




UNIVERSIDAD NACIONAL DE EDUCACIÓN A DISTANCIA

FACULTAD DE FILOSOFÍA



TRABAJO FIN DE GRADO

GRADO EN FILOSOFÍA

CAUSALIDAD EN ESCENARIOS DE COMPLEJIDAD

PRESENTADO POR

JOAQUÍN HERRERO PINTADO

DIRECTOR

JOSE FRANCISCO ÁLVAREZ ÁLVAREZ

MADRID, JUNIO 2018.

PÁGINA INTENCIONALMENTE EN BLANCO

Causalidad en escenarios de complejidad

Joaquín Herrero Pintado
Trabajo de Fin de Grado
Grado en Filosofía – UNED
5 de mayo de 2018

Resumen

En este trabajo abordamos la controvertida cuestión de la causalidad, de las relaciones causa-efecto, desde una óptica de filosofía contemporánea orientada al estudio info-computacional de la causalidad que considera que la filosofía debe de ser un estudio de la naturaleza completa y no solo la reflexión sobre el ser humano. Fundaremos nuestra argumentación en el concepto de *diferencia y complejidad*, gracias a los cuales es posible pensar la naturaleza como una interrelación compleja de sistemas de *información y simplificación* y veremos cómo este marco conceptual hace posible pensar la causalidad en términos que satisfagan enfoques empiristas al tiempo que no ignora la descripción de mecanismos dinámicos que la hacen posible.

Veremos cómo la metafísica de Leibniz acerca de la complejidad y su reducción ha sido puesta de nuevo en el centro del debate filosófico con mucho aprovechamiento por el enfoque info-computacional. Finalizaremos analizando un escenario concreto de complejidad, el de las redes neuronales y el fenómeno de *Big Data*, para ver cómo se pueden aplicar ahí las teorías causales de enfoque informacional.

La causalidad y el surgimiento del paradigma crítico

Podemos enmarcar las aportaciones de las primeras escuelas filosóficas, de Mileto, eleática o pitagórica a partir del siglo VI a. de C., con el término *filosofía de la naturaleza*, que podemos describir como una propuesta teórica de los procesos por los que, a partir de algún principio material regular y estable al que numerosos autores se refieren como *arjé* (ἀρχή), se produce la multiplicidad y el cambio que experimentamos con nuestros sentidos. Dichos filósofos aplicaron tal esquema de pensamiento tanto a física como a cosmología, medicina, matemáticas o incluso religión¹ comenzando así el descubrimiento de regularidades naturales, aquellas que solemos denominar *leyes naturales*. Hasta el día de hoy, el descubrimiento de regularidades naturales en escenarios de complejidad y cambio sigue siendo el punto central de la investigación que consideramos científica y también de gran parte del pensamiento filosófico.

Especialmente interesante es cuando algunas de las regularidades que se observan en la naturaleza parecen estar conectadas entre sí, variando de la misma forma. A este fenómeno lo denominamos *correlación* y suele ser el punto de partida para

1 Solís and Sellés (2009) p.63-5

plantear hipótesis sobre los mecanismos de funcionamiento de los fenómenos naturales. El concepto *correlación* fue definido en 1888 por sir Francis Galton, primo de Charles Darwin, tras observar la estrecha relación que hay entre la estatura de un hombre y la longitud de sus antebrazos.²

Ha sido ampliamente debatida filosóficamente la cuestión acerca de la naturaleza de la relación entre correlación y causalidad, esto es, si el hecho de que dos acontecimientos siempre aparezcan conjuntamente, uno tras otro, nos debe hacer pensar en que hay un mecanismo natural que necesariamente produce esa secuencia (lo cual sería un mecanismo causal) o si es sencillamente, como argumentará David Hume, un hecho de nuestra percepción, una necesidad mental, el percibir como una relación causal dos hechos de la naturaleza que, en realidad están desconectados.

El escepticismo de Hume respecto a la causalidad sirvió a Kant de aliciente para su puesta en cuestión de la metafísica especulativa³ y a emprender una investigación del concepto de causa que lo llevó a elaborar una propuesta no escéptica a la que llamó “la solución completa del problema humeano”. El resultado fue su revolucionaria teoría de la constitución de la experiencia mediante los conceptos a priori y los principios del entendimiento y a su concepción revolucionaria de juicios sintéticos a priori⁴.

Esta revolución kantiana da lugar a lo que se suele denominar *paradigma crítico*, por el título de las principales obras de Kant, en el que se rebajan las expectativas de la filosofía natural indicando que la filosofía debe dedicarse solo a aquello que es posible: a investigar las condiciones de posibilidad de nuestro acceso a un conocimiento de la naturaleza, cambiando así el foco de la investigación filosófica que, desde ese momento, pasa a concentrarse en los límites del conocimiento humano y enterrando el tema de la causalidad en el interior de la mente humana.

Marco conceptual: la jerarquía de la complejidad

George F. R. Ellis (1939), profesor emérito de sistemas complejos, indica que averiguar la naturaleza de la causalidad es un asunto fundamental para la ciencia, pues supone recuperar el objetivo inicial de la filosofía natural tal como fue concebida en Grecia, esto es, alejarse de una visión del mundo gobernado por dioses y demonios en favor de una basada en mecanismos confiables de causas y efectos verificados experimentalmente.⁵

En la ciencia las causas se separan de los efectos investigando las correlaciones entre fenómenos e interviniendo en la manipulación de uno de ellos (la causa) para

2 Mayer-Schönberger and Cukier (2013) p.60

3 “Lo confieso de buen grado: la advertencia de David Hume fue precisamente lo que hace muchos años interrumpió primero mi sueño dogmático y dio a mis investigaciones en el terreno de la filosofía especulativa una dirección completamente diferente”. Prolegomena, AA 04, p. 260

4 De Pierris and Friedman (2013)

5 Ellis (2008)

verificar si podemos predecir de forma fiable cambios en el otro (el efecto). Consideramos la física como el paradigma de esta forma de proceder, pues las descripciones matemáticas que utiliza permiten predecir el comportamiento físico de objetos cuando interaccionan entre ellos o se desplazan, mostrando así que es una ciencia que comprende la causalidad que los afecta.

La pregunta, indica Ellis, es si “*otras formas de causalidad tales como las investigadas en biología, psicología y las ciencias sociales son genuinamente efectivas o son simplemente epifenómenos cuya explicación es pura causalidad física*”. Este último es el llamado punto de vista reduccionista y afirma que no hay lugar para otro tipo de causalidades que no sean las físicas sobre la base de que todas las entidades físicas del mundo, incluidos nosotros mismos, estamos compuestos de los mismos elementos químicos, las mismas partículas fundamentales y, por lo tanto, sometidos a las mismas fuerzas físicas fundamentales.

Ellis afirma que sí hay otros tipos de causalidad en el mundo y se remite a la Metafísica de Aristóteles cuando en su libro I indica que “*se distinguen cuatro causas. La primera es la esencia, la forma propia de cada cosa, porque lo que hace que una cosa sea, está toda entera en la noción de aquello que ella es; la razón de ser primera es, por tanto, una causa y un principio. La segunda es la materia, el sujeto; la tercera el principio del movimiento; la cuarta, que corresponde a la precedente, es la causa final de las otras, el bien, porque el bien es en fin de toda producción*”⁶ Tal como indica Aristóteles, dice Ellis, experimentamos diferentes clases de causalidad en diferentes contextos. En física y química se muestran como principios y simetrías en las interacciones entre partículas; en bioquímica percibimos que la adaptación y la información es importante para llegar a explicaciones causales; en psicología y sociología resultan causalmente efectivas la reflexión analítica, la comprensión simbólica, los valores y el significado. ¿Son dos mundos imposibles de conciliar el de la causalidad física y las causalidades en los contextos que acabamos de enumerar?

Ellis propone un marco conceptual en el que podríamos encajar todas esas formas de causalidad. Dicho marco conceptual es el de la *jerarquía de la complejidad*, una jerarquía que incluiría en un nivel fundamental a la física de partículas, la física nuclear, la astronomía y la cosmología, cada una de ellas con sus procesos causales bien establecidos. Pero este marco también incluye a la psicología y la sociología en niveles más altos, donde los procesos causales no serían explicados en términos de los procesos fundamentales que suceden en los niveles más bajos de la jerarquía, sino que mediante procesos de reducción de complejidad de tipo *grano grueso*, es decir, con pérdida de información detallada, se permite que emerjan leyes efectivas, de carácter fenomenológico, en cada uno de los niveles superiores que aparentemente tendrían autonomía explicativa respecto de los niveles inferiores. Esta independencia de los niveles altos respecto a las leyes causales de los niveles bajos, dice Ellis, “*hace posible que las leyes fenomenológicas se conviertan en teorías efectivas de las interacciones en los niveles superiores*”. Esta propuesta se corresponde con lo que observamos en el mundo ya que, por ejemplo, los mecánicos que reparan motores o los neurocirujanos que reparan el

6 Aristóteles (1975) p.17-18

funcionamiento del cerebro, no necesitan comprender la física de partículas para ser eficaces en su profesión.

En el presente trabajo indagaremos en estos asuntos dentro del marco conceptual propuesto por Ellis:

1. las indagaciones filosóficas de Leibniz sobre la complejidad y los efectos de su reducción
2. la recepción en el siglo XX por Gregory Chaitin de la metafísica de la complejidad leibniziana y el papel central que juegan los procesos de reducción de complejidad para pensar tanto ontológica como epistemológicamente
3. las dificultades de la filosofía para conciliar la metafísica de la complejidad con un paradigma filosófico crítico predominante
4. propuestas contemporáneas para pensar filosóficamente el mundo fuera del paradigma crítico con las que se puede poner en marcha un nuevo proyecto de filosofía natural: las especulativas acerca del concepto de *diferencia* de Levi Bryant y las informacionales de Gordana Dodig-Crnkovic
5. un primer ejemplo práctico de cómo se pueden pensar los mecanismos causales en la biología si consideramos la naturaleza considerada como escenario complejo informacional, por Jessica Flack
6. un segundo ejemplo práctico de cómo usar estas propuestas filosóficas para comprender uno de los escenarios de complejidad informacional más relevantes en la actualidad, el *Big Data* y las redes neuronales. Veremos cómo podríamos teorizar sobre el funcionamiento interno de las redes neuronales si detectamos en ellas mecanismos de reducción de complejidad (Jessica Flack) y cómo los modelos causales podrían complementar los actuales desarrollos en inteligencia artificial (Judea Pearl) para mejorar la eficacia de estos.

Comenzaremos por rescatar del pensamiento de Gottfried W. Leibniz (1646-1716) su propuesta sobre el tratamiento de la complejidad.

Las indagaciones filosóficas de Leibniz

El “Discurso de Metafísica” de Leibniz, escrito en 1684, puede ser considerado un intento más, en línea con los filósofos naturales descritos al principio, de buscar los principios que rigen el funcionamiento del mundo.

