiene más detalles y, aunque no existe consenso sobre el nivel de restricción que deben tener las HPE, Hempel (1970) ya revela la importancia que tiene la evidencia en que una HPE sea una HAE. Por ejemplo, y si se quisiera ser poco restrictivo, una HPE podría ser “Llueve porque el cielo está triste”. Esto, según Hempel, sería una HPE válida a la espera de que existan pruebas de que el cielo está triste y que sea una HAE. Por otro lado, podemos tener



mayores restricciones para las HPE, esperando que estas no puedan ser cualquier enunciado válido, sino que tengan alguna clase de sustento o evidencia que las justifique. De este modo, podríamos categorizar entre mejores y peores HPE. En otras palabras, entre aquellas que se encuentren más o aquellas que se encuentren menos justificadas.

Un modelo permitiría obtener deducciones en su propio sistema (HAEs), con idealizaciones y restricciones, pero el sistema del modelo no es el sistema objetivo del economista (recordemos que son modelos subrogados). Si este es el caso, ¿cómo se puede traspasar el conocimiento del modelo al sistema objetivo? Dado que no es posible saber si el sistema del modelo corresponde al sistema objetivo (dadas sus idealizaciones), entonces las HAEs del modelo, serán solo HPEs del sistema objetivo. El modelo teórico pasa de ser deductivo nomológico en el sistema del modelo a un modelo inductivo estadístico en el sistema objetivo, ya que las conclusiones ya no representan el sistema objetivo con necesidad, sino que solo con posibilidad. No tenemos certeza de que dichas ecuaciones capturen los procesos del mundo real sin mayor justificación.

Aunque no esté claro cuáles son las condiciones externas relevantes para caracterizar la estructura de una HPE, existe algo cierto: una HPE no sería relevante como explicación si esta contradijera totalmente lo que sabemos acerca del fenómeno de estudio. Dado que las HPE no explican con necesidad, sino que solo con probabilidad, es necesaria una justificación coherente que permita creer que dicha HPE tiene un alto valor explicativo. El modelo de segregación racial no podría haber servido como explicación si no hubiera existido ya un cuestionamiento a la suposición de que todos tienen preferencias racistas. Expuesto de forma absurda, enunciar que un fenómeno ocurre “por acción de un hechicero” probablemente no sería validado como una explicación, si es que este enunciado no tiene relación con el conocimiento previo que se tiene de dicho fenómeno<sup>3</sup>. Si la interpretación del modelo nos entrega una HPE y con ello entendimiento, este, al ser un estado epistémico del agente epistémico, debe tener cierta coherencia con el conocimiento previo que tiene dicho agente. En este sentido, podrían ampliarse las funciones de una HPE no solo a la búsqueda de causas para un efecto conocido, sino que también a la búsqueda de mecanismos de correlaciones que observamos.

Lo hasta aquí expuesto nos deja ver que los modelos plantearían explicaciones de cómo es posible que ocurran las cosas y deben ser contrastados con otras fuentes de evidencia (e.g. otros modelos o evidencia empírica). El valor de los modelos estaría en plantear respuestas a cómo es posible que ocurran los fenómenos y ser contrastados con el sistema objetivo que pretenden explicar. El uso de los modelos pretende llevar la deducción matemática que ocurre en el sistema del modelo al sistema objetivo, pero no es posible realizar esto de manera directa, convirtiendo las HAE del sistema del modelo en HPE para el sistema objetivo. El modelo tiene como beneficio que es menos complejo y, en este sentido, su poder de explicación es potencialmente aplicable a situaciones relativamente similares en que algunas de las condiciones del modelo parecieran también existir en el sistema objetivo (e.g. el modelo de Hotelling aplicado a elecciones).

<sup>3</sup> Lo que no quiere decir que no pueda existir un movimiento que decida investigar las decisiones de dicho hechicero y, quizás, llegar a conclusiones inesperadas

Los modelos tienen beneficios al ser flexibles y tener un dominio de aplicación amplio. Permiten analizar intervenciones posibles en sí mismos, a través de la modificación de sus variables. En este sentido, el modelo describe mecanismos de acción de fenómenos dentro del sistema del modelo, lo que le otorga un valor epistémico. A pesar de esto, presentan limitaciones: al no cumplir con las condiciones externas, no es posible saber si aquello que representa el modelo es efectivamente su sistema objetivo. El modelo requiere concretarse con conocimiento empírico que permita hacer un enlace entre el sistema del modelo y el sistema objetivo.

### 3. El rol de los (cuasi-)experimentos en la ciencia económica

El uso de experimentos y cuasi-experimentos en economía es parte de una tendencia en el estudio de los fenómenos económicos. Estos pueden dejar de lado los modelos e idealizaciones y enfocarse en los sucesos empíricos de primera mano. El economista puede estar interesado en responder preguntas del tipo: ¿cuál será el efecto en los salarios de implementar una política? o ¿cuál será el efecto en el empleo de otorgar capacitaciones a personas desempleadas? Preguntas que, sin duda, tienen como trasfondo la causalidad.

Para responder estas preguntas, los economistas requieren estimar estos efectos, generando grupos de control lo más similares posibles a una situación contrafactual que permita realizar estimaciones verdaderas del efecto de  $X$  sobre  $Y$ . Teóricamente, al economista le gustaría observar a una persona que recibe una capacitación y el valor de la variable de resultado de interés (e.g. si está empleado o no) posterior a recibir la capacitación. Al mismo tiempo, le interesaría observar la situación contrafactual de dicha persona (i.e. si no hubiera recibido la capacitación) y el valor de su variable de resultado en el mismo plazo de tiempo. La diferencia entre ambos escenarios permitiría calcular el efecto de dicha capacitación para esa persona. Lamentablemente, observar una situación contrafactual para una misma persona no es posible. No podemos observar a la misma persona, en el mismo tiempo, recibiendo y no recibiendo la capacitación. Por consiguiente, se requieren técnicas para estimar dicho contrafactual. Estos métodos se dividen en dos grupos.

1. Intervenciones controladas aleatorias (RCTs en inglés): también llamadas *Metodología Experimental*, plantean la posibilidad de estimar el efecto de una política al generar tanto un grupo tratado como un grupo control que son seleccionados de forma aleatoria, donde el grupo control actuaría como el contrafactual del grupo tratado. A través de la aleatorización y la ley de los grandes números se puede asegurar que ambos grupos, en promedio, son similares tanto en sus características observables como no observables. Esto permitiría calcular el cambio en la variable de interés posterior a la intervención, pudiendo adjudicar causalmente ese cambio a la intervención misma<sup>4</sup>.

<sup>4</sup> En términos sencillos esta estimación se realiza, primero, aleatorizando a los individuos en un grupo tratado y control, que por la ley de los grandes números tendrán igual (o similar) valor promedio en la variable de interés. Posteriormente, se ejecuta una intervención para luego volver a observar el valor promedio de la variable de interés para cada grupo. Dado que la probabilidad de ser parte del grupo tratamiento o control no está relacionada con características de los individuos, ya que el

2. **Métodos de estimación cuasi-experimental:** estos métodos construyen un contrafactual en situaciones en que no es posible aleatorizar. Existen diversos métodos, pero, en breve, la construcción de dicho contrafactual requiere de supuestos que, de cumplirse, validan que el grupo control se asemeje al contrafactual del grupo de tratamiento. Por ejemplo, podemos generar un grupo de control para evaluar el efecto de asistir a un jardín infantil si obtenemos a otro grupo de niños que no asistieron y que tengan características observables similares, tales como su edad, ingresos de la familia, educación de los padres u otros. Es directamente en los supuestos de la construcción del grupo contrafactual donde se diferencian estos métodos y donde se hacen más o menos creíbles.

En lo que sigue nos enfocaremos en los primeros, y se expondrá en qué consisten sus beneficios y limitaciones. Esto toma relevancia dado lo extendida que ha sido esta metodología desde la década de los ochenta, especialmente para realizar experimentos de laboratorio o experimentos en terreno. No nos enfocaremos en los métodos cuasi-experimentales debido a que las críticas que se pueden realizar a estos son similares a los RCTs y suman otras, dados los supuestos necesarios para construir el grupo de control<sup>5</sup>. Una consideración relevante es que el uso de RCTs, aunque amplio en economía, es usualmente aplicado en el área de microeconomía (en economía del desarrollo, economía experimental, economía del comportamiento, economía de la educación, entre otras), mientras que su uso en macroeconomía está usualmente limitado por cuestiones metodológicas (los elementos o eventos macroeconómicos no son usualmente aleatorizables o son endógenos a los países).

