

¿Cómo puede contribuir la filosofía de la ciencia en la crisis del COVID-19?

Carlos Romero¹

1 UNAM

Introducción

Diariamente vemos noticias sobre políticos irresponsables que rechazan el consejo que los expertos basan en los modelos científicos, o nos encontramos con notas periodísticas que distorsionan los hechos o las teorías. En México, diariamente somos testigos —tanto que se ha vuelto un chiste recurrente— de la evidente incapacidad de la comunidad periodística para cubrir informes técnicos, así como de la dificultad que tienen muchos columnistas para comprender incluso los más básicos conceptos de la estadística. Además, muchas veces nos preguntamos por qué los científicos y las organizaciones de salud parecen estar cambiando constantemente de opinión, contradiciéndose entre sí, o no terminan de ponerse de acuerdo.

Aunque hay muchos factores relacionados con todos los hechos mencionados, hay un hecho fundamental sobre nuestra propia naturaleza que, a su vez, determina las posibilidades del conocimiento científico.

El hecho es muy sencillo de notar y de comprender, y es simplemente que los seres humanos somos seres *limitados*: que actuamos bajo muchas restricciones. Estamos limitados en nuestras capacidades; aunque podamos ampliarlas con el uso de la tecnología, también los recursos tecnológicos son limitados. Tenemos un tiempo limitado, un conocimiento previo limitado, y una capacidad de comunicación con otros seres humanos que también está limitada.

Este hecho, tan general y sencillo, tiene consecuencias importantes sobre la naturaleza misma de la ciencia, y como esta naturaleza puede ser tan poco intuitiva —tan poco cercana al sentido común—, podemos comenzar a comprender por qué políticos, reporteros y la sociedad en general a veces tenemos tantos problemas para comprenderla.

Vamos a ver tres aspectos de esto: la *incertidumbre* en la recolección de evidencia, que nos lleva al uso de la estadística; los “espacios abiertos” en el diseño de teorías, que nos lleva a la representación mediante modelos; y finalmente, los diversos baches en el camino hacia la formación de un consenso científico. Espero que comprender estos tres aspectos fundamentales del quehacer científico —una comprensión que se logra, por supuesto, al estudiar a la ciencia, pero también al estudiar la reflexión filosófica sobre ella— ayude a comprender mejor la aparente vorágine de información que esta crisis ha provocado.

Incertidumbre y estadística

El primer aspecto es la existencia de incertidumbre.

Distingamos el concepto de incertidumbre del de ignorancia. La ignorancia es simplemente el desconocimiento de cierto aspecto sobre cierto asunto u objeto, y por tanto es “blanco y negro”: dado un tema, lo conoces o lo ignoras. Incertidumbre, como la entiendo aquí y como se entiende usualmente, es la falta de comple-

ta seguridad respecto de la verdad de una hipótesis; esta seguridad se puede medir en grados, mediante la teoría de la probabilidad (u otras teorías), y por lo tanto no es “blanco y negro”. Por supuesto, la incertidumbre puede deberse, a su vez, al desconocimiento de ciertos hechos.

Como anuncié arriba, el concepto de incertidumbre es importante porque los humanos somos seres con recursos limitados. Esto nos obliga a hacer inferencias desde una *muestra*, es decir, un fragmento del mundo: una encuesta, o un experimento específico en un laboratorio. Con ello, buscamos generalizar hasta cubrir un fragmento más grande del mundo, o el universo entero. Así, partimos de selecciones de un fragmento de todo el conjunto de sistemas que caen dentro de la investigación, propiamente hablando. Seleccionamos muestras porque no podemos estudiar a la población completa. La selección de estas muestras está guiada por la estadística, que es el lenguaje universal de las ciencias (Spiegel 1991).

(Los filósofos de la ciencia de inicios del siglo XX pensaban que ese lenguaje era la lógica matemática, pero estaban equivocados; filósofos posteriores como Patrick Suppes (1969) argumentaron que eso no reflejaba el verdadero proceder científico.)