La peculiaridad de la forma como hace Leibniz esa indagación en esa obra es que parte de la declaración bíblica de que tras cada episodio creativo que se narra en el capítulo 1 del Génesis Dios declara su obra muy buena⁷. Eso hace pensar a Leibniz que “*hay reglas de bondad y de perfección en la naturaleza de las cosas*”⁸ y por eso Dios ha tenido una razón para componer su creación de cierta manera y no de otra. La tarea que se propone Leibniz es averiguar ese criterio de bondad que el Génesis

⁷ versículos 10, “vio Dios que esto era bueno”; 12, “Dios vio que esto era bueno”; 18, “vio Dios que esto era bueno”; 21, “vio Dios que todo ello era bueno”; 25, “vio Dios que todo esto era bueno” y 31, “Dios vio que todo cuanto había hecho era muy bueno”; según <http://biblia.catholic.net>

⁸ Leibniz (2002), pp. 54-55

no revela pero que hizo posible que Dios declarara *muy buena* su creación. Este objetivo de Leibniz, el de investigar qué es lo que hace que un mundo sea mejor que otro cuando existe la posibilidad de elegir, suele ser poco destacado en los comentarios habituales sobre Leibniz pero resulta evidente al leer su *Metafísica*.

Leibniz propone que lo que haría inmejorable a un Universo cualquiera es que fuera creado a partir de elementos simples (a los que llamará mónadas 30 años más tarde) y lo desarrolla especialmente en los apartados 5 y 6 de su *Metafísica* que, por tanto, son claves para comprender la investigación leibniziana sobre la complejidad.

En el apartado 5, “En qué consisten las reglas de perfección de la conducta divina, y que la sencillez de las vías guarda relación con la riqueza de los efectos” Leibniz afirma⁹:

“Conocer en detalle las razones que han podido moverlo a escoger este orden del universo [...] excede de las fuerzas de un espíritu finito. Sin embargo se pueden hacer algunas observaciones generales acerca de la conducta de la providencia en el gobierno de las cosas. [...] Pues se puede decir que el que obra perfectamente es semejante [...] a un hábil mecánico que consigue su efecto por la vía menos complicada.”

“Por lo que se refiere a la sencillez de las vías de Dios, existe propiamente respecto a los medios, como al contrario la variedad, riqueza o abundancia se dan respecto a los fines o efectos”

“La razón quiere que se evite la multiplicidad en las hipótesis o principios”

En el apartado 6, “Que Dios no hace nada fuera del orden, y que ni siquiera es posible fingir acontecimientos que no sean regulares” Leibniz asocia el concepto de *orden universal* al hecho de que exista una regla para indicar que un procedimiento es mejor que otros, y que esta regla vale tanto para Dios como para los geómetras o los artesanos, es decir, es válida para cualquiera que desee fabricar un objeto final.

¿Cuál es esa regla para elegir el mejor procedimiento? Leibniz lo indica en dicho apartado:

“Lo que pasa por extraordinario solo lo es respecto a algún orden particular establecido entre las criaturas. Pues en cuanto al orden universal, todo es conforme a él.”

“Pero cuando una regla es muy compleja, lo que es conforme a ella pasa por irregular”¹⁰

“De cualquier manera que Dios hubiese creado el mundo, siempre hubiera sido regular e incluido en cierto orden general”

“Dios ha elegido el que es más perfecto, es decir, el que es al mismo tiempo más sencillo en hipótesis y más rico en fenómenos”

9 Leibniz (2002), pp. 57,58

10 *“Mais quand une règle est fort composée, ce qui lui est conforme passe pour irrégulier”*

Leibniz asocia, por tanto, los principios rectores de la actividad creadora divina a decisiones respecto a cuánta complejidad es admisible.

Esta regla también sirve para determinar cuándo algo constituye una mejor explicación que una explicación alternativa. Para Leibniz podemos distinguir entre una explicación válida y otra inválida simplemente considerando el tamaño de la “regla” o hipótesis que la describe. Cuando necesitamos un número extenso de reglas explicativas entonces la explicación es más imperfecta que cuando conseguimos explicar algo complejo con solo unas cuantas reglas. En el primer caso tendríamos una regla “*fort composee*”, como Leibniz la llama, inservible, ya que si empezamos a aceptar reglas complejas entonces siempre tendríamos una forma de explicar cualquier cosa. La complejidad solo es aceptable cuando es posible describirla a partir de un conjunto limitado de reglas.

Por tanto es esta economía de decretos creadores, es decir, el “*decreto divino de producir siempre su efecto por las vías más fáciles*”¹¹ la clave fundamental que, según Leibniz, sirve para determinar cuándo un mundo es más perfecto que otro. El mejor de los mundos posibles es, pues, para Leibniz, aquel en el que se consigue máxima variedad, diversidad y riqueza del mundo a partir de un mínimo conjunto de ideas que lo determinan.

Recepción en el siglo XX de la metafísica de la complejidad leibniziana

La filosofía académica del siglo XX transcurrió por senderos deliberadamente alejados de una metafísica especulativa como la leibniziana, transitando tanto por el positivismo lógico como por la hermenéutica y la filosofía del lenguaje.

Sin embargo en los márgenes del pensamiento filosófico académico, de hecho en el interior de algunas especialidades científicas, fue emergiendo un nuevo pensamiento metafísico asociado a una filosofía de la naturaleza que permite volver a pensar en la elaboración de un *système du monde* que dé cuenta de lo mucho que queda por explicar del mundo natural a partir de, entre otros factores, una completa reconstrucción de la epistemología en forma de teoría de la información algorítmica. Esta reconstrucción comenzó con la investigación por parte de Gregory Chaitin (1947) sobre si está en la naturaleza de las matemáticas ser la más fiable fuente de conocimiento posible y su elaboración de una *Teoría de la Información Algorítmica*.

En su trabajo *Epistemology as Information Theory: From Leibniz to Ω* ¹² se refiere al *Discourse de Métaphysique* de Leibniz destacando la idea que hemos comentado antes: que el mejor de los mundos posibles es, para Leibniz, aquel en el que es posible combinar unos pocos elementos esenciales y obtener toda la variedad de fenómenos observados. Chaitin capta a la perfección el concepto leibniziano de “*mejor de los mundos posibles*” aunque en el pensamiento filosófico ha trascendido más bien la caricatura que de este concepto hizo Voltaire como un mundo en el que el mal no existiera.

¹¹ Leibniz (2002) p. 80

¹² Chaitin (2006)

Pues bien, Chaitin aplica esta definición leibniziana a la cuestión de qué constituye una teoría aceptable tras descubrir en el libro escrito por el matemático Herman Weyl (1885-1955) en 1932 titulado “The Open World” el tratamiento de Leibniz sobre la complejidad. En este libro se recogen tres conferencias sobre metafísica que interesaron a Chaitin.

Siguiendo a Leibniz Weyl indicaba en dicha obra que si se aceptan leyes arbitrariamente complejas (*fort composé*) para explicar el mundo entonces degradaríamos el concepto de “ley” porque siempre será posible hacer una ley supuestamente explicativa para cualquier fenómeno. La crítica que Weyl hace a Leibniz es que no haya profundizado en marcar más precisamente cómo medir la diferencia entre la simplicidad y la complejidad matemáticas porque sin esa norma de medida será imposible distinguir una teoría acertada de una errónea. La intuición de Weyl era muy acertada, pues las teorías contemporáneas que tratan de explicar los mecanismos causales mediante la transferencia de información necesitan de este tipo de medidas.

Esta argumentación leibniziana, que descubre leyendo a Weyl, es la que Chaitin usa para proponer su reconstrucción de la epistemología como teoría de la información algorítmica: según lo formula Chaitin una teoría aceptable tiene que ser siempre más concisa que los fenómenos que trata de explicar, es decir, la explicación debe consistir en una *reducción de la complejidad* de los hechos observados, comprimiéndolos, por decirlo así, y esa compresión resultaría ser la explicación.

En la actualidad los estudios sobre la complejidad con esta raíz leibniziana han aplicado la idea de que en la reducción de la complejidad se encuentra la base de fundamentación de cualquier teoría sobre el mecanismo de la causalidad, como veremos en las propuestas filosóficas de Jessica Flack más adelante.

La explicación con base computacional de nuestros mecanismos de adquirir conocimiento ha supuesto una naturalización de la epistemología que ha tenido como consecuencias inesperadas una mayor comprensión del funcionamiento de procesos biológicos en la naturaleza, como veremos más adelante.

Dificultades para conciliar la metafísica de la complejidad con el paradigma crítico predominante

La idea de establecer un fundamento seguro desde el que iniciar una reflexión filosófica acerca de la naturaleza de la realidad ha llevado en distintas épocas a diferentes aproximaciones filosóficas. Si para Aristóteles ese fundamento seguro era la metafísica después de la modernidad se instauró la epistemología como filosofía primera, esto es, la creencia de que antes de filosofar hay que comenzar con un análisis de nosotros mismos. Este es el denominado *paradigma crítico* del que ya hemos hablado, que afirma que el fundamento de todo filosofar se establece aclarando la cuestión de qué condiciones hacen posible el conocimiento y cómo podemos acceder a él.

Levi Bryant, profesor de filosofía del Collin College (Dallas, Texas), hace notar¹³ que a lo largo del siglo XX se han multiplicado los proyectos críticos con la ventaja de que se ha explorado este paradigma hasta la saciedad y el inconveniente de que carecemos de medios para decidir cuál es más verdadero o fundamental, pues todos estos esfuerzos parecen igual de plausibles. La consecuencia es que cada filósofo suele escoger dentro del paradigma crítico aquel enfoque que mejor satisface sus inquietudes psicológicas, políticas o intelectuales pero sin salirse de una misma forma general de enfocar los temas filosóficos.

Para comprobar el aire de familia que tienen los proyectos críticos del siglo XX por pertenecer a una misma forma general de comprender el mundo, Bryant los caracteriza de la siguiente forma:

- Kantianos, cuyo objetivo es analizar la estructura a priori de la mente para entender cómo estructura los fenómenos y condiciona nuestro acceso a ellos
- Fenomenólogos, que analizan la estructura de la intencionalidad vivida a partir de nuestro ser-en-el-mundo y descubrir cómo es la donación de lo dado. No pretenden describir empíricamente las cosas mismas sino trascendentalmente, es decir, esclareciendo las condiciones de su conocimiento y su sentido, porque las cosas están fundadas en la esencia de lo que aparece a la conciencia.
- Foucaultianos, evidencian cómo la realidad es construida a partir del ejercicio del poder y de las construcciones discursivas
- Derrideanos y Lacanianos, buscan los mecanismos por los cuales el lenguaje produce los objetos del mundo
- Marxistas, que opinan que son las fuerzas sociales y la historia las que construyen el mundo vivido por los seres humanos
- Gadamerianos, una propuesta hermenéutica que analiza el deambular de los textos a partir de los cuales construimos nuestro conocimiento y nos constituimos a nosotros mismos
- Por último, Wittgenstenianos, que diluyen los problemas filosóficos desvelando los mecanismos por los cuales el lenguaje ordinario construye muchos pseudo-problemas filosóficos

Casi toda la filosofía que se ha hecho en el siglo XX se ha hecho desde alguna de estas propuestas, es decir, desde el interior del paradigma crítico. Sin embargo, como dice el filósofo italiano Massimo Pigliucci, *“la filosofía se mueve en espacios conceptuales y en ellos los filósofos crean nuevos marcos de pensamiento sobre los problemas”*¹⁴. Por esta razón resultaría propio de la filosofía indagar si es posible pensar sobre el mundo desde fuera del paradigma crítico y si, haciéndolo así, conseguimos avanzar en la comprensión de la causalidad en entornos complejos.