### **3.1. Experimentos: Intervenciones Controladas Aleatorias (RCTs)**

Los RCTs han sido fomentados por organismos internacionales para la estimación de la efectividad de políticas públicas. Esto se debe a que, si estos son perfectamente implementados (i.e. cumplen las cuatro condiciones explicitadas más adelante), permitirían realizar estimaciones causales sin otros supuestos adicionales<sup>6</sup> y a partir de la ejecución de intervenciones aleatorias a grupos comparables. Los RCTs permitirían saber el efecto de dicha intervención en la forma de correlaciones estadísticas a partir de datos. Esta tendencia se origina en el ámbito de la medicina, con el movimiento de “Medicina basada en evidencia”, y, posteriormente, su símil la “Política basada en evidencia” comienza a extenderse en ciencias sociales como la economía (Deaton y Cartwright, 2018).

Teóricamente, una Intervención Controlada Aleatoria, una que cumpla sus condiciones adicionales, cumpliría la caracterización de Woodward (2000) sobre la intervención y la explicación para el promedio de los participantes en ella. Esta propone a las intervenciones como idealizaciones de la manipulación experimental sobre una variable  $X$  generando cambios en una variable  $Y$  de interés, que permitan extraer

grupo está aleatorizado, entonces, cualquier diferencia entre los promedios del grupo tratamiento y grupo control puede ser adjudicada a la intervención. En el caso de los métodos cuasi-experimentales, no es posible asegurar que la participación en la intervención no esté relacionada con las características del individuo.

<sup>5</sup> La tesis original de la que proviene este documento incluye un anexo en que se especifican las limitaciones para los métodos más usados.

<sup>6</sup> Supuestos que son requeridos por los métodos cuasiexperimentales

alguna clase de proceso causal. Para esto, dicha intervención debe cumplir con algunas características que listaremos en lo que sigue.

Supongamos que  $I$  es una intervención sobre una variable  $X$  (que posee la unidad o el individuo  $i$ , a quien se le realizará la intervención  $I$ ), de la que se intenta obtener alguna relación  $G$ , de tal forma que un cambio en  $X$  causa o explica un cambio en una variable  $Y$ , que es aquello que se intenta observar a través de la relación  $G$ . Podemos llamar al valor de  $x$  antes de la intervención  $x_0$  y al posterior a la intervención  $x_1$ . Entonces, para que dicha intervención permita obtener conclusiones confiables, debe cumplirse que:

1.  $I$  debe cambiar el valor de  $X$  del individuo  $i$  en comparación a lo que hubiera sido en ausencia de la intervención ( $x_1 \neq x_0$ ) y este cambio debe ser completamente producido por  $I$ .
2. El cambio en  $X$  producido por  $I$  debe, a través de la relación  $G$ , cambiar el valor de  $Y$ . Esto es que, de acuerdo con  $G$ , el valor de  $y_0$  que toma  $Y$  cuando  $X = 0$  es diferente del valor  $y_1$ , que toma  $Y$  cuando  $X = x_1$ .
3.  $I$  cambia  $Y$  solo a través de  $X$  y no a través de otra ruta. Esto quiere decir que  $I$  causa el cambio en  $Y$ , ya sea directamente o a través de la modificación de otra variable diferente a  $X$  conectada causalmente con  $Y$ . Vale decir,  $I$  solo modifica  $Y$  a través de la relación  $I - X - Y$ .
4.  $I$  no está correlacionada con otras causas de  $Y$  además de  $X$ , excepto por las mencionadas en el punto anterior.

En resumen, imaginemos que nos gustaría saber si un tratamiento  $T$ , que recibe un individuo  $i$ , tiene un efecto en la recuperación de una enfermedad  $R$ . Entonces,  $T$  puede tomar dos valores, 1 si el individuo  $i$  recibe el tratamiento y 0 si no lo recibe. De la misma forma,  $R$  puede tomar el valor 1 si el individuo  $i$  se recupera de la enfermedad y 0 si no se recupera. Es obvio que nos gustaría saber para un individuo enfermo  $i$ , que no recibe tratamiento y que no se recuperará (es decir  $T_i = 0$  y  $R_i = 0$ ), si es que se le diera el tratamiento (tal que hubiera sido  $T_i = 1$ ), si se recuperaría o si sería más probable su recuperación (de modo que cambie a  $R_i = 1$ ). No es posible responder esta pregunta, ya que no es posible entregar el tratamiento y al mismo tiempo no entregárselo a un mismo paciente. No obstante, lo que sí es posible es realizar un paso indirecto, dividiendo un grupo de pacientes en dos: uno tratamiento y otro control, de modo que los primeros reciben el tratamiento y los segundos no.

Solo dividir en grupos control y tratamiento no permite obtener información sobre la eficacia del tratamiento. El objetivo de dividir aleatoriamente es acercarse lo más posible al resto de las condiciones de Woodward. Por ejemplo, si en vez de aleatorizar se decidiera que solo pacientes más saludables reciban el tratamiento (quizá porque se cree que hay algún riesgo en el tratamiento), entonces esto agregaría un sesgo, ya que es posible que aquellos saludables tengan condiciones previas que permita una mayor recuperación. Dicho de otra manera, podría ser que la intervención esté correlacionada con alguna otra causa de recuperación diferente al tratamiento  $T$ .

El aleatorizar permite, para el conjunto de individuos que podrían participar de la intervención  $I$ , dividirlos en un grupo tratado y control. Si el grupo es suficientemente grande, las características de dichos grupos serán iguales en promedio dada la Ley de los Grandes Números. Esto permite que el grupo

control sea, estadísticamente, un grupo contrafactual del grupo tratamiento. Lo anterior no solo porque es posible asegurar que existe un balance no solo en variables observables, sino que también en aquellas no observadas e incluso en aquellas inobservables que no se sospecha que tengan relevancia en el efecto. En otras palabras, ambos grupos tendrán en promedio el mismo nivel de salud previo (donde cada grupo tendrá una proporción similar de individuos más sanos y menos sanos), lo que permite hacer una comparación limpia entre grupos. Dado que cada individuo tiene igual probabilidad de pertenecer a cualquiera de los dos grupos, entonces  $I$  no estará correlacionado con ninguna otra causa de  $Y$  más que  $X$ . Este enfoque permite solucionar, para los promedios, la imposibilidad de entregar un tratamiento y no entregárselo a un mismo individuo.

En términos estadísticos, este mismo ejercicio puede representarse a partir del siguiente modelo de datos lineal típicamente usado en ciencias sociales. Primero lo presentaremos para cada individuo y, más adelante, para el caso de los promedios:

$$Y_i = \beta_i T_i + \sum_{j=1}^J \gamma_j x_{ij}$$

En la ecuación anterior,  $Y_i$  corresponde a la variable de resultado o la variable de interés para nuestra unidad de análisis. Hablamos, por ejemplo, del nivel educacional, los ingresos u otro para una persona, familia, barrio o similar.  $T_i$  corresponde a una variable dicotómica, que puede tomar valor 1 o 0, que representa el ser asignado al grupo de tratamiento de la intervención. Por ejemplo, recibir un medicamento (donde  $T_i$  toma el valor 1 si es asignado al tratamiento y 0 en caso contrario) para cada unidad de análisis  $i$ .  $\beta_i$  es el efecto individual del tratamiento en  $i$  (representa qué tanto contribuye el valor de  $T$  al resultado  $Y$  para la unidad  $i$ ). Por último, las variables  $x$  representan características observables o no observables de  $i$ , que serían otras causas lineales del resultado. Existirían un total de  $J$  variables  $x$ , con su correspondiente parámetro  $\gamma$  (que refleja la importancia de la variable  $x$  en  $Y$ ).

Podemos analizar la ecuación anterior a partir de un enfoque contrafactual, usualmente llamado el Modelo Causal de Rubin (Rubin, 2005). En este caso,  $T$  sería una variable dicotómica que toma valor 1 o 0 dependiendo de si fue asignado al tratamiento o no. Podemos, por tanto, identificar dos resultados para un mismo individuo:  $Y_{i1}$  e  $Y_{i0}$ , el primero si fue asignado al tratamiento y el segundo si no fue asignado al tratamiento. Es claro que la diferencia entre ambas variables de resultados será solo  $\beta_i$ , que sería el efecto del tratamiento para la persona  $i$ . Esto dado que  $T_i$  toma el valor 0 en el caso de la unidad no tratada y porque, al ser el mismo individuo  $i$ , sus variables  $x$  son iguales, por lo que la resta sería 0. Como fue mencionado previamente, para un mismo  $i$  no podemos tratarlo y no tratarlo al mismo tiempo. No obstante, para un grupo sí podemos calcular la diferencia de los promedios de la variable de resultado, lo que se denomina el Efecto Promedio del Tratamiento [*Average Treatment Effect* o ATE].