En su aspecto más básico, la selección de una muestra debe guiarse por el principio de que debe ser lo más *representativa* posible: aunque es un subconjunto de la población total, lo que se busca es que represente de la manera más fiel posible a la población entera. Esto, a su vez, dependerá de dos factores: qué tan variada es la muestra, y qué tan variada es la población total.

Toda inferencia desde un contexto limitado hasta una generalidad supone que hay un patrón o una *regularidad* subyacente: que así como es en este laboratorio, así aproximadamente es en todo lugar, y en todo momento, donde se encuentre el fenómeno. A veces esas regu-

laridades constituyen *leyes* universales, otras veces mecanismos o constricciones más particulares (Ladyman & Ross 2007; Winning en prensa).

La necesidad de tomar muestras —o lo que es igual: la imposibilidad de conocer la población total, debido a nuestras restricciones— implica cierto grado de incertidumbre en las inferencias que podemos hacer. Calcular esa incertidumbre es la tarea fundamental de la estadística inferencial.

Para subrayarlo: esto vale tanto en el tiempo con el espacio. Es decir: suponemos que el sol sale hoy tanto como salió ayer y saldrá mañana, y que sale aquí tanto como saldrá en Australia y en Groenlandia. Suponer que hay estas generalidades que se repiten, permite que estudiemos un fenómeno general solamente analizando muestras. Nos permite inferir que el virus que analizo en mi laboratorio es básicamente el mismo que anda circulando por el mundo —al menos el de una cepa determinada—, o que los patrones de compra y venta de una persona en un intervalo determinado son más o menos generales y se van a replicar en una economía. Esta suposición de uniformidad en la naturaleza es, estrictamente hablando, una suposición *metafísica*: una muy general, y que podemos confirmar diariamente, pero que nunca podremos confirmar absoluta y definitivamente (Henderson 2020).

Así, la suposición de que estamos detectando un patrón puede fallar de manera categórica, si no hay tal patrón —si la naturaleza no es suficientemente uniforme en ese aspecto. Pero también puede fallar en grados, si la representación del patrón que hemos detectado no es suficientemente fina. Esto nos lleva a la naturaleza del tipo de representación más común en la ciencia, que es el modelo.

La representación científica mediante modelos

De prácticamente la mayoría del universo nos es imposible tener una percepción directa: quizá porque están en el pasado remoto, o porque están muy lejos, o porque son muy pequeños o muy grandes. Para estudiarlos, requerimos sustitutos o *indicadores*, así como *tecnología* para estudiarlos. Además, muchos fenómenos son tan complejos que, para siquiera comenzar a representarlos, debemos poner entre paréntesis algunas de sus características y de los factores que influyen en ellos.

Un ejemplo de lo primero es el estudio del clima de épocas pasadas, la *paleoclimatología* (aunque podríamos considerar otras ramas de la ciencia, como la macroeconomía). Como no podemos regresar en el tiempo para estudiar el clima de tiempos pasados en los que no había registros sistemáticos —o incluso cuando no existían seres humanos sobre la Tierra—, necesitamos indicadores de ese fenómeno. Existen varios tipos, como los testigos de hielo, que se extraen de diferentes capas y cuyas propiedades físicas indican la evolución del clima durante su existencia (Steig 2015).

Las indicaciones son asociaciones probabilísticas —otra vez la incertidumbre— que se justifican con base en el conocimiento científico disponible (Castro 2020). A su vez, dando estas correlaciones por sentado, la evolución de estos datos se pone en una *serie de tiempo*, que es simplemente el acomodo de estos datos de acuerdo con su ocurrencia en el tiempo; ella nos permite ver cómo han evolucionado y nos pueden sugerir la existencia de ciertas regularidades o patrones. Esta “sugerencia” se formaliza en un *modelo*.

Existen varios conceptos de “modelo” en la ciencia —como un modelo a escala del sistema solar, donde los planetas y el Sol se representan con esferas de unicel, digamos—, pero el más importante es este: un modelo es la *representación*

matemática de un fenómeno. Consiste en una o varias ecuaciones y en una interpretación “oficial” o canónica de las variables y funciones involucradas.