13Bryant (2011), 262

14 “I think philosophy moves in a series of conceptual spaces (as opposed to, say, the empirical space which constraints the advancement of science), where philosophers produce and then analyze a number of “peaks” representing useful frameworks for thinking about a given problem”,
<http://www.philosophersmag.com/index.php/footnotes-to-plato/63-what-do-philosophers-think-part-i>

Propuestas contemporáneas para pensar filosóficamente el mundo fuera del paradigma crítico

Consideramos ahora la posibilidad de volver a pensar la filosofía como una filosofía natural sin necesidad de volver a paradigmas pasados sino elaborando una nueva forma de pensar la naturaleza tomando como centrales los conceptos de *diferencia* y de *información*.

De la metafísica de la diferencia a la información

Cree Levi Bryant que el modo de proceder propio del paradigma crítico, es decir, a partir de una indagación epistemológica por las condiciones de producción y acceso del conocimiento, está tan incorporado en nuestra cultura filosófica que parece imposible proceder de otra forma. Sin embargo eso es precisamente lo que Bryant hace¹⁵ para poder superar lo que él considera el agotamiento del paradigma crítico y su consecuente esterilidad.

Para ello nos propone un experimento: pensar pre-críticamente. Esto no lo propone para regresar a algún paradigma anterior sino, al contrario, para descubrir uno nuevo. La pregunta pre-crítica desde la que Bryant propone partir es: *¿Cuál es la afirmación más general y fundamental que podemos hacer sobre la naturaleza de los seres?* Y Bryant la responde mediante la enunciación de lo que él llama el *Principio Óntico*: *los seres son y llegan a ser debido a sus diferencias*. Veamos cómo lo argumenta.

Antes de proceder a enunciar su *Principio Óntico*, en el que desarrolla esta forma pre-crítica de pensar, Bryant nos advierte de que cuando pensemos en términos de categorías metafísicas (como él va a hacer) deberíamos hacerlo evitando el dogmatismo, esto es, hay que proponer formulaciones tentativas que estén sujetas a posterior revisión, tal como indicó Alfred North Whitehead al afirmar que el proyecto filosófico por excelencia es el que elabora “*categorías metafísicas que no sean declaraciones dogmáticas*.”¹⁶

El modo de proceder de Bryant se separa de la tendencia, desde Hegel, a definir la realidad (lo que es) en términos de su contrario (lo que no es). Bryant indica que esta forma de proceder no nos separaría aún del procedimiento epistemológico crítico, pues estaríamos diciendo que es nuestra observación del mundo la que establece el tipo de diferencias y contrastes ser/no-ser. Un modo de proceder verdaderamente ontológico debería de ser afirmativo con respecto al ser, respecto a la realidad, es decir, debería de proceder mediante afirmar que la diferencia que nos permite identificar objetos reales pertenece a las cosas mismas. Con esta hipótesis (que habrá que justificar ahora) obtenemos un camino de salida del paradigma crítico, pues

- nos empezamos a separar de la mente humana como criterio para establecer las diferencias entre unas cosas y otras, diferencias que nos permiten acceder a la realidad

15 Bryant (2011)

16 Alfred North Whitehead, *Process and reality*, New York, The Free Press, 1978, p.8

- evitamos la idea de que las-cosas-en-sí estén más allá de toda posibilidad de conocimiento, es decir, que ninguna de sus propiedades inherentes se nos presentan ante nuestra intuición, lo cual implicaría que las cosas-en-sí no serían capaces de producir ninguna diferencia que podamos percibir.

La hipótesis de Bryant, afirmativa, ontológica, es los seres son y llegan a ser debido a sus diferencias. En este sentido, para Bryant el Principio Óntico no apela a las cosas que llegamos a *conocer* (γίγνώσκειται) sino que trata sobre *lo que es* (ἔστιν) y *lo que puede llegar a ser* (γίγνεται). Estamos, por tanto, usando el término *diferencia* como un aspecto central en nuestra descripción de la realidad. Bryant va a desarrollar las siguientes ideas respecto al término *diferencia*:

- La *diferencia* tiene *prioridad epistémica*, es decir, no necesitamos apelar a la mente para definir el término *diferencia*. Si necesitáramos que la mente definiera qué es *diferencia* antes de poder usarla estaríamos regresando al paradigma crítico, pues para Kant son las categorías a priori de la mente las que definen el ámbito de aquello en lo que es posible pensar. Sin embargo diciendo que la diferencia tiene prioridad epistémica estamos invirtiendo la forma de pensar del paradigma crítico: la diferencia existe, no la construye nuestra mente, y por tanto podemos usarla sin necesidad de elaborarla conceptualmente de manera previa.
- La *diferencia* tiene *prioridad ontológica*, metafísica, su existencia no depende de que los humanos se relacionen o no con la realidad pues existe sin necesidad de nosotros. De esta forma superamos la forma de pensar de toda la filosofía crítica y la fenomenología, para quienes si hay algo que no percibimos entonces no existe o, al menos, no podemos decir nada sobre ello. Diciendo que la *diferencia* tiene prioridad ontológica estamos diciendo que *ahí fuera* hay una realidad compuesta de diferencias. Para Bryant la diferencia es algo que está por todas partes y es fundamental, no es algo puesto por nuestra mente, esto es, la diferencia tiene prioridad ontológica. Y la forma de pensar pre-crítica trabaja a partir de esta hipótesis.

El uso que Bryant da a la palabra *principio* cuando enuncia su Principio Óntico también contrasta con el uso de la palabra “principio” en la filosofía crítica. Por ejemplo, para Husserl, “*el principio de todos los principios es que una plena claridad es la medida de toda verdad*”¹⁷ a semejanza de Descartes, que apela a las “*ideas claras y distintas*” del cogito. En contraste, como vimos antes, Bryant plantea el Principio Óntico con el estatuto epistemológico de hipótesis, no de certezas fundacionales y, por tanto, sujeto a mayor desarrollo y ampliación.

Según Bryant el *arjé* (ἀρχή) no sería una diferencia esencial u originaria a partir de la cual el resto de las diferencias puedan explicarse al estilo del elemento fundacional del mundo buscado por los antiguos griegos. Para el Principio Óntico el *ser* consiste en un *enjambre de diferencias*, es decir, es una multiplicidad. De este hecho se deducen para Bryant dos principios: (a) el Principio de Inhumanidad y (b) el Principio Ontológico.

17 Ideas I §78

(a) Principio de Inhumanidad

Debido a que el Principio Óntico pertenece a la esfera de lo que es y lo que puede llegar a ser esto implica que las diferencias a las que se refiere Bryant no son exclusivas del dominio humano. Las diferencias que interesan al Principio Óntico no estarían restringidas a lo que se pueda conocer y por tanto no tienen relación con lo que se manifiesta, con los fenómenos, con la experiencia o con cualquier campo relacionado con el conocimiento. El *ser de la diferencia* no depende de la consciencia o del conocimiento pues la diferencia es un asunto de las 'cosas en sí mismas' y no de nuestra relación con ellas.

Una posible objeción a este planteamiento sería si es posible hablar sobre diferencias previamente a disponer del *concepto de diferencia*. Es decir, ¿no es necesario pensar a partir de conceptos? Si esto fuera así significaría que la diferencia no podría ser un principio fundamental porque requeriría antes elaborar una identidad con el concepto para poder trabajar con ella. Este es el argumento principal que todas las filosofías correlacionistas o anti-realistas esgrimen contra las metafísicas de la diferencia. Bryant ve la solución a esta crítica en la estrategia seguida por Ernst Zermelo y Adolf Fraenkel al enunciar los axiomas de Zermelo-Fraenkel con los que consiguieron definir 'conjunto' sin caer en las paradojas que Russell identificó en 1901 en la axiomática de conjuntos de Frege. La idea de estos matemáticos es evitar la definición de cada elemento de un conjunto y limitarse a describir sus condiciones de pertenencia a cada conjunto. De esta forma la teoría de conjuntos puede operar sobre conjuntos sin necesitar de una definición previa que aplique a todos los conjuntos sino que lo hace definiendo las condiciones de pertenencia para cada conjunto.

De igual forma, Bryant propone la estrategia de estipular las diferencias no mediante la definición de un concepto sino mediante identificar lo que es común en todas las diferencias. En esta línea sigue la idea de Alain Badiou, que ha demostrado que es posible trabajar sin un concepto y sin una definición axiomática de términos, pues para operar sobre los conceptos no es necesaria la identidad del concepto.

(b) El Principio Ontológico: una ontología plana

Junto con el Principio de Inhumanidad, este es otro de los principios que se derivan del Principio Óntico. Para enunciarlo Bryant se basa en la declaración de Deleuze en *Diferencia y Repetición*: "*lo esencial de la univocidad no es que el Ser se diga en un único y mismo sentido, sino que se diga en un único sentido y mismo sentido de todas sus diferencias individuantes o modalidades intrínsecas. Es Ser es el mismo para todas esas modalidades pero esas modalidades no son las mismas. Es 'igual' para todas pero ellas mismas no son iguales.*"¹⁸

En este texto Deleuze está perfilando el escenario de surgimiento del ser que Bryant propone, ya que el criterio mínimo para que algo sea considerado *ser* según Deleuze consistiría en marcar una diferencia. Si hay diferencia entonces el ser es. Esto implica que el ser no estaría dividido entre apariencia y realidad, lo que excluiría, según Bryant, pensar la realidad en términos de las formas platónicas, los múltiples de Badiou, lo virtual de Deleuze, la duración bergsoniana, la voluntad de

18 Deleuze (2018) p. 72

poder nietzscheana o la materia de los materialistas, porque la cosa es tan sencilla como que donde tenemos diferencias tenemos seres. No hay un conjunto de diferencias que sean ‘de verdad’ en contraste con otro grupo de diferencias que sean ‘solo aparentes’.

De lo anterior se infiere que la propuesta de Bryant es una ontología *realista*. Pero, además, Manuel Delanda¹⁹ ha indicado que también sería una ontología *plana* “*compuesta exclusivamente de individuos únicos, singulares, que difieren en una escala espacio-temporal pero no en su estatus ontológico*” a diferencia de las ontologías jerárquicas que se basan en relaciones entre tipos generales e instancias particulares repartidas en niveles que representan categorías ontológicas, tales como organismo, especie o género. Sin embargo la propuesta de Bryant no se limita al mundo natural, como parece que sí hace DeLanda en su trabajo. Dado que, según el Principio Óntico, dondequiera que haya una diferencia existe un ser, se deduce de él que las señales, ficciones, ejércitos, corporaciones o naciones son también seres.

Pues bien, una vez puesta la base desde la que vamos a trabajar, una *metafísica de la diferencia* para determinar qué es un *ser*, ¿qué podemos hacer con el concepto de *diferencia* propuesto por Levi Bryant? ¿Para qué sirve? Pues sirve para algo importante: con el concepto de diferencia podemos construir el concepto de información. En efecto así ha sido definido el concepto de *información* por Bateson y MacKay:

- Donald MacKay: “*una distinción que crea una diferencia*”²⁰
- Gregory Bateson: “*una diferencia que marca la diferencia*”²¹

Sin embargo para seguir avanzando también tenemos que revisar críticamente lo que solemos considerar *información*.

John Collier²² (1950), profesor de filosofía de la Universidad de KwaZulu-Natal en Durban (Sudáfrica) indica que normalmente consideramos la información desde una perspectiva *estática*, es decir, como un atributo o propiedad de un estado epistémico, o una propiedad semántica de las proposiciones. Sin embargo, esta visión estática es, para Collier, un caso particular de la concepción *dinámica* de la información, que es más general y que afirma que la información no es algo que *esté* sino algo que *fluye* en un sistema interconectado.