La estimación del ATE es bastante relevante y simple de calcular. El estimador del ATE será la diferencia entre el resultado promedio del grupo tratado ( $\bar{Y}_1$ ) menos el promedio del resultado del grupo control ( $\bar{Y}_0$ ). Para un individuo en específico no podríamos observar su resultado siendo tratado y no tratado, pero sí podemos observarla para dos grupos diferentes. Lo anterior queda representado en la

siguiente ecuación, donde identificamos los valores promedio de las variables con una barra sobre cada una de ellas:

$$\bar{Y}_1 - \bar{Y}_0 = \bar{\beta}_1 + \sum_{j=1}^J \gamma_j \left( (\bar{x}_{1ij} - \bar{x}_{0ij}) \right) = \bar{\beta}_1 + ((\bar{S}_1 - \bar{S}_0))$$

Como hemos mencionado antes,  $\beta_i$  sería el efecto de pertenecer al grupo tratamiento o al grupo control para el individuo  $i$ . Es posible obtener el efecto promedio del tratamiento (i.e. ATE) considerando el total de personas en nuestra muestra, que en la ecuación anterior es representado por  $\bar{\beta}_1$ , y el interés del economista estaría en estimarlo utilizando alguna técnica, como podría ser un RCT. En el extremo derecho de la ecuación podemos ver que a  $\bar{\beta}_1$  se le suma una diferencia, esta representa el balance promedio neto de otras causas que podrían afectar la variable de resultado, entre el grupo tratamiento y el grupo control. Generalmente este valor no será cero, por lo que, en tal caso, nuestra estimación tendría un sesgo, pudiendo sobrestimar o subestimar el ATE. Es necesario, por tanto, buscar una forma de lidiar con este problema para obtener un balance perfecto entre ambos grupos. Por ejemplo, si el tratamiento se entrega a personas más saludables y se espera su recuperación, entonces, al no haber balance en el nivel de salud entre el grupo control y el tratamiento, esta diferencia no sería 0, por lo que el valor estimado sería  $\bar{\beta}_1$  más el sesgo generado por el desbalance.

Los métodos econométricos cuasi-experimentales y experimentales plantean diferentes formas de lidiar con este elemento para que sea lo menor posible, con tal de minimizar el sesgo de la estimación del efecto de la intervención. En el caso de las Intervenciones Controladas Aleatorias, este elemento se vuelve cero (si el RCT ha sido realizado de la manera correcta, cumpliendo sus condiciones) a través de la aleatorización, lo que permite que no haya correlación entre la selección a la intervención y las características de los individuos (hay ortogonalidad entre las variables  $X$  y la selección a la intervención). Dado que el grupo tratamiento y control provienen de la misma distribución, la aleatorización garantiza, por construcción, que el valor del último término a la derecha de la ecuación sea cero en valor esperado, siendo por tanto el estimador obtenido de  $\bar{\beta}_1$  un estimador insesgado del efecto promedio del tratamiento (ATE) en la muestra en que hemos realizado el RCT. En otras palabras, que el valor esperado del estimador del parámetro es igual al valor real del parámetro. Con pocos supuestos es posible, de manera deductiva, obtener un estimador del efecto de un tratamiento sin requerir un modelo previo o supuestos de las covariables o variables de confusión, solo siendo necesarios los valores de la variable de resultado. En el caso de los métodos cuasi-experimentales, como se mencionó previamente, estos utilizan algún supuesto que en caso de ser cierto permitiría que la diferencia de  $(\bar{S}_1 - \bar{S}_0)$  sea 0. En tal caso, el estimador del ATE también será insesgado y obtenido por deducción, pero la interpretación del resultado dependerá de la credibilidad de los supuestos utilizados. Dado que un RCT no depende de la credibilidad de sus supuestos, sino que solo de su correcta implementación y cumplimiento de sus condiciones, estos están en una posición de credibilidad mayor a otros métodos de estimación.

### 3.2. Objetivos y beneficios de los RCTs

Tal como se expuso previamente, el estudio de los fenómenos económicos puede ser complejo y sería imposible controlar todas las variables para realizar un experimento controlado (Urbach, 1985). Pero no solo es difícil identificar dichas variables, otro reto incluye el cuantificarlas (Reiss, 2006). La aleatorización permite solucionar este problema ya que, si los cofactores se mantienen balanceados entre el grupo tratamiento y control, entonces, identificar los cofactores no es relevante para la estimación, pudiendo así saber si es que cierto tratamiento ha generado o no un efecto en la variable de resultado de interés. Tomemos de ejemplo el responder una pregunta de política pública, como podría ser ¿qué tendría más efecto en aumentar la asistencia de niños a la escuela: transferencias condicionadas a familias, otorgar becas, uniformes escolares gratuitos, información a los padres sobre retornos a la educación o dar medicamentos antiparasitarios? (J-PAL, 2012). Este tipo de preguntas sería difícil de responder con un modelo matemático, incluso es posible que desconozcamos totalmente los mecanismos subyacentes que explicarían por qué entregar medicamentos antiparasitarios en la escuela puede generar una mayor asistencia escolar. No obstante, los experimentos permitirían responder esta clase de preguntas sin tener conocimiento de todos los procesos detrás de un efecto.

Los RCTs nos permitirían evadir la necesidad de describir por completo un problema, ya que es posible obtener de manera deductiva una estimación de cuánto un aporta tratamiento a una variable de resultado de manera creíble. Esto último puesto que no son necesarios supuestos adicionales para establecer al grupo que es designado aleatoriamente como control como un contrafactual promedio del grupo tratamiento. En conjunto a lo anterior, los métodos experimentales permiten realizar pruebas de teorías establecidas. Esto permite que formen un puente entre la teoría económica, representada a través de los modelos matemáticos, y la evidencia empírica (List, 2007).

Sin embargo, todos los beneficios de los RCTs mencionados con anterioridad solo podrán deducirse si el método cumple con cuatro condiciones importantes (Deaton y Cartwright, 2018; Fevereau, 2016):

1. Nula atrición: es decir, que sea posible medir posterior a la evaluación a todas las unidades participantes.
2. Cumplimiento total: es decir, que todos los asignados al tratamiento o al control efectivamente participen de su grupo asignado.
3. Muestras grandes: es decir, que la muestra tenga un tamaño suficiente que permita el balance de las características tanto observables como no observables y el cumplimiento de la ley de los grandes números.
4. Además, se debe considerar la necesidad de realizar placebos y que la evaluación sea ciega (elementos no extendidos en la disciplina actualmente).

Las condiciones mencionadas tienen como objetivo que no existan desbalances de la muestra posterior a la aleatorización. En caso de cumplirse dichas condiciones, se podría establecer la causalidad del efecto promedio del tratamiento, a partir de la construcción misma del método. Estas condiciones entregan credibilidad a los RCTs y los posicionan como el *gold-standard* en métodos de evaluación de impacto,

ya que no sería necesario utilizar supuestos adicionales. El uso de este método fuera del laboratorio ha permitido comprender los fenómenos económicos en el mundo real (i.e. en un ambiente natural), en el que las personas participantes se ven enfrentadas a decisiones del día a día (Harrison y List, 2004). Esto ha permitido, a su vez, ir más allá de la teoría, de la intuición y del laboratorio.

En términos de Cartwright (2007), un RCT entra en la categoría de *Clincher*. En otras palabras, metodologías que son decisivas en sus conclusiones, pero que tienen ámbitos de aplicación estrechos. Estos se contraponen a otras metodologías llamadas *Voucher*, cuyos rangos de aplicación son más amplios, pero no son decisivas en sus conclusiones en tanto solo describen (e.g. los análisis cualitativos o descriptivos, entre otros). Considerando lo expuesto, un *Clincher* será todo aquel método que, si es correctamente aplicado, mostrará conclusiones verdaderas de forma deductiva.

Los RCTs pueden ser más confiables que otros métodos, pero esto solo mientras se cumplan las condiciones anteriormente señaladas. En caso contrario, el método no podría ser considerado un *Clincher*, sino un *Voucher*, puesto que necesitaríamos el supuesto adicional de que la estimación es tan buena como si se cumplieran las condiciones. Esto amerita que la política pública no pueda tomar un RCT como evidencia por el mero hecho de la aleatorización. Esta última es condición necesaria, pero no suficiente para su confiabilidad. La interpretación de sus resultados requiere más información que solo saber que la intervención fue aleatorizada, y es en la toma de decisiones donde estos factores entran en juego. Un investigador puede preferir como método un RCT, pero esto no quiere decir que un tomador de decisiones políticas deba tomar el mismo camino. Teniendo esto en consideración, se hace un más relevante explorar las críticas a este método.

### 3.3. Críticas a los RCTs

La estimación a través de Intervenciones Controladas Aleatorias tiene beneficios que otros métodos no tienen, a saber, que sus conclusiones se derivan de manera deductiva si es que estos son ejecutados correctamente. Además, están libres de supuestos adicionales, lo que los hace más creíbles. Estas características son deseables para la política basada en evidencia puesto que, si es posible saber qué cosa funciona para lograr un propósito determinado, entonces, estaremos en una mejor posición para aplicar políticas que cumplan con dichos propósitos. Sin embargo, los RCTs han quedado libres de críticas. En esta sección se explorarán las más importantes.