Un ejemplo de esto, de particular relevancia para el contexto presente, son los modelos *compartimentalizados* de la epidemiología (Edelstein-Keshet 2005, §6.6). El caso más sencillo es el modelo SIR. Se estudia una población con un número fijo de miembros, en donde surge una enfermedad. Se divide a la población en tres compartimentos o estados: Susceptibles, Infectados y Recuperados (que incluye los decesos por la enfermedad). El modelo consiste en tres ecuaciones que dan la dinámica del cambio de un estado a otro (es decir, la tasa en la que los susceptibles pasan a ser infectados y estos a recuperados), dados dos *parámetros* o variables que se van a sustituir por valores experimentales: una tasa de transmisión y una tasa de recuperación. Solamente para ilustrar, voy a poner las tres ecuaciones, que son muy sencillas y que explico abajo:

$$\begin{aligned}\frac{dS}{dt} &= -\frac{bIS}{N} \\ \frac{dI}{dt} &= \frac{bIS}{N} - gI \\ \frac{dR}{dt} &= gI\end{aligned}$$

La primera nos dice cuántas personas (por segundo, vamos a decir, aunque en realidad, en un intervalo infinitesimal de tiempo) pasan a ser susceptibles: es el negativo del factor bIS dividido sobre el número total de personas en la población (N). El factor bIS , a su vez, es el producto del número de Infectados por el número de Susceptibles por el parámetro b , que mide la probabilidad de contagio. Así, la primera ecuación nos dice cuántas personas dejan de ser susceptibles (de ahí el signo negativo): esa cantidad depende de la probabilidad de contagio, y de cuál es la fracción de la población que está infectada y cuál es susceptible. La tercera ecuación nos dice cuántas personas se recuperan por segundo: esta cantidad es

una proporción g de las que están infectadas, donde g es un parámetro que mide la tasa de recuperación. Finalmente, de las primera y la tercera ecuación, podemos comprender la segunda: nos dice cuántas personas se infectan por segundo, y son aquellas que han dejado de ser susceptibles pero no pasan a recuperarse.

El modelo SIR, entonces, consiste en las tres ecuaciones anteriores y la interpretación de los objetos matemáticos que describen: las tres funciones S , I , R , la variable N y los parámetros b y g . Este modelo no es una *teoría* completa, no brinda una explicación del fenómeno como tal —no nos explica, por ejemplo, por qué alguien pasa de estar infectado a recuperarse—, sino que es una descripción matemática de él: la evolución temporal de una población con respecto a una enfermedad.

Además de la comprensión que se logra con el lenguaje matemático —se reducen las palabras y se extrae un patrón complejo en tres sencillas ecuaciones—, la virtud de tener un formalismo es que permite el análisis matemático: además de describir la historia de una epidemia particular, podemos comprender las características generales de muchas posibles historias. Este método, que comenzó con Poincaré, nos permite un entendimiento más robusto del fenómeno (Lyon & Colyvan 2008; DeLanda 2011).

En muchos casos, el patrón que estamos analizando no es exactamente la forma en que se da el fenómeno fuera del ambiente controlado: nuestra descripción se acerca a, pero no es una copia completamente exacta de, el fenómeno. (Este es uno de los significados centrales del concepto de “modelo”.) Por ejemplo, en el caso de las epidemias, el modelo *SIR* puede ser útil para un entendimiento general del fenómeno, pero ciertamente deja muchos factores fuera, como los decesos, o la inmunidad. Esta es una característica general de los modelos: que *idealizan* y que *abstraen*.

Los modelos abstraen porque ignoran ciertos factores (Jones 2005). En el caso del modelo SIR, se ignoran factores como cuántas personas mueren o nacen (pues se deja a N constante), o si entre los infectados algunos pasan a ser inmunes y no pueden volver a infectarse, etcétera. El modelo abstrae de estas características.

Los modelos también *idealizan* porque modelan a ciertas características de una forma distinta a como son (Potochnik 2017). Por ejemplo, el modelo SIR idealiza a la población como si fuera un número continuo —como un líquido, digamos—, en lugar de un número de personas divisibles entre sí; esta idealización se hace para poder utilizar las herramientas del cálculo integro-diferencial.