Visto así, la teoría de la información que necesitamos en la filosofía natural que estamos considerando consistiría en el estudio riguroso de las diferencias y de sus relaciones. Dicha teoría debería de tener, para Collier, un aspecto fisicalista y otro

19 Manuel DeLanda, *Intensive Science & Virtual Philosophy*, New York, Continuum, 2002, p. 41.

20 “a distinction that makes a difference”, MacKay, Donald M. (1969) *Information, Mechanism and Meaning*. Cambridge, MA: MIT Press.

21 “a difference that makes a difference”, Bateson, G. (1973) *Steps to an Ecology of Mind*. Paladin. Frogmore: St. Albans. p.428

22 <https://srpc.ukzn.ac.za/staff-profile/philosophy/john-collier/>

dinámico. El primero debería de fundamentar el hecho de que las diferencias de las que se compone la información son hechos físicos y el segundo fundamentaría que dichas diferencias tienen que ver con fuerzas o flujos ya que esta es una característica universal de todo aquello que consideramos real. Estas son las dos premisas de las que parte Collier para estudiar la *causalidad* entendida como *transferencia de información*.²³

Por tanto, disponiendo de la metafísica sobre lo real propuesta por Bryant basada en diferencias y del concepto de información propuesto por Collier construido a partir de ella y conectada con las fuerzas y flujos de lo real estamos en condiciones de elaborar hipótesis sobre cómo los seres actuarían en este mundo, es decir, cómo sería su forma de estar en un mundo en el que *ser* implicaría relacionarse con seres definidos a partir de sus diferencias. Pero, además, con una particularidad. Si modelamos la naturaleza como información entonces se nos abre un campo empírico, un campo típicamente científico para el estudio filosófico de la naturaleza, el campo de los modelos y las simulaciones. Y esta es una novedad en la filosofía, poco habituada a pasar de las hipótesis a los modelos y también una razón por la cual es tan importante la constitución de grupos interdisciplinarios entre científicos y filósofos. Creemos que el estudio de la causalidad en el contexto de una filosofía informacional nos podría permitir cerrar la tradicional brecha entre las concepciones especulativas y empiristas pues el enfoque informacional nos proporciona al mismo tiempo una sólida fundamentación ontológica y epistemológica.

Pues bien, si con el concepto *diferencia* construimos el concepto *información*, la parte de la filosofía que estudia la información como una filosofía de la naturaleza deviene en una especialidad filosófica, y a tal especialidad muchos autores la denominan info-computación. Veremos ahora qué es la info-computación, es decir, qué se puede postular sobre la naturaleza y sobre el ser humano a partir del concepto de información que surge cuando pensamos en el universo como lugar donde se dan las diferencias.

La info-computación como filosofía natural

La info-computación es una forma novedosa de comprender la realidad, un nuevo *systeme du monde* aplicable a toda la realidad, tanto a las producciones culturales humanas como a las regularidades biológicas observadas en los sistemas considerados vivos, esto es, en sistemas celulares adaptativos y autoorganizativos. Por tanto podemos considerar la info-computación como una *filosofía de la naturaleza*, una que requiere la hibridación de la filosofía con algunos conocimientos que hemos recluso tradicionalmente en ciencias naturales especializadas y también con nuevas ideas en el campo de la computación.

El paradigma info-computacional considera que la naturaleza es una red de estructuras informacionales y que todos los procesos de la naturaleza se desarrollan procesando dichas estructuras en el tiempo. Los procesos naturales, pues, consistirían en computación, cálculo, sobre las estructuras informacionales de la propia naturaleza, del entorno, para reducir la complejidad de su información y producir nuevas y creativas formas de tratar con él. Dicho cálculo sucedería tanto

23 Collier2011

en el nivel biológico como en el mental y cultural. Observamos aquí cómo la info-computación hereda las ideas leibnizianas sobre la reducción de complejidad como el mejor mecanismo de comprensión posible y la epistemología de Chaitin postulando que el ámbito sobre el que se produce dicha reducción de complejidad es la naturaleza entendida como información computable.

La info-computación es, por tanto, una nueva conceptualización metafísica que parte del carácter situado de un cuerpo en relación con el mundo (*embodiment*) para, a partir de ahí, crear modelos que permitan la fundamentación de todo sistema natural que sea adaptativo y autoorganizativo.

A pesar de contener la palabra “computación” no estamos hablando de tecnología. Tiene, más bien, relación con los conceptos de *información* y de *cálculo*, pues considera que la información es el elemento último, el más fundamental, con el que podemos describir la realidad y la forma de tratar la información es integrándola en un cálculo, en una computación. Como dice Gordana Dodig-Crnkovic “*la computación no es el lenguaje de la naturaleza; la computación es la forma en la que la naturaleza se comporta*”²⁴.

El info-computacionalismo amplía el concepto habitual de *computación* proponiendo un nuevo paradigma al que podríamos llamar *computación interactiva* que considera que la computación necesariamente implica interacción con el entorno durante el proceso computacional²⁵. Este paradigma también se aleja del concepto de computador (o mente, por analogía) como un mero procesador autónomo de símbolos.

El modelo info-computacional se asienta, pues, sobre estos dos pilares:

1. Los procedimientos computacionales suceden mientras se interactúa con el entorno y dicha interacción sustituye el anterior concepto de *datos de entrada* en la computación tradicional.
2. El concepto de “computador” se amplía puesto que ya no es simplemente un motor de ejecución de cálculos para producir datos de salida sino que “*al tiempo que ejecuta sus operaciones, el software crea nuevo hardware*” y en el que “*el software es definido por el hardware*”, es decir, el computador en este nuevo paradigma se reconstruye permanentemente en una interrelación hardware-software.²⁶

Estos dos factores suponen, como dice Kampis, “*una interrelación de niveles lógicos que va más allá del espacio computacional de una máquina de Turing*”²⁷ y es precisamente por superar el espacio computacional definido por Turing por lo que estos modelos computacionales pueden ser usados para la realización de modelos teóricos sobre el funcionamiento de los seres vivos ya que estos se caracterizan por los mismos dos factores que la info-computación: la interacción con el entorno y la *autopoiesis*, término este con el que Maturana y Valera caracterizaron la

24 Dodig-Crnkovic (2013)

25 Goldin and Wegner (2008)

26 Kampis (1991) p.223

27 Kampis (1991) p.223

organización de los seres vivos, que “*producen su propia organización a través de la producción de sus propios componentes*”.(Maturana and Valera 1994, 69)

Por tanto el aparato conceptual, los modelos y las herramientas creados por la info-computación nos permiten estudiar filosóficamente cualquier sistema adaptativo autoorganizativo, es decir, los sistemas vivos, la inteligencia, las redes neuronales y los sistemas cognitivos. En cierta forma podemos ver la info-computación como una ciencia natural, como afirma Peter Denning en su obra *Computing is a Natural Science*: “*la computación no es, de hecho nunca lo ha sido, una ciencia solo de lo artificial. La computación ha existido mucho antes de que las computadoras fueran inventadas pero hemos vivido tanto tiempo en la creencia de que la computación era una ciencia de lo artificial que puede ser difícil de aceptar que muchos científicos ahora vean proceso de información en la naturaleza de forma abundante.*”²⁸

Decíamos antes que esta filosofía se encuadraría también dentro de un nuevo realismo y a eso se refiere Luciano Floridi en su *A defence of informational structural realism*²⁹ cuando indica que la realidad funciona epistemológicamente provocando o impidiendo ciertas construcciones en el sistema de información que la procesa.³⁰

La arquitectura computacional propuesta para los sistemas info-computacionales implica considerar que la realidad en su complejidad puede considerarse como una estructura jerárquica compuesta de múltiples niveles, cada uno de ellos con sus propios algoritmos de proceso, algunos de los cuales serían el nivel físico-químico, el neurobiológico, el computacional, el representacional, el ambiental-adaptativo y el experiencial-consciente. La hipótesis del info-computacionalismo es que cada acto cognitivo-computacional se realiza recursivamente, mediante funciones que invocan los algoritmos internos de proceso de información de cada uno de los niveles de los que conste el sistema. Esto no nos parece incompatible con la hipótesis de Bryant de una jerarquía plana de objetos porque Bryant está hablando de la realidad desde una perspectiva ontológica y la info-computación desde una perspectiva sistémica, identificando mecanismos de funcionamiento de los procesos naturales como componentes dentro de una organización jerárquica.

28 Denning (2007) p.13

29 Denning (2008)

30 “*Reality in itself is not a source but a resource for knowledge. Structural objects (clusters of data as relational entities) work epistemologically like constraining affordances: they allow or invite certain constructs (they are affordances for the information system that elaborates them) and resist or impede some others (they are constraints for the same system), depending on the interaction with, and the nature of, the information system that processes them.*”

Causalidad en sistemas biológicos como computación de información

Jessica Flack³¹, profesora en el Santa Fe Institute donde estudia sistemas complejos y codirectora del Collective Computation Group³², trata la relación entre computación y causalidad a partir de la explicación del comportamiento coordinado de los sistemas biológicos y lo hace mediante lo que ella llama *computación colectiva*.

Parte de la consideración de los sistemas biológicos como “*jerarquías de información organizadas en espacios funcionales y escalas de tiempo*”³³. Considera los sistemas biológicos como sistemas adaptativos que pueden ser descritos como *sistemas autopoieticos* de Maturana y Valera y se caracterizan por la interacción entre sus componentes independientes. Debido a esta interacción interna los sistemas biológicos son capaces de formar un todo integrado capaz de reaccionar tanto ante cambios en su ambiente como a cambios en las partes que, mediante su interacción, lo componen.

Estos sistemas difieren considerablemente de los sistemas físicos pues mientras que en los sistemas físicos el orden es generado mediante un único proceso, la minimización de la energía, en los sistemas biológicos hay un paso más que se puede describir como proceso de información. Las implicaciones de esta diferencia aún no están completamente resueltas, es decir, son grandes preguntas abiertas por qué los sistemas biológicos tienen este paso adicional y si el proceso de información los convierte en fundamentalmente subjetivos y por tanto imposibles de caracterizar mediante leyes.

Flack observa que los sistemas adaptativos generalmente son *colectivos*, es decir, están compuestos de componentes parcialmente independientes cuyo comportamiento contribuye a la dinámica del sistema general. Lo interesante es que Flack no postula que el sistema funcione por un mecanismo de coordinación interno sino a partir de la heterogeneidad de las partes que lo componen. La teoría de Flack es que cada una de dichas partes efectúa una computación de propiedades y genera variables de *grano grueso*, esto es, simplificaciones del comportamiento complejo del ámbito micro generando así propiedades estables en el ámbito macro. La computación de dichas variables de *grano grueso* son, por tanto, operaciones de reducción de complejidad.³⁴

Para Flack los sistemas superan su posible subjetividad intrínseca mediante computación, calculando sus propios mundos macroscópicos ya sea en tiempo evolutivo o en tiempo de aprendizaje. Esta computación implica consolidar regularidades y resulta en mayor eficiencia en el trabajo realizado. Ejemplos de esta computación colectiva incluyen el comportamiento coherente que surge en el organismo debido a las decisiones individuales de miles de millones de neuronas

31 <http://c4.santafe.edu/people/c4Jessica/>

32 <http://c4.santafe.edu/>

33 Flack (2017b)

34 Flack (2017a)

en nuestro cerebro; también se puede ver en estructuras sociales, como la distribución de poder que surge de las interacciones entre chimpancés que funcionan como intercambio de señales acerca del estatus de cada uno, lo cual tiene profundas implicaciones en cómo manejan los conflictos posteriormente, o también el funcionamiento de bancos de peces que resulta de las decisiones sobre velocidad y dirección de cada pez individual.