La primera de las críticas usuales es la diferencia entre *Eficacia* y *Efectividad*. Entenderemos estos conceptos de la siguiente manera (Cartwright, 2009):

1. Eficacia: aquello que se establece sobre las causas en un RCT. Dicho de otro modo, las causas que suceden en la muestra en la que se ha realizado el estudio, dentro del sistema del experimento. Entonces, si se ha realizado un RCT de la forma esperada, es posible decir que la intervención ha causado un efecto promedio en la muestra de estudio.
2. Efectividad: aquello que produce una causa en el sistema objetivo, fuera del sistema del experimento. En otras palabras, lo que la causa utilizada en el sistema del experimento produce



en el sistema objetivo. Por ejemplo, el efecto que produce un medicamento sobre la población general (o la población del sistema objetivo).

No es posible pasar de manera directa de una evaluación que demuestra eficacia a concluir efectividad respecto de la población objetivo, esto necesitaría una justificación adicional. Es necesario asegurar que el contexto en que se realizó el experimento tiene alguna similitud con el contexto de interés al que se desea generalizar dicho conocimiento, sea para aplicar una política pública u otro objetivo del economista. Esto se hace asegurando que los mecanismos detrás del efecto del experimento también se encuentran en el contexto de interés o que la muestra en la que se realizó el experimento es similar (o fue seleccionada sin sesgos) de la población del sistema objetivo<sup>7</sup>.

Usualmente se asume que una causa eficaz en el experimento también será eficaz fuera del experimento, a menos que ese efecto sea anulado por causas opuestas. Cartwright (2009, p.186-187) expone como ejemplo la reducción del tamaño de los cursos en escuelas. Esta reducción, evaluada utilizando un RCT, logró beneficios significativos en Tennessee, pero no logró ser efectiva en California<sup>8</sup> ¿Cuál fue el problema? La decisión de política no fue adecuada en California puesto que la implementación fue apresurada. La demanda por profesores y salas de clase aumentó de un año a otro sin que existiera la capacidad para sustentar esta decisión, y esto afectó principalmente a los estudiantes de menores ingresos que terminaron asistiendo a clases impartidas por profesores con menor capacitación. A pesar de que el primer RCT estimó una eficacia, la efectividad no estaba asegurada debido a las condiciones necesarias para implementar la política en el sistema objetivo.

Lo anterior pone de manifiesto la importancia de la validez externa o la capacidad de extrapolación de los RCTs del sistema del experimento al sistema objetivo. Este punto se puede dividir en dos apartados:

1. La validez externa del experimento en una muestra específica: es decir, si la eficacia que obtenemos de un RCT realizado en una muestra específica se replicará en la muestra en que se implementará la decisión de política. La posibilidad de traspasar los resultados de un RCT de una observación específica podría nunca estar garantizada (i.e. ¿qué justificaría la creencia de que la siguiente muestra tendrá la misma eficacia antes de que lo observemos?). No obstante, el problema se puede evitar si logramos caracterizar de tal forma a dicha creencia que haga su justificación posible. A final de cuentas, este problema es simplemente una extensión del problema de la inducción de Hume (Henderson, 2020), y algo con lo que tiene que vivir cualquier estudio empírico.
2. La validez externa del experimento en un contexto específico: aunque podría ser una extensión del primero, este segundo apartado refiere a que cierto RCT sea usado como evidencia para generar políticas en contextos disímiles en el que sucede el RCT. El problema es que es posible

<sup>7</sup> Si habláramos de vacunación, el efecto que tiene una vacuna en la muestra del experimento puede no ser igual al que tiene o tendrá en la población general. No obstante, podría ser igual si la selección de la muestra del estudio se realiza sin sesgos.

<sup>8</sup> Para los efectos positivos en Tennessee véase: Mosteller (1995). Por otro lado, para la poca efectividad en el caso de California véase: Graue, Hatch, Rao y Oen (2007).

que en estos contextos distintos aquellos elementos necesarios para la eficacia no estén presentes. Dicho de otro modo, si nuestro sistema objetivo es un contexto diferente de aquel en que se realiza el experimento, será necesaria más información para justificar que una eficacia del sistema del experimento será una efectividad en el sistema objetivo. Ya no solo entra en consideración la muestra, sino que también el contexto. Por ejemplo, es bastante claro que la política de entregar antiparasitarios en Chile tendrá efectos muy diferentes a los que tendría en Kenia.

Aunque esto podría echar por la borda a los RCTs, han existido evaluaciones de políticas que han generado efectos positivos en diversos contextos. Por ejemplo, las transferencias condicionadas a familias, con la condición de que sus hijos cumplan metas de asistencia a la escuela o controles de salud, han mostrado efectos positivos en diversos contextos (Gertler y Boyce, 2001). Según Deaton y Cartwright (2018), esto se debe a que las condiciones para su efectividad se encuentran en diversos contextos:

1. Los beneficiarios deben valorar positivamente el dinero. En caso contrario no hay incentivo a recibir la transferencia.
2. Los beneficiarios deben tener algún nivel de interés en que sus hijos se eduquen o estén sanos. En caso contrario, no fomentarían la asistencia a la escuela o a controles preventivos de salud.
3. Los beneficiarios deben tener disponibles escuelas o establecimientos de salud cercanos. En caso contrario, aunque quisieran asistir no podrían hacerlo.
4. El gobierno debe tener interés en el bienestar. En caso contrario, la política no prosperará.

Cartwright (2009), plantea que la dependencia en estos mecanismos hace que los RCTs no nos permitan conocer las causas de un efecto en un sistema objetivo, sino solo sus capacidades. Una causa nos diría que, si esta ocurre, entonces ocurrirá el efecto. La capacidad, en cambio, serían tendencias que podrían suceder o que podrían ser anuladas si en dicho contexto no están presentes las condiciones para generar un efecto (e.g. si los padres no ven valor en el dinero, entonces recibirlo no sería un incentivo para otra acción). Dicho de otro modo, un RCT podrá ser extrapolado solo si existen los mecanismos necesarios que traduzcan la capacidad a un efecto.

Una segunda crítica a los RCTs se relaciona con su supuesta independencia de la teoría y los supuestos, que los haría más creíbles. Esto, aunque cierto, solo permitiría analizar cada evento por sí mismo (i.e. el evento de cada intervención en un tiempo y espacio dado), pero no justificaría la extrapolación o la generalización de los resultados, que es lo que le interesaría al economista. El economista, en términos de Woodward (2000), estaría interesado en el espacio de invarianza de una temática, como la reducción de la pobreza, mejoras en educación o en salud. En este ámbito, el RCT estará supeditado a teorías previas para su construcción (e.g. ¿por qué otorgar la transferencia condicionada a mujeres en vez de hombres?), y también requerirá teoría para la interpretación de los datos y su extrapolación (e.g. ¿el aumento de la inversión de los padres en la salud de sus hijos responde a un aumento de la utilidad de los padres al considerar en su función de utilidad el beneficio de sus hijos o por un aumento de los salarios esperados de los hijos?). Por tanto, la pretensión de un RCT de ser un elemento de evidencia libre de la teoría o de

supuestos dependerá del nivel en el que hablamos. Si queremos hablar sobre la construcción de los estimadores, en la validez interna, efectivamente la aleatorización permite liberarse de supuestos usualmente criticables (o menos creíbles) a los que se enfrentan los métodos cuasi-experimentales. Si decidimos subir de nivel, en que deseamos aplicar los resultados de un RCT desde un contexto a uno diferente, entonces serán la teoría, los supuestos, la interpretación del modelo de datos del RCT y la identificación de los mecanismos los que permitirán realizar esa labor. Ninguna metodología de estimación podría realizar este ascenso sin una justificación externa al método mismo.

Por último, existen críticas que tienen que ver con la dificultad práctica de un RCT y no con su valor epistemológico. Estas se mencionan a continuación, pero con un fin meramente expositivo. A mi parecer, ellas no tienen relación con el valor epistemológico de los RCT, sino que con situaciones prácticas y contingentes<sup>9</sup>:

1. La factibilidad de aleatorizar: no todas las políticas son aleatorizables, por ejemplo, pareciera difícil aleatorizar la independencia del Banco Central. Esto, aunque cierto, es una crítica contingente y podría ser el caso que en un futuro algo similar sea posible de aleatorizar.
2. La dificultad de ejecutar un RCT: si un RCT debe cumplir las condiciones mencionadas previamente, puede ser difícil asegurar que estas se cumplan. Sin embargo, esta crítica también es contingente. Por ejemplo, un RCT dentro de una página web, como los realizados por Facebook o Amazon, puede ser muy fácil de implementar, mientras que uno que se realice en diversas regiones de un país evidentemente será más difícil. Esto, aunque válido, no es una crítica al método, sino que más bien son consideraciones acerca de la ejecución y extrapolación de sus resultados.
3. La ética de aleatorizar: en ocasiones se aboga que la aleatorización no sería ética porque deja a una parte sin obtener un beneficio (i.e. al grupo de control) y/o porque su ejecución es muy costosa. En cuanto al primer punto, actualmente existen técnicas para evitar este problema. Por ejemplo, y si un programa tiene capacidad para financiar a 1000 personas, en vez de aleatorizar 500 y 500 se buscan 2000 y se aleatorizan 1000 y 1000, manteniendo así la cantidad de beneficiarios (Galiani, Gertler, Undurraga, Cooper, Martínez y Ross, 2017). En cuanto a los costos, estos también serán contingentes a la evaluación misma y, gracias a la tecnología, cada vez se reducen más ante la capacidad de automatizar procesos.