En la filosofía contemporánea de la ciencia existen muchas clasificaciones de los diferentes tipos de idealizaciones y abstracciones, pero por ahora nos basta con notar que, al final del día, ambas expresan el mismo fenómeno subyacente: la limitación de nuestras capacidades y nuestros recursos. Abstraemos e idealizamos porque muchos fenómenos en el mundo son complejos: contienen muchos componentes que interactúan entre sí, y son afectados por, e influyen en, muchos otros tipos de fenómenos. Abstraer estas interacciones o idealizar algunos de sus componentes es necesario si queremos un modelo que sea manejable, con el que se puedan hacer cálculos.

Los modelos también resumen o generalizan, tomando ciertos promedios, sumas u otros derivados como indicadores del comportamiento individual (Batterman 2001). Por ejemplo, un modelo de la economía puede contener como parámetro el producto interno bruto del país, pero este parámetro es una suma total del comportamiento económico de millones de agentes individuales. Se habla entonces de una resolución del modelo: por ejemplo, si hiciéramos *zoom* dentro del producto interno bruto, veríamos una red muy compleja de todas las transac-

ciones que lo dan como resultado. Lo mismo sucede si vemos una porción de agua en un recipiente: si hacemos *zoom*, encontraremos todas las moléculas en sus interacciones químicas. Se dice entonces que el agua existe en una escala distinta a las moléculas, como el producto interno bruto existe en una escala distinta de las compras y las ventas individuales (Ladyman & Ross 2007); pero aceptamos la realidad de estas macro-entidades, además de sus componentes, porque ellas tienen poderes causales: porque tienen efectos reales en el mundo (Bunge 2004).

En la filosofía de la ciencia existe un debate sobre cómo es que las representaciones científicas representan a los sistemas físicos (Chakravartty 2010), y en particular cómo es que un modelo idealizado lo hace: ¿representa sistemas idealizados que se parecen a los reales? ¿O representa sistemas reales de forma idealizada? De igual forma, existe un debate, ya muy viejo, sobre el *reduccionismo*: además de la porción de las moléculas, ¿debemos aceptar la existencia de la porción de agua, si esta está completamente compuesta de aquéllas? (Bunge 2004; Ladyman & Ross 2007)

Sea como sea que se resuelvan estas preguntas, el que los modelos no sean representaciones completamente “exactas” o “fieles”, es otra puerta de entrada para la incertidumbre: dentro de aquello que estamos representando, ¿cuál es el rango de posibles variaciones en las que el modelo representa sistemas más cercanos al real?

La misma incertidumbre que se tiene al recolectar evidencia —por ejemplo, debido al hecho de que tenemos acceso solamente a *muestras* y no a la población entera, o a indicadores y no al fenómeno en sí— hace que algunos de los parámetros de los modelos también tengan incertidumbre, que se hereda a la descripción y predicción que podemos hacer con ellos. Tenemos, entonces, un *espacio paramétrico*: un espacio de posibles valores

de esos *parámetros*, a los que podemos “modular” como la perilla de un radio (Spiegel 1991). Dependiendo qué tan grande sea nuestra incertidumbre, más amplio será el espacio de *parámetros* que tendremos que considerar.

Comprender el concepto de incertidumbre también es vital para comprender que muchos resultados científicos en realidad son resultados sobre *el rango de hipótesis que es razonable creer, dada la evidencia*: es decir, las diferentes posibilidades que, por todo lo que sabemos hasta ahora, podrían darse, aún cuando tenemos cierta incertidumbre sobre cuál se dará. No solamente acotamos el espacio de parámetros de un modelo; también, entre más exacto es el conocimiento que logramos, más acotado es ese rango de hipótesis y modelos que posiblemente describen al fenómeno.

Si comprendemos que el avance del conocimiento *científico* se trata de acotar la incertidumbre, esto podría —espero— ayudarnos a superar la fe ciega pero también las teorías de la conspiración o el negacionismo.