Partiendo de esta concepción de los seres biológicos como jerarquías de información con comportamiento colectivo Flack ha elaborado un modelo que explicaría la *causalidad hacia abajo*, es decir, la controvertida idea que afirma que los niveles ‘superiores’ de organización de los sistemas adaptativos pueden influir causalmente en los niveles ‘inferiores’ de dichos sistemas, como, por ejemplo, sucede en los sistemas biológicos complejos con los eventos mentales, que consideramos causa de los eventos físicos. ¿Por qué es controvertida esta idea? Por su carencia de materialidad. En efecto, si consideramos que los niveles superiores de organización que exhiben los organismos son simplemente patrones espaciotemporales emergentes a partir de la actividad de los niveles inferiores, entonces se desprende que ese nivel emergente, virtual, por decirlo así, no puede ser causa de nada sino un efecto.

Este enfoque de Flack que consiste en operacionalizar la causalidad hacia abajo es un modelo que resulta muy útil por mantenerse dentro de coordenadas materialistas ya que lo que Flack trata de hacer es identificar el mecanismo por el cual los sistemas adaptativos identifican las regularidades ya sea a lo largo de procesos evolutivos o durante periodos de aprendizaje y cómo utilizan dichas regularidades percibidas para modificar su comportamiento.

Tradicionalmente se entiende que la causalidad en los sistemas adaptativos hay que atribuirlos a los denominados mecanismos de *feedback*, es decir, aquellos mecanismos en los que el sistema se alimenta a sí mismo de sus propias producciones. Se dice entonces que los *outputs* de un sistema quedan convertidos en *inputs* al mismo sistema que los genera, generándose un mecanismo de causa-efecto. Sin embargo este mecanismo resulta insatisfactorio a la hora de estudiar mecanismos causales pues los procesos de feedback suelen ser instantáneos pero la causalidad quedaría mejor explicada por procesos más estables en el tiempo. Esta es la razón por la que el mecanismo buscado por Flack debería de tener la peculiaridad de cambiar lentamente, de ser estable ante los constantes cambios del comportamiento microscópico del entorno. Por eso Flack propone como mecanismo la detección de regularidades en el entorno.

¿Cuál sería el mecanismo por el que los sistemas biológicos pueden detectar detectan regularidades? Flack indica que sería mediante comprimir series temporales de datos hasta convertir esos datos específicos en una especie de *datos de grano grueso*³⁵. Es decir, que, para Flack, los componentes de muchos sistemas adaptativos “calculan” sus mundos macroscópicos mediante un mecanismo de compresión, reducción de la información tal como vimos que proponía Chaitin a partir de Leibniz, haciendo así que la percepción del entorno pierda detalle y convirtiendo ese “resumen” de información en una variable de grano grueso con la que percibe el entorno.

35 ‘coarse graining’

Para entender el concepto de *datos de grano grueso* Flack propone que pensemos en qué es lo que llamamos *temperatura*³⁶: la temperatura es la velocidad media de las partículas de un sistema. La temperatura es, por tanto, una computación, un cálculo que produce una representación de grano grueso del comportamiento de todas las partículas y que tiene la cualidad de que nos funciona como predictor del estado futuro del sistema mucho mejor que considerar la velocidad concreta de cada partícula. De hecho, indica Flack, se da la circunstancia de que como la entropía de todos los sistemas del universo aumenta con el tiempo, cada vez hay disponible menos información detallada sobre ellos lo cual haría cada vez más difícil predecir el comportamiento de los sistemas si no tuviéramos métodos como el de obtener variables de grano grueso.

Hemos dicho que esta información de grano grueso, agregada, llega a funcionar mejor como predictor en cualquier sistema que la simple reacción al comportamiento microscópico. La razón es que se mantiene estable ante pequeñas perturbaciones y, por tanto, al tener menor tasa de variación contiene una estabilidad que puede ser usada universalmente por todos los componentes del sistema. Esto, a su vez, crea un flujo de información entre el comportamiento microscópico y las propiedades macroscópicas.

En la figura 1 Flack ilustra cómo la computación colectiva C de propiedades macroscópicas S crea dicho flujo de información D que es el que produce una impresión de causalidad hacia abajo en el momento en el que los componentes de dichos sistemas adaptativos ajustan su comportamiento en respuesta a las estimaciones de propiedades las macroscópicas calculadas colectivamente.




Figura 1 - Flack (2017a)

Esto, puede verse fácilmente, es mucho más que un simple mecanismo de feedback y, desde nuestro punto de vista, explica mejor la reacción de los seres biológicos ante su entorno. Flack distingue entre causalidad hacia abajo débil y fuerte, siendo esta última forma la responsable de la aparición de nuevos niveles organizativos en los sistemas biológicos adaptativos, con lo que el modelo de Flack puede ser usado para explicar la *autopoiesis* de Maturana y Valera³⁷ y la interrelación hardware-software de Kampis que hemos visto anteriormente.

36 Flack (2017a)

37 Maturana and Valera (1994)

El proceso de reducir la complejidad de un sistema a información de grano grueso resulta muy útil porque puede usarse, tanto en física como en biología, para la elaboración de una teoría efectiva, es decir, una que nos permita modelar el comportamiento de un sistema sin necesidad de detallar los cambios subyacentes de estado del sistema. La hipótesis de la reducción de complejidad mediante la creación de variables de grano grueso tiene como base el propio mecanismo de funcionamiento del sistema sin introducir información externa a él, lo cual distingue este tipo de abstracción de otros.

Visto que la propuesta de Flack constituye una hipótesis muy interesante sobre el funcionamiento de la causalidad en sistemas biológicos nos preguntamos si podríamos postular algún mecanismo parecido en el escenario *Big Data*, incorporado a las técnicas de minería de datos masivos, para encontrar relaciones causales. Para ello vamos a analizar la cuestión de la causalidad en los escenarios denominados de *inteligencia artificial*.

Causalidad en Redes Neuronales y Big Data

A pesar de que el término *Big Data* sugiera un mero incremento en la cantidad de datos que se recogen y se procesan automáticamente lo cierto es que hay autores que proponen ver el fenómeno como un cambio fundamental en diversos escenarios.

Por ejemplo, Gary Marcus³⁸ (1970), profesor del departamento de psicología de la Universidad de Nueva York, relaciona las técnicas de Deep Learning con la complejidad al indicar que el término “deep” (profundo) no se refiere a la capacidad de captar conceptos complejos como ‘justicia’ o ‘democracia’ sino a una característica técnica de esta arquitectura de redes neuronales: que usan un gran número de capas ocultas donde las arquitecturas anteriores usaban solo una. Por eso traducir al castellano “Deep Learning” como “aprendizaje profundo” puede dar lugar a equívocos porque lo que es profundo no es el aprendizaje sino la red neuronal creada. De hecho, como vamos a ver, según Marcus el aprendizaje es superficial.

Por su parte, Viktor Mayer-Schönberg³⁹, profesor de gobernanza de Internet en la Universidad de Oxford y Kenneth Cukier, periodista especializado en tecnología y sociedad, proponen⁴⁰ que veamos el fenómeno desde un doble punto de vista, por una parte como un cambio cualitativo en la forma de almacenar y procesar los datos y, por otra parte, no perder de vista lo que ellos llaman el lado oscuro del Big Data como consecuencia del cambio cualitativo que perciben.

Veamos estas dos opiniones sobre *Deep Learning* en relación con el tema de la causalidad que nos ocupa.

38 Marcus (2018)

39 <https://www.oii.ox.ac.uk/people/viktor-ms/>

40 Mayer-Schönberger and Cukier (2013)

Crítica #1: no se capta la complejidad conceptual

Respecto al tipo de aprendizaje que se consigue con Deep Learning, Marcus indica que se aprenden “*contingencias específicas para escenarios particulares*” aunque se suelen describir los resultados del Deep Learning en términos de aprendizaje conceptual tales como ‘el sistema sabe cómo mover la raqueta para golpear la pelota de forma que haga un túnel’ para el famoso experimento de la red neuronal *DeepMind* de Google jugando al videojuego de Atari.⁴¹

En realidad los experimentos de aprendizaje por refuerzo⁴² (aquellos en los que el que aprende trata de maximizar la recompensa) han demostrado que el aprendizaje es muy superficial pues se confrontó al sistema *DeepMind* con un nuevo escenario que variaba ligeramente respecto a aquel en el cual fue originalmente entrenado y se ha comprobado que las soluciones que el sistema propone en el nuevo escenario son extremadamente superficiales aunque hubiera podido seguir usando las técnicas aprendidas en el escenario original donde su rendimiento era sobresaliente. Esto lleva a Marcus a pensar que se está cometiendo un sesgo de sobreatribución, también llamado de correspondencia, es decir, se está tomando como un ‘aprendizaje de conceptos’ (pelota, muro) y ‘estrategias’ lo que en realidad es una aproximación superficial dentro de un conjunto reducido de circunstancias en las que ha recibido un gran entrenamiento.

Por otra parte Marcus indica, como también veremos que hace Pearl, que los procesos de Deep Learning no son lo suficientemente transparentes, son modelos de *caja negra* y eso hace que surja preocupación ética sobre su uso en la gestión financiera o el diagnóstico médico, ámbitos en los cuales los humanos necesitamos argumentar las razones de nuestras acciones.

Crítica #2: se enfoca a la búsqueda de correlaciones

Marcus ve que el estado actual de Deep Learning no es capaz de distinguir una correlación de una causalidad: “*Deep Learning aprende correlaciones complejas entre características de entrada y de salida sin una representación sobre su causalidad*”⁴³. De hecho cuando un sistema Deep Learning comprueba que, por ejemplo, en una determinada población hay una gran correlación entre la altura de los individuos y el vocabulario que usan, el sistema no es capaz de relacionar eso con un tercer factor como podría ser el desarrollo socioeconómico de su entorno. Esta precaución metodológica, sin embargo, es imprescindible en la investigación que llamamos científica, pues sin ella se introduce un *factor de confusión* que puede

41 Mnih, V., Kavukcuoglu, K., Silver, D., Rusu, A. A., Veness, J., Bellemare, M. G. et al. (2015). Human-level control through deep reinforcement learning. *Nature*, 518(7540)(7540), 529-533.

42 Ver “A Beginner’s Guide to Deep Reinforcement Learning” en <https://deeplearning4j.org/deepreinforcementlearning> y la conferencia de Jorge del Val Santos en el T3chfest de 2017 “Introduction to (deep) reinforcement learning” en <https://t3chfest.uc3m.es/2017/programa/introduction-deep-reinforcement-learning/?lang=es>

43 Marcus (2018) p.13

hacer que consideremos que hay una correlación entre variables que, en realidad, son independientes.

Si nos limitáramos a analizar el ejemplo anterior según la correlación detectada por un sistema Deep Learning entonces podríamos cometer el error de pensar que el hecho de que los niños se hagan más altos al mismo tiempo que van aprendiendo nuevas palabras se debe a que el crecimiento de los niños incrementa su vocabulario o que, por el contrario, aprender nuevas palabras tiene como consecuencia un incremento en la altura de los niños.