<sup>9</sup> Estas críticas se utilizan dada la posición de credibilidad que tienen los RCTs por sobre los cuasi-experimentos. Organismos internacionales a veces prefieren financiar estudios experimentales por sobre cuasi-experimentales, aunque existan situaciones prácticas en que no sea posible aleatorizar. Esta decisión normativa no proviene del método mismo y de su epistemología, sino que, a mi parecer, de la falta de comprensión de que el RCT no es un fin en sí mismo, sino que un medio para obtener conocimiento tan válido como puede ser un método cuasi-experimental o un modelo. En términos sencillos, si es posible aleatorizar, sus conclusiones pueden ser más creíbles, pero no parece adecuado dejar de realizar investigaciones porque contingentemente no es posible aleatorizar, especialmente si hay otras formas que sí son viables para analizar dicha pregunta.

La mayor credibilidad de un RCT debe basarse en un análisis profundo sobre cómo generalizar sus resultados

Aunque gran parte de las críticas son válidas, estas tienen respuestas que plantean que un RCT puede ser un buen método para la estimación. En concreto, las críticas más importantes refieren al primer punto, sobre la validez externa de un RCT específico. Este problema será mayor en cuanto se desee utilizar la evidencia de un RCT desde un contexto a otro no relacionado al del experimento (e.g. de un país a otro). El RCT puede ser considerado un buen método de estimación, uno que nos permitiría tener evidencia causal. Sin embargo, su contexto de aplicación es limitado o puntual, solo aplicaría al contexto en que fue realizado (i.e. sistema experimental). En este caso, la causalidad esperada del RCT requiere una justificación mayor para ser traspasada desde el sistema del experimento al sistema objetivo. En este ámbito, el reconocimiento de los mecanismos y las capacidades estimadas del RCT serán relevantes para justificar la creencia de que la tendencia que podría generar puede replicarse en el sistema objetivo.

### 3.4. El sentido de la explicación de los RCTs

Entendiendo los beneficios y críticas que tienen los RCTs, y considerando especialmente que estos permiten obtener estimaciones causales que solo están justificadas para el propio contexto en que son aplicados y que además parecen entregar poca información sobre los factores que apoyan un resultado, entonces, se hace relevante enumerar en qué momentos está justificado el uso de un RCT. Deaton y Cartwright (2018) enuncian cuatro situaciones en que un RCT es suficiente por sí mismo para el cumplimiento de un objetivo específico:

- a. Un RCT es suficiente por sí mismo cuando es utilizado como contraejemplo de una proposición teórica general.
- b. Un RCT es suficiente por sí mismo cuando el parámetro de interés es el ATE para una población bien definida y de la cual se seleccionó una muestra de manera aleatoria simple. En este caso, será relevante considerar si hay o no externalidades producto de la intervención.
- c. Un RCT es suficiente por sí mismo cuando los resultados del RCT pueden ser usados a través del método hipotético deductivo para probar una teoría. Por ejemplo, Banerjee, Duflo, Goldberg, Karlan, Osei, Parienté, Shapiro, Thuysbaert y Udry (2015) realizaron RCTs en seis países diferentes para probar si una intervención que otorga activos productivos, entrenamiento y mentoría, puede sacar a las personas de la pobreza. Este estudio se relaciona con el concepto de trampas de pobreza, con el que diversos economistas han demostrado escepticismo respecto a su existencia, y entrega una justificación de la existencia de estas. Los RCTs, dada su validez interna y especialmente si son realizados en contextos heterogéneos, pueden complementar a las proposiciones teóricas. Esto en virtud de que entregan las condiciones externas que validan una teoría.
- d. Un RCT es suficiente por sí mismo para justificar a los donantes de un proyecto que su aporte ha logrado un efecto en la población en la que se ejecuta una intervención. En este caso, la población de interés es la misma en que se ha ejecutado el RCT.

Por consiguiente, y a pesar de sus críticas, existen situaciones en las que un RCT es suficiente por sí mismo. Sin embargo, en ninguna de estas situaciones está justificada la extrapolación de los resultados a

nuevos contextos. Entonces, cabe preguntarse cómo logra explicar un RCT y si sus explicaciones son causales o solo probables, como ya se ha dicho para los modelos.

Ya se ha mencionado que los RCTs tienen una fuerte validez interna, como también una fuerte validez externa para exactamente la muestra del experimento. No obstante, la extrapolación de los conocimientos obtenidos en un RCT a uno diferente no está asegurada. Esto implica que las explicaciones causales del RCT solo podrían aplicarse para el contexto mismo en que este fue realizado. Entonces: ¿un RCT genera *How Actually Explanations* (HAE) o *How Possibly Explanations*? La respuesta a esta pregunta estará dada por el contexto de aplicación. Si el contexto es igual en todos aquellos factores relevantes para la eficacia en el RCT (y el RCT ha sido ejecutado de forma ideal), entonces, de manera deductiva podremos estimar el ATE. Este ATE corresponde al sistema objetivo en el que deseamos utilizar la estimación (no solo para la muestra, sino que para las siguientes intervenciones realizadas en el mismo contexto), obteniendo una efectividad para el sistema objetivo. En tal caso, nuestro RCT cumple tanto con las condiciones internas como las condiciones externas de la explicación. Es importante tener en cuenta que este argumento requiere que se omita el problema de la validez externa para una muestra específica que, acorde a lo expuesto previamente, puede ser válido dependiendo de la pregunta de investigación específica.

En cambio, podemos enfrentarnos al caso de desear utilizar la estimación del RCT realizado en un contexto como evidencia para un contexto diferente (o que no podamos justificar que cumpla con la igualdad en todos los factores relevantes para el desarrollo de una eficacia). En tal caso, cumplirá con las condiciones internas, pero no podrá cumplir con las condiciones externas. Solo generaría *How Possibly Explanations*, es decir, en el nuevo contexto de aplicación nuestra evidencia solo genera entendimiento. En este sentido el RCT permitirá justificar la probabilidad de capacidades para el sistema objetivo, ya que, al no tener total conocimiento de los mecanismos subyacentes a la estimación realizada, no es posible asegurar que la eficacia estimada en el sistema del experimento sea efectividad en el sistema objetivo.

Ahondando un poco más en lo anterior, que un RCT genere explicaciones posibles se debe a que este permite obtener una deducción para las condiciones del contexto mismo del RCT. Esto hace que nuestro experimento tenga una aplicación más estrecha y puntual para un contexto específico (con condiciones específicas). Aunque ocurra esto, los RCTs presentan otros beneficios que los pueden ubicar como una buena opción de estimación, como, por ejemplo, su mayor credibilidad. La decisión de realizar o no un RCT debería ser analizada caso a caso, tomando en cuenta el objetivo de la investigación, la necesaria credibilidad y también los costos asociados.

Por tanto, y haciendo un paralelo entre ambos, si un modelo puede responder preguntas del tipo “¿qué pasaría si las cosas fueran diferentes?” (“*What-if-things-had-been-different*”), un experimento nos permite contestar preguntas del tipo “¿Qué pasaría si las cosas fueran como en el experimento?”. Si el sistema al que se quiere extrapolar un RCT tiene un contexto diferente al del sistema experimental, entonces, esta relación no sucede con necesidad, sino que con probabilidad. La evidencia del RCT justifica con necesidad para el contexto del RCT mismo. No obstante, para un sistema más amplio, la justificación será modal.

Lo anterior plantea una discusión interesante. Hasta el momento sabemos que un RCT es una buena técnica de estimación que permite inferir causalidad si la población objetivo es igual (en características) a la muestra utilizada. En cambio, si no se cumple dicha condición, no es posible justificar solo por el método que la eficacia del RCT se transforme en efectividad en el sistema objetivo. En este caso el RCT generará entendimiento, ya que responderá a preguntas sobre qué sucedería si el sistema objetivo fuese igual al sistema del experimento, entregando solo una explicación modal. Por otro lado, los RCTs poseen defectos en tanto solo justifican de manera deductiva para situaciones puntuales (i.e. exactamente para aquella en que se ha realizado la estimación) y el método por si solo omite información acerca de los mecanismos detrás de un efecto estimado.