No es justificable la fe ciega porque, desde el inicio, sabemos que en los modelos científicos hay idealización, abstracción, y la consecuente incertidumbre; pero esto explica por qué a veces los grupos científicos y los poderes políticos cambian de opinión, se contradicen, y promueven distintos programas y acciones: porque el rango de las hipótesis aceptables se hace más pequeño, o porque algún tipo de evidencia inesperada modifica la opinión común.

La ciencia avanza estableciendo consensos sobre lo que indica la evidencia, pero el progreso existe porque los consensos no son dogmas

Es un subtítulo muy largo, pero resume la situación esencial. Empecemos con la noción de consenso.

Un consenso es un acuerdo entre diversos agentes (personas con capacidad de actuar). Un consenso sobre algún tema puede deberse a muchas razones, como intereses comunes o amenazas; pero un consenso propiamente *científico* se debe a un acuerdo sobre lo que indica la evidencia disponible. Como vimos antes, la ciencia nunca provee conocimiento ilimitado, sino hipótesis que mejor explican la evidencia que, bajo nuestras limitaciones, hemos podido conseguir.

La fuerza de un consenso científico se debe a muchos factores sociales estudiados por la sociología de la ciencia, pero en su aspecto puramente *epistemológico*, se debe a la percepción informada que la comunidad científica tiene de un hecho: qué tan fuerte es el apoyo de la evidencia disponible hacia una hipótesis particular (Kitcher 1993, cap. 3). Entre más fuerte es ese apoyo, se restringe más el conjunto de hipótesis alternativas, y cobra más potencia la idea de que la hipótesis no es una “mera hipótesis”, sino que representa a un hecho.

Un ejemplo de esto es la existencia de la selección natural. Ante los negacionistas y los defensores de teorías pseudocientíficas como el diseño inteligente, muchos biólogos responden que la evolución por selección natural “no es una teoría: es un hecho”. En parte esto es, por supuesto, algo de retórica para acallar a los negacionistas; pero en parte también refleja el que, en la ciencia y en la vida cotidiana, tomamos como hecho aquellas hipótesis para las que nuestra evidencia brinda el mayor apoyo.

La existencia de consensos científicos, que destilan el conocimiento más sofisticado que se tienen sobre un área, refuta al *pluralismo* radical: la tesis de que “no hay una sola ciencia”, como si se tratara de conjuntos dispares de personas, cada una con sus creencias particulares, sin poder lograr un acuerdo. Es verdad que sobre muchas cuestiones todavía no hay un consenso, y cualquier especialista que

trabaje en una de ellas será el primero en decírtelo: te dirá “Hasta hoy sabemos que X, pero sobre este problema específico todavía no se sabe lo suficiente”. Puede ser que haya una ausencia de una teoría, o que falte mucha más evidencia, o una combinación de los dos. En otros casos, existe la teoría y la evidencia, pero también se conoce cómo *no* casan una con la otra (Barwich 2019).

En las circunstancias como la de la presente crisis por el COVID-19, donde surge de manera bastante rápida un fenómeno que no se comprende muy bien, la evidencia sobre sus características puede estar siendo descubierta paso a paso, a veces lentamente. A veces, incluso, ni siquiera se sabe en dónde buscarla, ni cuáles son las preguntas correctas a las que hay que encontrarles respuesta (Kitcher 1993, cap. 4).

Esta ignorancia sobre cuáles son las preguntas correctas, y la incertidumbre sobre qué indica la evidencia, puede resultar en consensos de muy breve duración, que dan la impresión de que la comunidad científica no se pone de acuerdo. Y a veces es verdad, no se ponen de acuerdo.

Sin embargo, con un poco de suerte, ese desacuerdo se arregla rápidamente, e indica la confluencia de opiniones debido a un muy buen argumento sobre cómo debe interpretarse la evidencia. Si tenemos muy buena suerte, los descubrimientos posteriores serán coherentes con ese acuerdo, y el consenso se reforzará, de manera que se comience a establecer una teoría que agrupe los diferentes aspectos del fenómeno (esto se parecería a uno de los varios sentidos en que Kuhn (1970) hablaba de *paradigmas*). Si no tenemos suerte, persistirá el disenso, y podrían formarse tendencias, corrientes, escuelas o grupos, que diferirán en sus hipótesis acerca de cómo es el fenómeno de acuerdo a la evidencia disponible. El público en general a veces creará que una de estas hipótesis representa la real-

idad como tal; en la mayoría de los casos, solamente los especialistas sabrán que existe este desacuerdo.