A pesar de esto hay que reconocer que el aprendizaje automático basado en *Deep Learning* ha tenido grandes éxitos, como son principalmente su uso como clasificador, es decir, para determinar a qué conjunto de categorías pertenece determinada palabra, o también su extraordinaria habilidad para el reconocimiento del lenguaje natural escrito, del habla y de imágenes. Muchos de estos logros han sido debidos a una variación de las redes neurales profundas denominada CNN (*Convolutional Neural Network*) que incorporan un mecanismo denominado *backpropagation* ideado por Yann LeCun⁴⁴ que, mediante aplicar ciertas restricciones a las conexiones de la red neuronal permiten a esta captar una propiedad denominada *invarianza traslacional*. Es decir, la red adquiere la capacidad de reconocer objetos a pesar de que su apariencia varíe de alguna manera (posición, rotación, tamaño, iluminación, etc.)⁴⁵

Sin embargo cuando nos preguntamos en qué se basa el éxito predictivo que se adjudica a los análisis de Big Data tenemos que concluir, como indican Mayer y Cukier, que “*las predicciones basadas en correlaciones son el corazón de los datos masivos.*”⁴⁶

Antes de la época *Big Data*, cuando los datos eran escasos, “*los estadísticos a menudo escogían una aproximación, recogían entonces los datos relevantes y procedían al análisis de correlación para descubrir la calidad de ese sustituto.*”⁴⁷ Para elegir la mejor aproximación hacía falta disponer de una hipótesis basada en teorías, es decir, una idea acerca de cómo funciona un proceso más allá de las apariencias. Las teorías se ponían a prueba y mediante diversos métodos de análisis de correlación se comprobaba si las aproximaciones eran correctas. Si no lo eran, se repetía de diferente forma este proceso para determinar si el problema estaba en los datos o en la hipótesis de partida. Este método, al que Mayer y Cukier llaman “*ensayo y error, impulsado por hipótesis*” es el que ha hecho posible nuestro avance del conocimiento de la naturaleza a partir de datos.

Este enfoque, que podemos denominar clásico, sigue formando parte del corazón de la investigación científica, que procede a partir de una hipótesis y sigue una serie de metodologías de análisis de datos para verificar la hipótesis o refutarla.

44 LeCun, Y. (1989). Generalization and network design strategies. Technical Report CRG-TR-89-4

45 Ver “Quantifying Translation-Invariance in Convolutional Neural Networks”, Eric Kauderer-Abrams, <https://arxiv.org/abs/1801.01450>

46 Mayer-Schönberger and Cukier (2013) p.61

47 Mayer-Schönberger and Cukier (2013) p.60

Este método que parte de una hipótesis y acaba en su confirmación o su refutación cambia drásticamente con la aparición del análisis de datos a gran escala ¿Cómo ha cambiado esta situación el Big Data? De manera radical.

La exaltación de la correlación que parece estar contagiando a muchos entusiastas del Big Data les lleva a proponer que, dada la ingente cantidad de datos que tenemos debido al rastro digital procedente de actividades humanas y de la naturaleza, en este momento para poder predecir e intervenir en el mundo ya no necesitamos partir de hipótesis y luego establecer conexiones causales en los datos sino que resulta suficiente con establecer correlaciones. En apoyo de las ventajas de esta forma de razonar citan casos como el proyecto Google Flu Trends⁴⁸: *“Muchas de las limitaciones que nos obligaron a adoptar el enfoque basado en hipótesis ya no existen en la misma medida. Ahora tenemos tantísimos datos a nuestra disposición, y tanta capacidad de procesamiento, que ya no tenemos que escoger laboriosamente una aproximación o un pequeño puñado de ellas y examinarlas una a una. Ahora, un sofisticado análisis computacional puede identificar la aproximación óptima, como hizo para Google Flu Trends después de someter a prueba casi quinientos millones de modelos matemáticos.”*⁴⁹

Esto ha llevado a algunos a postular la idea de que podemos prescindir de teorías en un escenario de datos masivos. En su famoso y polémico artículo de 2008⁵⁰ Chris Anderson, editor de la revista Wired, propone un cambio de paradigma para la investigación científica que, en su opinión, debería de pasar de estar orientada por la teoría a estar orientada por los datos, más concretamente por las correlaciones que se encuentren en los datos.

Mayer y Cukier identifican un cierto prejuicio moral en los practicantes de Big Data hacia la idea de causalidad que justifica que se concentren en analizar correlaciones, principalmente que la creencia en la causalidad parece contradecir la existencia de una voluntad humana libre: *“Desde hace siglos existe un debate filosófico acerca de la existencia misma de la causalidad. Si todas las cosas fueran causadas por otras, la lógica dicta entonces que no seríamos libres de decidir nada. No existiría la voluntad humana, puesto que cualquier decisión que tomáramos, cualquier pensamiento que tuviéramos, serían causados por algo que, a su vez, sería el efecto de otra causa, y así sucesivamente. La trayectoria de cualquier vida se vería determinada por la sucesión de unas causas que conducen a unos efectos”*. De hecho prefieren pensar en la causalidad como una fantasía útil citando a Daniel Kahneman y su idea de que los seres humanos tomamos decisiones en base a heurísticas rápidas sin necesitar análisis en profundidad de las situaciones. Mayer y Cukier indican que son precisamente las causalidades que imaginamos las que fundamentarían el pensamiento rápido heurístico que nos ayuda a decidir. La causalidad imaginada sería así un atajo cognitivo que facilitaría nuestra comprensión del mundo.

Este cuestionamiento de la noción de causalidad queda perfectamente resumido por Mayer y Cukier cuando dicen que *“la causalidad no va a pasar a la historia,*

48 <https://www.google.org/flutrends/about/>

49 Mayer-Schönberger and Cukier (2013) p.60

50 Anderson (2008)

pero está siendo derribada de su pedestal como fuente primaria de sentido. Los datos masivos potencian enormemente los análisis no causales, reemplazando a menudo a las investigaciones causales.”⁵¹

Mike Flowers, que ha sido durante algún tiempo director analítico de la ciudad de Nueva York con una misión de aumentar la eficiencia de los servicios públicos a partir de los datos disponibles sobre su uso resumió muy bien el pragmatismo con el que se actúa en las tecnologías Big data: *“No me interesa la causalidad salvo en la medida en que lleva a la acción. Necesito un punto de datos específico al que pueda acceder y saber su importancia. Si es significativo, actuaremos en consecuencia. Si no lo es, no haremos nada. Mire, tenemos auténticos problemas que resolver. Sinceramente, no puedo andar perdiendo el tiempo pensando en otras cosas, como la causalidad, ahora mismo”⁵²*.

¿Significa esto que ahora podemos prescindir de elaborar teorías y buscar causas, que en este momento podemos comprender el mundo mediante el análisis masivo de datos sencillamente buscando correlaciones? En realidad no. En el análisis de datos masivos siempre se está usando algún modelo conceptual aunque no sean modelos sobre el mundo sino teorías estadísticas, matemáticas y teorías de las ciencias informáticas. Cuando analizamos los datos escogemos instrumentos que se basan en teorías. Y cuando interpretamos los resultados, aplicamos teorías de nuevo. Está claro que la era de los datos masivos no carece de teorías: están por todas partes, con todo lo que ello implica. (Mayer-Schönberger and Cukier 2013, 77–78)

Como contrapartida a la idea de abandonar la causalidad al procesar datos masivos vale la pena destacar el proyecto *Causality Workbench Project*⁵³ que hace disponibles conjuntos de datos a modo de laboratorio virtual, de “banco de trabajo de causalidad” y organiza desafíos para localizar relaciones causales mediante aprendizaje automático.

Los datos masivos comienzan a ser una parte importante de nuestra comprensión y comienzan a proponerse como la forma de enfrentarnos a problemas globales como, por ejemplo, el cambio climático. Por eso es importante analizar si es posible y conveniente tratar de encontrar causalidad en los datos, si encontrarla nos ayudará a obtener una mejor comprensión del mundo o si es mejor adoptar un punto de vista pragmático y que las teorías pasen a un segundo plano en favor de la correlación.

Vamos a considerar algunas propuestas en la primera dirección. Jessica Flack y Judea Pearl piensan que es posible encontrar asociaciones causales en el proceso de análisis de datos masivos y ofrecen dos propuestas desde ángulos diferentes.

Mecanismos causales en redes neuronales: Jessica Flack

Jessica Flack destaca que las redes neuronales que se están creando en la actualidad son construidas a partir de un proceso de ensayo y error y que no

⁵¹ Mayer-Schönberger and Cukier (2013) p.74

⁵² Mayer-Schönberger and Cukier (2013) cap. X

⁵³ <http://www.causality.inf.ethz.ch/>

tenemos aún principios que nos expliquen su funcionamiento una vez construidas. A esto se añade el hecho de que la distinción entre una red neuronal como *método* para hacer predicciones y la red neuronal como una *inteligencia artificial* que hace su propia predicción es cada vez menos nítida, se suele confundir la perspectiva epistemológica con la ontológica enfatizando lo que se cree que son, inteligencias, en lugar de lo que hacen, los procesos que suceden en su interior.

En línea con su investigación sobre sistemas biológicos de la que hemos dado cuenta más arriba, Flack propone una hipótesis sobre el funcionamiento de las redes neuronales basada en el surgimiento en su interior de variables de grano grueso mediante procesos de compresión y simplificación de la información. Es decir, un proceso de reducción de complejidad semejante al postulado en los sistemas biológicos estaría detrás de la capacidad de las redes neuronales de alcanzar la respuesta simple solicitada⁵⁴.

Para ello describe una red neuronal como un sistema jerárquico en varios niveles en el que en cada nivel se consolida mediante un mecanismo de *causalidad efectiva hacia abajo*, aquella que, a diferencia de la *causalidad aparente*, no funciona mediante la coordinación de los componentes para conseguir la acción macroscópica sino que se logra por influencia de las heterogeneidades que se dan en el propio sistema. Este mecanismo de causalidad, indica Flack, hace que el comportamiento macroscópico obtenido sea robusto ante pequeñas perturbaciones como hemos visto anteriormente.

La jerarquía de capas que caracteriza a las redes neuronales profundas es la que haría posible el proceso de granulación gruesa y produciría, como sucede con los sistemas biológicos, un mecanismo de causalidad descendente efectiva, de tal manera que la producción de variables de grano grueso en las capas superiores de la red neuronal influiría en el comportamiento microscópico de las capas inferiores a través del mecanismo de causalidad hacia abajo, lo que provocaría la reducción de la incertidumbre de los datos.

Flack cita un trabajo de Mehta y Schwab⁵⁵ que concluyen que las representaciones de grano grueso del comportamiento microscópico serían calculadas colectivamente por los componentes de la red en dos fases: una fase de acumulación de información y una fase de agregación. Cada capa de la red tomaría como entrada las representaciones gruesas de los datos calculados por la capa inferior y realizaría su propia representación gruesa a partir de esa información.

También cita los trabajos de Schwartz-Ziv y Tishby⁵⁶ y su concepto de *cuello de botella* que describe un proceso de simplificación, de reducción de complejidad consistente en comprimir los datos de entrada con el objetivo de conservar solo las características más generales útiles para la predicción descartando el resto, el

54 Flack (2017a)

55 Mehta P, Schwab D. 2014 An exact mapping between the variational renormalization group and deep learning. (<http://arxiv.org/abs/1410.3831v1>)

56 Shwartz-Ziv R, Tishby N. 2017 Opening the black box of deep neural networks via information. (<http://arxiv.org/abs/1703.00810v3>)

“ruido”. Resuena en esta descripción la lectura que vimos que Gregory Chaitin hace de la metafísica de Leibniz y su propuesta de *comprensión basada en la comprensión*.