Tomando en cuenta que tanto los modelos teóricos como los RCTs generan explicaciones posibles fuera de su sistema de estudio en el que son deductivos, es decir, al sacar el modelo del sistema del modelo y al RCT del sistema del experimento; entonces, es posible que ambos puedan ser complementarios. Tal como se abordó previamente, los modelos tienen el beneficio de que pueden generar explicaciones para situaciones que a veces son más amplias que el origen del modelo y, además, pueden establecer mecanismos para un efecto. Por otro lado, los RCTs pueden generar explicaciones causales en fenómenos puntuales (específicamente el de su misma aplicación). Pareciera que la falencia de un método sería la fortaleza del otro. Los modelos responden preguntas generales, son flexibles y otorgan mecanismos, pero la aplicación de sus resultados a fenómenos reales puede ser poco creíble. En cambio, las conclusiones de los RCTs son confiables para la muestra que utilizan, pero son poco flexibles en tanto aplican solo al sistema del experimento y no entregan mecanismos. Bajo esta premisa, a continuación se propone brevemente cómo ambos métodos podrían complementarse para generar una mayor comprensión del sistema objetivo.

#### **4. Amalgama de métodos de evidencia: Modelos y RCTs**

Hasta el momento se ha estudiado que tanto los modelos como los RCTs tienen limitaciones. Ninguno puede responder de forma cierta preguntas fuera de su sistema objetivo. Tanto los modelos como los RCTs tienen deficiencias, pero también poseen ventajas que pueden complementarse. Los modelos tienen como deficiencia que al ser altamente idealizados no representan un sistema objetivo o no podemos saber si lo representan, pero, debido a su generalidad, pueden ser usados en diferentes situaciones. En cambio, los RCTs tienen como deficiencia que su nivel de aplicación es sumamente puntual, solo en el contexto y muestra en que fue realizada la intervención, obteniendo conclusiones deductivas (si cumplen todas sus condiciones). Pero, y a diferencia de otros tipos de métodos que sí los requieren, no necesitan supuestos extras para ser creíbles. En resumen, no es posible saber si los modelos aplican al mundo real, pero son altamente generales. Los RCTs hablan del mundo real, pero en situaciones sumamente locales (o puntuales). Aquello que uno tiene como falencia el otro lo tiene como ventaja.

Esta sección pretende entregar brevemente indicios sobre cómo es posible utilizar ambos métodos para, al menos, aumentar la confianza en el conocimiento que ambos otorgan. Esta amalgama se basa en el principio de variedad de evidencia, o en que más evidencia confirma de manera más fuerte una hipótesis en contraste con menor variedad de evidencia. Este principio se hace relevante cuando el acceso a un

fenómeno de interés es incompleto, indirecto o utiliza supuestos y, al mismo tiempo, se deben tomar decisiones políticas de la forma más informada posible (Fletcher, Landes y Poellinger, 2019).

Los modelos teóricos son aplicables a diferentes situaciones (i.e. son generales), pero, al momento de querer llevar las deducciones de nuestro modelo al sistema objetivo de interés del economista, esto no es posible solo a través del modelo. Es necesaria más información que justifique este paso desde los modelos generales idealizados a ámbitos más concretos.

Los experimentos parecen representar la realidad fehacientemente, pero su nivel de aplicación es demasiado puntual o estrecho. Específicamente, los RCTs son creíbles al obtener sus conclusiones deductivamente y con menos supuestos que otros métodos.

Estos métodos de evidencia parecen complementarse mutuamente en exactamente sus respectivas limitaciones. El objetivo debe estar en concebir capacidades que puedan ser aplicables a situaciones generales y no solo a situaciones locales. Por consiguiente, podemos establecer los siguientes objetivos para cada método:

1. Los modelos teóricos plantean enunciados teóricos, que pueden ser probados a través de experimentos.
2. Los experimentos contra ejemplifican o sustentan enunciados teóricos, además de entregar intuiciones u obtener capacidades generalizables que amalgamadas pueden ser modeladas.

Lo anterior evidentemente es un proceso iterativo. Los modelos y los experimentos se complementan al plantear nuevas pruebas posibles de realizar y, posteriormente, contra ejemplificando. Si uno falla, es posible ajustar la teoría, y mejores teorías también permiten mejorar nuestros experimentos. Si nuestros modelos y nuestros experimentos no pueden darnos evidencia totalmente certera sobre por qué ocurren en realidad las cosas y cada uno puede hablar sobre por qué posiblemente ocurren las cosas, el uso de ambos de forma complementaria permitiría aumentar la probabilidad o la creencia de por qué posiblemente ocurren las cosas. La teoría se fortalece al tener pruebas concretas y empíricas. El experimento se fortalece al tener un modelo que describe mecanismos que el mismo experimento deja de lado.

Ahora bien, los experimentos no están supeditados a la teoría, sino que será una decisión del investigador si proseguir desde una descripción a un modelo o un experimento. Puede ser el caso que un economista decida realizar múltiples experimentos (algunos más o menos complejos) que permitan generar intuiciones u obtener capacidades generalizables que, posteriormente, se amalgamen en un modelo matemático que permita generar hipótesis sobre mecanismos que puedan ser probadas mediante métodos empíricos. De acuerdo con Guala (2005), en vez de pensar modelos y experimentos por separado o mediando uno por el otro, debemos pensarlos cada uno como sistemas. Estos sistemas no son el sistema objetivo y ambos deben justificar su similitud con él, que les entregue validez externa, ya que sus beneficios solo se sustentan por sí mismos en su propio sistema, el del modelo y el del experimento

Al incluir características que pueden encontrarse en el sistema objetivo, y que pueden no estar incluidas en el modelo, podemos decir que el sistema del experimento es más concreto que el sistema del modelo.

El modelo es controlable, idealizable a voluntad y contiene más información de mecanismos que el experimento. Ambos, en un proceso iterativo, permiten dar mayor seguridad a las conclusiones que se deseen derivar sobre el sistema objetivo. Complementariamente, la extrapolación desde el experimento al sistema objetivo, así como la extrapolación desde el modelo al sistema objetivo, tendría una mayor probabilidad de ser cómo ocurren las cosas.

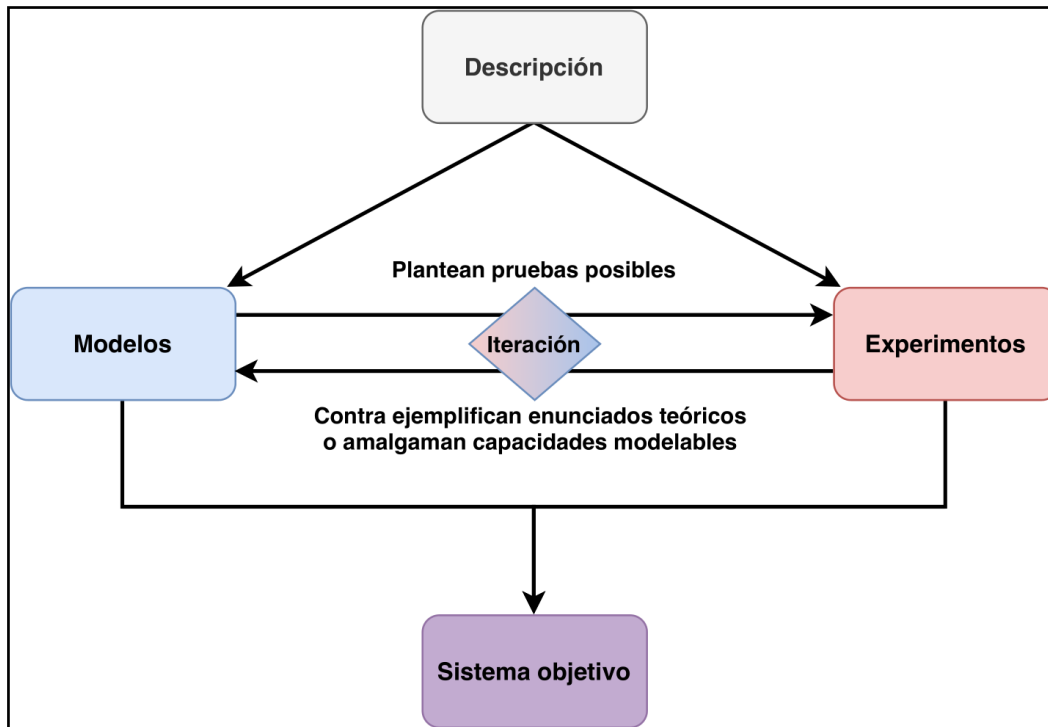


Figura 2: Amalgama de métodos de evidencia. Basado en Guala (2015).

Por tanto, los experimentos permitirían concretizar un modelo, mientras que un modelo permitiría otorgar mecanismos para un experimento. Será la identificación de dichos mecanismos lo que nos permitiría realizar una extrapolación de los resultados de estos métodos a un nuevo contexto y solo un proceso iterativo permitirá que estemos más seguros acerca de que nos acercamos al sistema objetivo.