Pero el progreso existe porque los consensos no son dogmas: creencias inamovibles frente a la evidencia. Sí puede suceder —por razones incluso puramente psicológicas— que algunos defensores de una hipótesis se resistan a abandonarla, incluso frente a mucha evidencia en su contra (extrapolar estos casos llevó a Max Planck a la idea que tradicionalmente se frasea así: “la ciencia avanza un funeral a la vez”). Pero esta resistencia difícilmente será duradera. La emergencia de un nuevo paradigma se vuelve una crisis notoria cuando la hipótesis anterior deja de poseer las virtudes —los rasgos deseables— que los científicos esperan encontrar en una teoría aceptable.

Si tenemos suerte, esa crisis se resolverá en una teoría bien armada: una que *explique* los fenómenos involucrados: que diga por qué suceden, que vaya más allá de un modelo que solamente los *describa*. Si no tenemos suerte, la crisis continuará durante años.

Referencias

- Barwich, Ann-Sophie (2019) “The Value of Failure in Science: The Story of Grandmother Cells in Neuroscience”. *Frontiers in Neuroscience* **13**(1121).
- Batterman, Robert (2001) *The Devil in the Details: Asymptotic Reasoning in Explanation, Reduction, and Emergence*. Oxford University Press.
- Bunge, Mario (2004) *Emergencia Y Convergencia: Novedad cualitativa y unidad del conocimiento*. Gedisa.
- Castro, Matías (2020) “Algunos Problemas Epistemológicos y Metodológicos en la Construcción de Indicadores Sociales”. *Nullius in Verba Site* 2711-2616. URL= <<https://nulliusinverbasite.com/epsprob/>>
- Chakravartty, Anjan (2010) “Informational Versus Functional Theories of Scientific Representation”. *Synthese* **172**, pp. 197-213.
- DeLanda, Manuel (2011) *Intensive Science and Virtual Philosophy*. Bloomsbury.
- Edelstein-Keshet, Leah (2005) *Mathematical Models in Biology*. SIAM.
- Henderson, Leah (2020) “The Problem of Induction”, *The Stanford Encyclopedia of Philosophy (Spring 2020 Edition)*, Edward N. Zalta (ed.), URL = <<https://plato.stanford.edu/archives/spr2020/entries/induction-problem/>>.
- Jones, Martin (2005) “Idealization and Abstraction: A Framework”. En Jones & Cartwright (eds.): *Idealization XII: Correcting the Model*, pp. 173–217. Rodopi.
- Kitcher, Philip (1993) *The Advancement of Science: Science Without Legend, Objectivity Without Illusions*. Oxford University Press.
- Kuhn, Thomas (1970) *The Structure of Scientific Revolutions, 2nd edition*. University of Chicago Press.
- Ladyman, James, & Ross, Don (2007) *Every Thing Must Go: Metaphysics Naturalized*. Oxford University Press. Con David Spurrett and John Collier.
- Lyon, Aidan & Colyvan, Mark (2008) “The Explanatory Power of Phase Spaces”, *Philosophia Mathematica* **16**(2), pp. 227–243.
- Potochnik, Angela (2017) *Idealization and the Aims of Science*. University of Chicago Press.
- Spiegel, Murray R (1991) *Probabilidad y Estadística*. McGraw-Hill.

Steig, E.J. (2015) “Paleoclimatology: Ice Cores”. En Gerald R. North, John Pyle y Fuqing Zhang: *Encyclopedia of Atmospheric Sciences (Second Edition)*, pp. 404-410. Elsevier.

Suppes, Patrick (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. Springer.

Winning, Jason (en prensa) “Mechanistic Causation and Constraints: Perspectival Parts and Powers, Non-Perspectival Modal Patterns”. *British Journal for the Philosophy of Science*. DOI: 10.1093/bjps/axy042