Flack, por tanto, parece encontrar un mecanismo general para hallar sentido consistente en la reducción de complejidad y la construcción de variables de grano grueso. Es la suya una investigación que vale la pena seguir con atención.

Pasamos ahora a una forma diferente de considerar la causalidad en el escenario de datos masivos, la de Judea Pearl⁵⁷ (1936), científico de la computación y filósofo. Su propuesta, crítica con el estado actual de la explotación de datos masivos, pretende mejorar dicho estado mediante la incorporación de modelos causales a los algoritmos actualmente usados para procesar datos. Veamos cómo lo argumenta.

Causalidad por modelos causales: Judea Pearl

El final del siglo XX ha visto una explosión de trabajo en el desarrollo de modelos causales⁵⁸, es decir, de métodos formales para representar relaciones causales y facilitar el desarrollo de inferencias a partir de ellos. Dicha representación de las relaciones causales suele hacerse en los modelos causales mediante ecuaciones y dígrafos (grafos dirigidos), siendo Judea Pearl un ejemplo influyente de esta tendencia.⁵⁹ El hecho de que en los grafos que Pearl emplea las aristas no sean simétricas sino que tengan un sentido definido los diferencia de la representación de redes bayesianas, que no pueden recoger causas ni efectos ya que aunque establecen fuertes lazos de correspondencia entre los hechos correlacionados no establecen ninguna dirección causal entre ellos que permitan transitarlos desde las causas a los efectos.

Dice Judea Pearl⁶⁰ que “*las preguntas causales nunca pueden ser contestadas solo con datos sino que requieren de nosotros la formulación de un modelo del proceso que genera los datos o, al menos, de algunos aspectos de ese modelo*”. A pesar de disponer de muchos datos, preguntas tales como ¿hay algún gen que cause el cáncer de garganta? o ¿por qué está disminuyendo la población de mi pescado favorito? aún son inabordables. Son problemas de inferencia causal.

Ante preguntas causales Pearl opina que lo que se necesita es un modelo del proceso que ha generado los datos de que disponemos porque si no cualquier estudio que se haga a partir de esos datos se limitará a resumirlos o transformarlos pero no a interpretarlos. Esto no significa que la minería de los datos, es decir, el proceso intensivo de los datos disponibles como se hace en *Big Data*, sea inútil porque al menos nos permite establecer altas tasas de correlación entre variables, por ejemplo entre ciertos tipos de genes y ciertos tipos de cáncer. Pero necesitamos además un modelo que indique qué otras *rutas causales* podrían conducir al mismo resultado, es decir, siguiendo el ejemplo anterior, qué factores

57 http://bayes.cs.ucla.edu/jp_home.html

58 Beebe, Hitchcock, and Menzies (2009)

59 Woodward (2016)

60 Pearl and Mackenzie (2018) p.367

no genéticos producen los tipos de cáncer para los que hemos encontrado una alta correlación con factores genéticos.

Pearl es crítico con los mecanismos de Redes Neuronales Convolucionales (CNN, *Convolutional Neural Networks*) que vimos más arriba, pues no siguen las reglas de la probabilidad: no tratan con la incertidumbre de forma transparente. En vez de eso, la arquitectura de la red evoluciona libremente durante la fase de entrenamiento y cuando dicha fase termina no sabemos qué cálculos hace la red o por qué funciona. Si la red neuronal convolucional falla no tenemos ni idea de cómo arreglarla. Son sistemas opacos.

El inconveniente de estos sistemas opacos es que, como no tienen capacidad de interactuar con los humanos en términos de un lenguaje de causas y efectos no podemos exponerles un razonamiento y esperar que, como consecuencia de dicho argumento, hagan ajustes finos en su comportamiento. Es la incapacidad de poder hacer esta especie de micro entrenamiento a posteriori el que Pearl critica poniendo un ejemplo doméstico: si el robot que aspira el suelo de nuestra vivienda se pone en marcha a la hora programada y nosotros estamos dormidos en el sofá a esa hora, no tenemos ninguna forma de decir al robot que esa acción ha estado mal. No nos referimos a la acción de aspirar la casa, sino la acción de aspirar la casa estando nosotros durmiendo la siesta. No podemos comunicarnos con el robot para que comprenda la siguiente serie causal: el aspirador hace ruido, el ruido despierta a la gente y eso hace que algunas personas se enfaden. La red neuronal que rige el comportamiento de ese robot no es transparente y por tanto no es posible saber como injertar en ella *series causales* que adapten su conducta a nuevas circunstancias. El entrenamiento al que se somete a las redes neuronales acaba constituyendo su mundo completo, opaco y cerrado.⁶¹ Aunque Pearl considera las redes bayesianas insuficientes para el estudio de la causalidad (por no ser grafos dirigidos) al menos, indica, son transparentes, sabemos cómo funcionan, podemos seguir cada paso y entender cómo y por qué cada nueva evidencia ha cambiado las creencias de la red⁶² a diferencia de lo opacas que, hemos visto, resultan las redes neuronales convolucionales.

La insuficiencia de los actuales sistemas de aprendizaje, comúnmente llamados de “inteligencia artificial” es explicada por Pearl en términos de lo que él denomina la Escalera de la Causalidad (Ladder of Causation) en la que, como se ve en la figura 2, indica tres niveles distintos de aprendizaje de más superficial a más profundo.

61 Pearl2008 p.375

62 Pearl2008 p.133

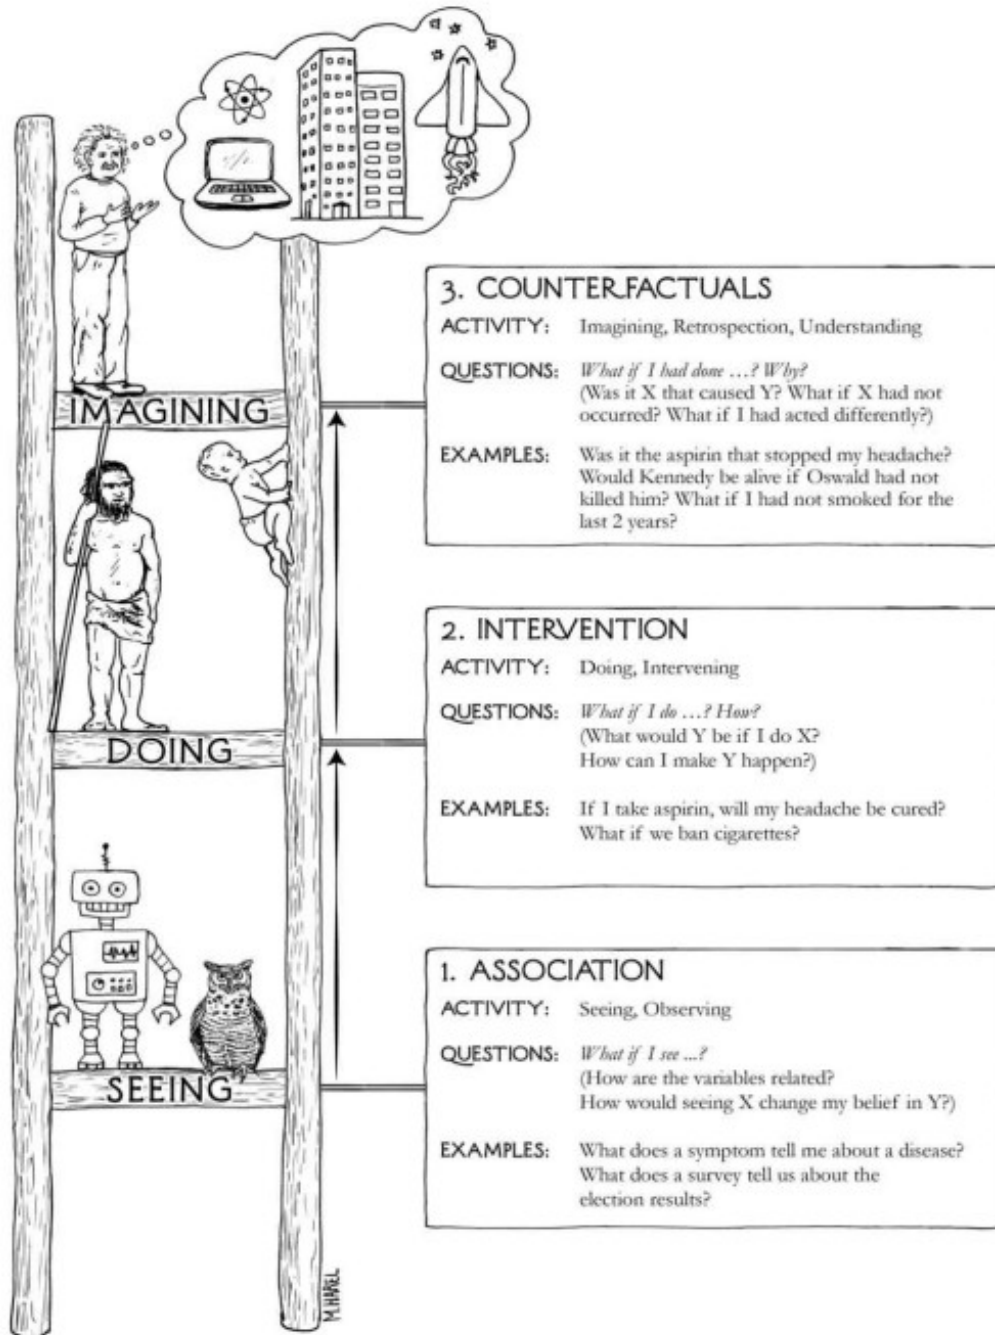


Figura 2 - Pearl (2008)

El nivel más superficial, llamado *asociación*, es aquel que describe la capacidad de aprender a partir de la asociación de variables mediante procedimientos de correlación y regresión. Este es el nivel en el que Pearl ubica los actuales sistemas de aprendizaje, que son capaces de hacer buenas predicciones pero no son capaces de producir explicaciones. De hecho, indica Pearl, “*las buenas predicciones no necesitan buenas explicaciones. El búho puede ser un buen cazador sin necesidad de entender por qué la rata siempre va del punto A al punto B*”⁶³

63 Pearl2008 p.375

En el nivel más elevado de su escala, denominado *contrafácticos*, se encuentra el tipo de razonamiento que trata con preguntas del tipo “¿qué pasaría si...?”, el cual Pearl considera “*el bloque de construcción básico de la conducta moral así como del pensamiento científico*” pues consiste en la capacidad de reflexionar en las propias acciones individuales e imaginar escenarios alternativos. Esta capacidad está, por el momento, reservada a los seres humanos pero, indica Pearl, la algoritmización de contrafácticos será lo que permita alcanzar la inteligencia artificial *fuerte*, es decir, alcanzar un escenario en el que las máquinas tengan una inteligencia similar a la de los humanos. Esta situación no es indeseable, en opinión de Pearl, precisamente porque la causalidad estaría integrada en ella y permitiría que las propias máquinas “*reflexionaran sobre sus errores, determinaran con precisión defectos en su propio software, funcionar como agentes morales y conversar con naturalidad con los seres humanos sobre sus decisiones e intenciones.*”⁶⁴

Esta intención de *algoritmizar la causalidad* es lo que lleva a Pearl a concebir el *motor inferencial*⁶⁵ representado en la figura 3: una “máquina” hecha de software con la que pretende modelar los razonamientos contrafácticos en los que él basa la percepción de causalidad.