Será el proceso de identificar dichos mecanismos en dónde se justificará la extrapolación. Aunque los modelos son una forma de obtener estos mecanismos, no serían la única. Otros métodos de evidencia pueden usarse como métodos de exploración (e.g. trabajos cualitativos, evaluaciones de proceso, estadística descriptiva) o incluso, en estados más avanzados, es posible realizar RCTs anidados (i.e. aleatorizar subelementos de un RCT para comprender los mecanismos detrás del efecto de una intervención). Los modelos y los RCTs podrían ser métodos preferidos de evidencia, dado que, dentro de su mismo sistema, sus conclusiones se obtienen de forma deductiva. Sin embargo, esto no puede eliminar otras formas de acercamiento que el economista pueda tener para aproximarse a la complejidad del fenómeno económico. Sería un absurdo pensar que un solo método lograría resolver esa complejidad y entregarnos todas las respuestas y descripciones de un fenómeno. Ante esta complejidad, se hace relevante aceptarla y buscar formas de describirla.



Este trabajo de amalgama de evidencia, aunque no se ha extendido en la disciplina, sí cuenta con precedentes, como es el estudio teórico y empírico de las trampas de pobreza o los estudios tanto empíricos como teóricos en Banerjee *et al* (2015). Junto con ello, organizaciones como J-PAL han fomentado el uso de “Teorías de Cambio” para identificar los mecanismos en que actúa una intervención. Esta amalgama de evidencia pone de manifiesto el desafío a la economía de no plantear un solo método para una gran disciplina, sino que diferentes acercamientos a preguntas más específicas. Todo esto a través de la intervención y la teoría, no de la complejidad económica en general, pero sí de preguntas más específicas y quizá más abarcables, como podría ser la mejora de la educación preescolar, el uso del microemprendimiento para aliviar la pobreza, la disminución de brechas de género en el ambiente laboral, entre muchos otros problemas de política pública actual. Todas problemáticas que requieren de buena evidencia para su solución.

## 5. Conclusiones

El estudio de la economía ha tenido cambios desde los tiempos de sus autores clásicos. La economía ha pasado por dos grandes revoluciones metodológicas. La primera, la Revolución Marginalista, introdujo las matemáticas, el cálculo y los modelos teórico-matemáticos al análisis de los fenómenos económicos. Esto bajo la perspectiva de que la economía se puede estudiar como la física estudia sus sistemas. La segunda revolución, la Revolución Empírica, se basó en la estadística y la econometría como método de estudio, bajo la idea de que los fenómenos económicos pueden estudiarse como la medicina.

Actualmente ambos métodos son utilizados, pero con un alza sostenida de publicaciones que utilizan métodos empíricos. Ambos métodos tienen sus detractores: los de la economía teórica proponen que estos tienen problemas de credibilidad con base en sus idealizaciones. Por otro lado, los detractores de los métodos empíricos proponen que estos son muy específicos y tienen dificultad para generalizar sus resultados.

Los modelos teóricos no son el sistema objetivo del economista, sino que se utilizan de forma subrogada para estudiar un sistema objetivo. Los modelos no pueden generar directamente explicaciones del mundo real, ya que estos contienen idealizaciones que permiten al investigador hacer comprensibles fenómenos complejos. Esto requiere que el modelo sea interpretado para realizar el enlace desde el sistema del modelo al sistema objetivo. Las explicaciones de los modelos serían solo explicaciones de cómo es posible que sucedan las cosas.

La evidencia empírica (ejemplificada en este estudio a través de los RCTs) no está exenta de limitaciones. La principal consiste en que es necesario interpretar un RCT para extrapolar sus resultados desde el sistema del experimento al sistema objetivo, que podría ser el contexto de aplicación de una política pública. Los mecanismos de un RCT son omitidos por el método, sin ellos no es posible asegurar que la eficacia de un RCT se volverá una efectividad en el sistema objetivo. Si se desea extrapolar los resultados de las técnicas empíricas a nuevos contextos de aplicación, esta evidencia solo entregará capacidades que estarán justificadas en cuanto estén identificados los mecanismos que causaron la eficacia en el contexto del experimento y exista algún grado de similitud de estos mecanismos en el

sistema objetivo. El RCT permitiría contestar preguntas sobre cómo sucederían las cosas si fueran como en el sistema del experimento.

Ambos métodos tienen limitaciones, pero también tienen beneficios. Los modelos son generales y entregan información acerca de posibles mecanismos, pero al ser idealizados no representan el mundo real. Los RCTs exploran directamente el mundo real y tienen una alta validez interna, pero esta validez interna es sumamente específica para el contexto de la intervención realizada. Estos métodos pueden ser complementarios para suplir sus respectivas limitaciones y permitir extrapolar, si es posible identificar mecanismos.

Los modelos teóricos permitirían plantear enunciados teóricos que luego pueden probarse empíricamente, mientras que los métodos empíricos pueden sustentar dichos enunciados teóricos y extraer capacidades generalizables que luego se pueden amalgamar en un modelo. Dada la complejidad de los fenómenos económicos, no pareciera haber método infalible para estudiar la economía. Este desafío plantea tomar lo mejor de los métodos ya existentes y utilizarlos de forma robusta para comprender un fenómeno. Los modelos teóricos, más que una contraposición a los métodos empíricos (y viceversa), pueden ser utilizados como complementos bajo la aceptación de que ambos nos otorgan entendimiento de sucesos económicos complejos.

## Referencias

- Alexandrova, A. (2008). "Making models count". *Philosophy of Science*, 75(3): 383–404. <http://dx.doi.org/10.1086/592952>
- Alexandrova, A. y Northcott, R. (2009). "Progress in economics: Lessons from the spectrum auctions". En K. Harold y R. Don, *The Oxford Handbook of Philosophy of Economics*. Oxford University Press. doi: <https://doi.org/b2n56c>
- Angrist, J. D. y Pischke, J. S. (2010). "The credibility revolution in empirical economics: How better research design is taking the con out of econometrics". *Journal of economic perspectives*, 24(2): 3–30. doi: <https://doi.org/cd563q>
- Banerjee, A., Duflo, E., Goldberg, N., Karlan, D., Osei, R., Parienté, W., Shapiro, J., Thuysbaert, B. y Udry, C. (2015). "A multifaceted program causes lasting progress for the very poor: Evidence from six countries". *Science*, 348(6236): 1260799-1/16. doi: <https://doi.org/4p7>
- Batterman, R. W. (2005). "Critical phenomena and breaking drops: Infinite idealizations in physics". *Studies in history and philosophy of science part B: Studies in history and philosophy of modern*, 36(2): 225–244. doi: <https://doi.org/fnm99b>
- Bokulich, A. (2011). "How scientific models can explain". *Synthese*, 180(1): 33-45. doi: <https://doi.org/br8vd2>
- Cartwright, N. (1989). *Nature's capacities and their measurement*. Clarendon. doi: <https://doi.org/cpkt2j>

- Cartwright, N. (2007). "Are rcts the gold standard?" *BioSocieties*, 2(1): 11–20. doi: <https://doi.org/bwzwrw>
- Cartwright, N. (2009). "What is this thing called "efficacy"?. En C. Mantzavinos, *Philosophy of the social sciences : philosophical theory and scientific practice*, 185-206. Cambridge University Press. doi: <https://doi.org/gpnk>
- Craver, C. F. (2006). "When mechanistic models explain". *Synthese*, 153(3): 355–376. doi: <https://doi.org/ct73tv>
- de Regt, H. W. (2004). "Discussion note: Making sense of understanding". *Philosophy of Science*, 71(1): 98–109. doi: <https://doi.org/d3hzdj>
- de Regt, H. W., y Dieks, D. (2005). "A contextual approach to scientific understanding". *Synthese*, 144(1): 137–170. doi: <https://doi.org/dsh5t5>
- Deaton, A., y Cartwright, N. (2018). "Understanding and misunderstanding randomized controlled trials". *Social Science & Medicine*, 210: 2–21. doi: <https://doi.org/gd5qgt>
- Doganova, L. (2015). "Economic models as exploration devices". *Journal of Economic Methodology*, 22(2): 249–253. doi: <https://doi.org/gpnn>
- Dray, W. (1968). "On explaining how-possibly". *The Monist*, 52(3): 390–407. doi: <https://doi.org/fz8nz8>
- Duran, D. (2014). *De la Economía política a la ciencia económica: Dos tensiones que explican el cambio de objeto de estudio del fenómeno económico (Tesis de Magister)*. Santiago: Universidad de Santiago de Chile.
- Elgin M. y Sober E. (2002). "Cartwright on Explanation and Idealization". En Earman J., Glymour C., Mitchell S. (eds) *Ceterus Paribus Laws*. Dordrecht: Springer
- Euler, L. (1741). "Solutio problematis ad geometriam situs pertinentis". *Commentarii academiae scientiarum Petropolitanae*, 8: 128–140.
- Fevereau, J. (2016). "On the analogy between field experiments in economics and clinical trials in medicine". *Journal of Economic Methodology*, 23(2): 203–222. doi: <https://doi.org/ghn7h>
- Fletcher, S. C., Landes, J., y Poellinger, R. (2019). "Evidence amalgamation in the sciences: an introduction". *Synthese*, 196: 3163–3188. doi: <https://doi.org/gpns>
- Galiani, S., Gertler, P. J., Undurraga, R., Cooper, R., Martínez, S. y Ross, A. (2017). "Shelter from the storm: Upgrading housing infrastructure in latin american slums". *Journal of urban economics*, 98: 187–213. doi: <https://doi.org/f93x9k>
- Gertler, P. J. y Boyce, S. (2001). "An experiment in incentive-based welfare: The impact of progress on health in Mexico". En *Royal Economic Society Annual Conference 2003*, 85. Royal Economic Society. URL: <https://ideas.repec.org/s/ecj/ac2003.html>

- Graue, E., Hatch, K., Rao, K., y Oen, D. (2007). "The wisdom of class-size reduction". *American Educational Research Journal*, 44(3): 670–700. doi: <https://doi.org/dwhdtk>
- Grüne-Yanoff, T. (2009). "Learning from minimal economic models". *Erkenntnis*, 70(1): 81–99. doi: <https://doi.org/cxdkft>
- Grüne-Yanoff, T. (2013). "Genuineness resolved: a reply to Reiss' purported paradox". *Journal of Economic Methodology*, 20(3): 255–261. doi: <https://doi.org/f22p98>
- Guala, F. (2005). *The methodology of experimental economics*. Cambridge University Press. doi: <https://doi.org/frsd6b>
- Hamermesh, D. S. (2013). "Six decades of top economics publishing: Who and how?". *Journal of Economic Literature*, 51(1): 162–72. doi: <https://doi.org/gdgzp6>
- Harrison, G. W. y List, J. A. (2004). "Field experiments". *Journal of Economic literature*, 42(4): 1009–1055. doi: <https://doi.org/bbnhxw>
- Hausman, D. (1992). "Economics as an inexact and separate science". En *The Inexact and Separate Science of Economics* (pp.205-226). Cambridge: Cambridge University Press. doi: <https://doi.org/bbnhxw>
- Hempel, C. (1970). *Aspects of Scientific Explanation: And Other Essays in the Philosophy of Science*. New York: Free Press.
- Hempel, C. G. y Oppenheim, P. (1948). "Studies in the logic of explanation". *Philosophy of science*, 15(2): 135–175. doi: <https://doi.org/d6x7fq>
- Henderson, L. (Spring 2020 Edition). *The Problem of Induction*. The Stanford Encyclopedia of Philosophy, Edward N. Zalta (ed.). URL: <https://plato.stanford.edu/archives/spr2020/entries/induction-problem/>
- Hindriks, F. (2008). False models as explanatory engines. *Philosophy of the Social Sciences*, 38(3): 334–360. doi: <https://doi.org/ds38zq>.
- J-PAL. (2012). *Deworming: A best buy for development*. Innovations for poverty action (IPA). Consultado el 15 de junio de 2021. URL: <https://www.poverty-action.org/publication/deworming-best-buy-development>.
- Kitcher, P. (1981). "Explanatory unification". *Philosophy of science*, 48(4), 507–531. doi: <https://doi.org/cgbn8n>
- Kuorikoski, J. y Ylikoski, P. (2015). "External representations and scientific understanding". *Synthese*, 192: 3817–3837. doi: <https://doi.org/f3n5vr>
- Lange, M. (2013). "What makes a scientific explanation distinctively mathematical?". *The British Journal for the Philosophy of Science*, 64(3): 485–511. doi: <https://doi.org/gftk2c>
- Lange, M. (2016). *Because without cause: Non-causal explanations in science and mathematics*. Oxford University Press. doi: <https://doi.org/gpnt>

- Lipton, P. (2009). "Understanding without Explanation". En de Regt H., Leonelli S., y Eigner K. (eds.), *Scientific Understanding: Philosophical Perspectives* (pp. 43-63). Pittsburgh: University of Pittsburgh Press. doi: <https://doi.org/gpvn>
- List, J. A. (2007). "Field experiments: a bridge between lab and naturally occurring data". *The BE Journal of Economic Analysis & Policy*, 5(2): 1-47. doi: <https://doi.org/bh2pjd>
- Mäki, U. (1992). "On the method of isolation in economics". *Poznan Studies in the Philosophy of the Sciences and the Humanities*, 26: 19-54.
- Mäki, U. (2009). "MISSing the world. models as isolations and credible surrogate systems". *Erkenntnis*, 70(1): 29-43. doi: <https://doi.org/cvz5nd>
- McMullin, E. (1978). "Structural explanation". *American Philosophical Quarterly*, 15(2): 139-147.
- McMullin, E. (1985). "Galilean idealization". *Studies in History and Philosophy of Science Part A*, 16(3): 247-273. doi: <https://doi.org/b6fm57>
- Mirowski, P. (1992). *More heat than light*. Cambridge Books. doi: <https://doi.org/bkjn36>
- Mosteller, F. (1995). "The tennessee study of class size in the early school grades". *The future of children*, 5(2): 113-127. doi: <https://doi.org/crc855>
- Panhans, M. T. y Singleton, J. D. (2017). "The empirical economist's toolkit: from models to methods". *History of Political Economy* (49) (Supplement): 127-157. doi: <https://doi.org/ggthz8>
- Pincock, C. (2007). "A role for mathematics in the physical sciences". *Noûs*, 41(2): 253-275. doi: <https://doi.org/dnqsnr>
- Potochnik, A. (2017). *Idealization and the Aims of Science*. University of Chicago Press. doi: <https://doi.org/gpnw>
- Reiss, J. (2006). *Error in economics: towards a more evidence-based methodology*. London: Routledge. doi: <https://doi.org/c83f3q>
- Reiss, J. (2012). "The explanation paradox". *Journal of Economic Methodology*, 19(1): 43-62. doi: <https://doi.org/gg8nq4>
- Reutlinger, A. (2016). "Is there a monist theory of causal and noncausal explanations? the counterfactual theory of scientific explanation". *Philosophy of Science*, 83(5): 733-745. doi: <https://doi.org/gpnx>
- Reutlinger, A. (2017). "Explanation beyond causation? new directions in the philosophy of scientific explanation". *Philosophy Compass*, 12(2): e12395. doi: <https://doi.org/gpnz>
- Rubin, D. B. (2005). "Causal inference using potential outcomes: Design, modeling, decisions". *Journal of the American Statistical Association*, 100(469): 322-331. doi: <https://doi.org/cqsb7s>
- Schelling, T. (2006). *Micromotives and macrobehavior*. WW Norton & Company.
- Strevens, M. (2008). *Depth: An account of scientific explanation*. Harvard University Press.

- Sugden, R. (2009). "Credible worlds, capacities and mechanisms". *Erkenntnis*, 70(1): 3–27. doi: <https://doi.org/bvvcnw>
- Suppes P. (1969). "Models of Data". En *Studies in the Methodology and Foundations of Science. Synthese Library (Monographs on Epistemology Logic, Methodology, Philosophy of Science, Sociology of Science and of Knowledge, and on the Mathematical Methods of Social and Behavioral Sciences)*, vol 22. Dordrecht: Springer. doi: <https://doi.org/gpn2>
- Svorenčík, A. (2015). "The experimental turn in economics: a history of experimental economics". *University of Utrecht: Utrecht School of Economics Dissertation Series #29*.
- Trout, J. (2002). "Scientific explanation and the sense of understanding". *Philosophy of Science*, 69(2): 212–233. doi: <https://doi.org/dj8d3h>
- Urbach, P. (1985). "Randomization and the design of experiments". *Philosophy of Science*, 52(2): 256–273. doi: <https://doi.org/dkkspt>
- van Frassen, B. C. (1980). *The scientific image*. Oxford University Press. doi: <https://doi.org/cjr6gp>
- Verreault-Julien, P. (2019). *Understanding with models*. Ph.D. thesis, Erasmus University of Rotterdam.
- Weisberg, M. (2012). *Simulation and similarity: Using models to understand the world*. Oxford University Press. doi: <https://doi.org/gpn3>
- Wimsatt, W. C. (1987). "False models as means to truer theories". En M. H. Nitecki y A. Hoffmann (eds.), *Neutral models in biology* (pp.23-55). Oxford: Oxford University Press.
- Woodward, J. (2000). "Explanation and invariance in the special sciences". *The British Journal for the Philosophy of Science*, 51(2): 197–254. doi: <https://doi.org/fn7znh>
- Woodward, J. (2003). *Making things happen: A theory of causal explanation*. New York: Oxford university Press. doi: <https://doi.org/c68mpx>
- Ylikoski, P. y Aydinonat, N. E. (2014). "Understanding with theoretical models". *Journal of Economic Methodology*, 21(1): 19–36. doi: <https://doi.org/gd8tpq>