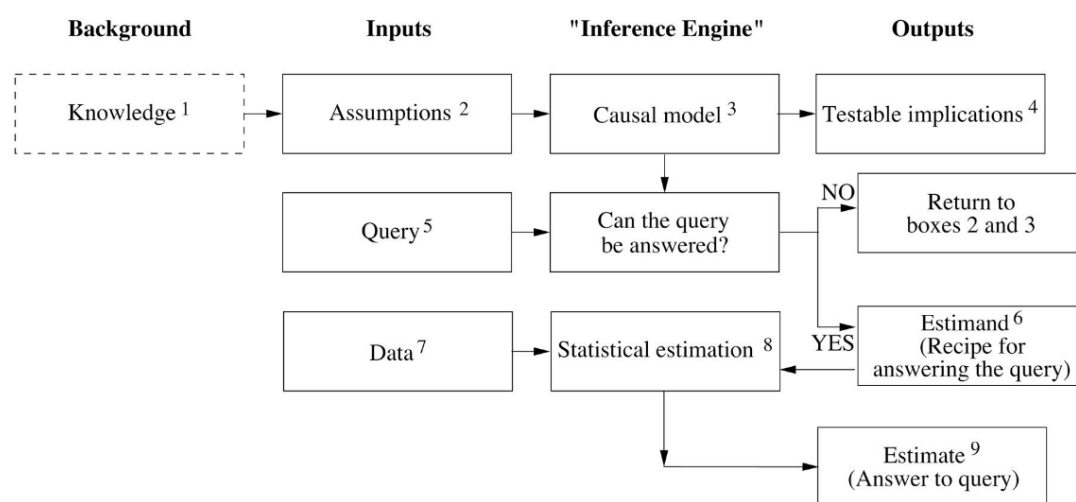


Figura 3 - Pearl (2008)

Esta “máquina” aceptaría tres clases de entrada

1. Suposiciones (*Assumptions*, recuadro 2)
2. Consulta (*Query*, recuadro 5)
3. Datos (*Data*, recuadro 7)

y produciría tres clases de salidas

1. Si/No

⁶⁴ Pearl and Mackenzie (2018) p.18-9

⁶⁵ “Inference Engine”. En terminología de software un “motor” (engine) es un programa capaz de procesar reglas externas a él.

2. Un *Estimand* (recuadro 6), es decir, una fórmula matemática que podemos considerar una receta para generar la respuesta para cualquier dato hipotético que esté disponible en el futuro
3. Una *Estimate*, (recuadro 9), es decir, la respuesta a la “Consulta” (recuadro 5) que hemos hecho en los datos de entrada junto con una estimación estadística (recuadro 8) del rango de incertidumbre de la respuesta debido a la limitación de los datos o los errores que contengan

El *motor inferencial* de Pearl funciona contra un fondo de experiencia (recuadro 1) que está siempre implícita en el agente que hace la investigación causal y que puede afectar a las suposiciones, es decir, a aquellas cuestiones que el investigador considera relevantes para la investigación y que podrían ser incorporadas al modelo causal.

El *modelo causal* que es la pieza central de este *motor inferencial* puede estar redactado en forma de diagramas causales, la opción preferida por Pearl, pero también pueden ser ecuaciones estructurales, afirmaciones lógicas, etc. En este modelo causal la definición de “causalidad” es simple y bastante metafórica: “una variable X es causa de Y si Y ‘escucha a’ X y determina su valor en función de lo que escuche. Por ejemplo, si sospechamos que la esperanza de vida L de un paciente ‘escucha’ al hecho de si el paciente ha tomado la droga D entonces consideramos a D una causa de L y dibujamos una línea desde D hacia L en el diagrama causal. Naturalmente, la respuesta a la ‘Consulta’ sobre D y L seguramente dependerá de otras variables también, las cuales deben de estar representadas en el diagrama junto con sus causas y sus efectos”⁶⁶

Los diagramas causales que componen el *modelo causal* son, por tanto, esquemas funcionales de los patrones de dependencias que se observan en los datos, patrones que deben ser usados para verificar el modelo (*Testable implications*, recuadro 4). Dichos diagramas, como hemos dicho, tienen siempre la forma de *Grafo Acíclico Dirigido* para que sea imposible transitarlo circularmente, es decir que para cada vértice (nodo) del grafo no haya ningún camino que comience y acabe en él⁶⁷.

Pues bien, si, por ejemplo, en el grafo con el que estuviéramos esquematizando el modelo causal no hubiera una flecha que uniera dos puntos concretos (dos variables) eso tendría que tener necesariamente una contrapartida en los datos: deberíamos de poder observar en los datos la total independencia de ambas variables. Si, por el contrario, sí que hubiera una flecha que uniera dos variables concretas en el diagrama causal, por ejemplo, una que fuera desde D hacia L , lo que estaría afirmando implícitamente el modelo es que hay una función o regla sobre el espacio de probabilidades de L que especifica la forma como L cambiará si cambia D , y eso debería de verificarse en los datos.

Las *Consultas* que se introducen en el motor de inferencia serían las preguntas científicas que queremos contestar formuladas en un vocabulario causal, en la nomenclatura de Pearl, $P(L | do(D))$.

⁶⁶ Pearl and Mackenzie (2018) p.21

⁶⁷ Ver “Directed Acyclic Graph” en Wikipedia.
https://en.wikipedia.org/wiki/Directed_acyclic_graph

La propuesta de Pearl es, como hemos visto tanto una propuesta crítica como una constructiva. La parte crítica ejemplificada en su *Escalera de la Causalidad* en la que muestra dónde se sitúa el estado actual de la explotación de datos masivos en comparación con la forma humana de razonar a base de contrafácticos. La propuesta constructiva evidenciada en su *motor inferencial* que pretende que fundamente el diseño de futuros algoritmos que introduzcan el razonamiento causal en los procesos Big Data.

Conclusión

Hemos visto que podemos trazar una cierta línea de continuidad entre el impulso original de la filosofía en la antigua Grecia como filosofía natural y algunas propuestas filosóficas contemporáneas pues en ambos casos se pretende que la filosofía no constituya solamente un estudio del ser humano y sus posibilidades de conocimiento sino de la naturaleza en sí misma, intentando localizar no ya elementos sino procesos básicos que nos ayuden a entender la naturaleza como un todo y poder postular mecanismos de funcionamiento para los seres biológicos.

Para fundamentar esta reedición de la filosofía natural hemos comprobado que se ha utilizado la conceptualización sobre la complejidad expuesta en la *Metafísica* de Leibniz, que ha sido recibida por filósofos que trabajan en el campo de la computación. Estas ideas han servido para establecer una nueva metafísica basada en la diferencia a partir de la cual se puede construir el concepto de información y postular procesos naturales y universales de reducción de la complejidad como fundamento del funcionamiento natural.

La filosofía así concebida volvería a ser especulativa pero tendría también un fundamento epistemológico que permitiría no recaer en los excesos del pensamiento especulativo y proporcionaría métodos empíricos de verificación de los modelos computacionales que, especulativamente, se puedan proponer.

Finalmente hemos puesto a prueba dichos modelos computacionales en dos ámbitos, el funcionamiento de los sistemas biológicos y sus peculiares formas de organización colectiva y también la localización de conexiones causales en escenarios de datos masivos, comprobando que en cada uno de ellos funcionan explicativamente los mismos modelos sobre la información y su reducción de complejidad.

Finalmente quiero hacer notar que el presente trabajo recoge una investigación en curso sobre complejidad y causalidad que pretendo que desde este momento sea colectiva y en la que se abre el foco hacia analizar cómo podrían aplicarse modelos computacionales a otros escenarios, como la elucidación del concepto de “evidencia” en medicina o al estudio del uso que se hace de la causalidad en los modelos de cambio climático,.

La dirección en Internet del proyecto de investigación de la que el presente trabajo es parte está dentro del proyecto *filosofias.es* centrado en Ciencia, Tecnología y Sociedad: <https://filosofias.es/wiki/doku.php/proyectos/tfg/start>

Bibliografía

- Anderson, Chris. 2008. "The End of Theory: The Data Deluge Makes the Scientific Method Obsolete." 2008. <https://www.wired.com/2008/06/pb-theory/>.
- Aristóteles. 1975. *Metafísica*. Madrid: Espasa Calpe.
- Beebe, Helen., Hitchcock Christopher, and Peter. Menzies. 2009. *The Oxford Handbook of Causation*. Oxford University Press Oxford.
- Bryant, L. 2011. "Towards a Speculative Philosophy." In *The Speculative Turn*, edited by Harman G. Bryant L. Srnicek N. Melbourne: re.Press.
- Chaitin, G. 2006. "Epistemology as Information Theory: From Leibniz to ω ." *Collapse* 1:27–51.
- Deleuze, Gilles. 2018. *Diferencia Y Repetición*. Buenos Aires: Amorrortu.
- Denning, P. 2007. "Computing Is a Natural Science." *Communications of the ACM* 50(7):13–18.
- . 2008. "A Defence of Informational Structural Realism." *Synthese* 161(2):219–53.
- De Pierris, Graciela, and Michael Friedman. 2013. "Kant and Hume on Causality." In *The Stanford Encyclopedia of Philosophy*, edited by Edward N. Zalta, Winter 2013. <https://plato.stanford.edu/archives/win2013/entries/kant-hume-causality/>; Metaphysics Research Lab, Stanford University.
- Dodig-Crnkovic, G. 2013. "Alan Turing's Legacy: Info-Computational Philosophy of Nature." In *Computing Nature. Studies in Applied Philosophy, Epistemology and Rational Ethics*, edited by Giovagnoli R. Dodig-Crnkovic G. Berlin: Springer.
- Ellis, George F.R. 2008. "On the Nature of Causation in Complex Systems." *Transactions of the Royal Society of South Africa* 63(1). Taylor Francis:69–84. <https://doi.org/10.1080/00359190809519211>.
- Flack, J. 2017a. "Coarse-Graining as a Downward Causation Mechanism." *Philosophical Transactions of the Royal Society A*.
- . 2017b. "Life's Information Hierarchy." In *From Matter to Life: Information and Causality*, edited by Ellis G. F. R. Walker-S.-I. Davies P. C. W. University Press.
- Goldin, D., and P. Wegner. 2008. "The Interactive Nature of Computing: Refuting the Strong Church–Turing Thesis." *Minds and Machines* 18:17–38.
- Kampis, G. 1991. *Self-Modifying Systems in Biology and Cognitive Science. A New Framework for Dynamics, Information and Complexity*. Oxford: Pergamon Press.
- Leibniz, G.W. 2002. *Discurso de Metafísica*. Madrid: Alianza Editorial.
- Marcus, Gary. 2018. "Deep Learning: A Critical Appraisal." *CoRR* abs/1801.00631. <http://arxiv.org/abs/1801.00631>.

- Maturana, H., and F. Valera. 1994. *De Máquinas Y Seres Vivos: Autopoiesis, La Organización de Lo Vivo*. Buenos Aires: Lumen.
- Mayer-Schönberger, V., and K. Cukier. 2013. *Big Data. La Revolución de Los Datos Masivos*. Madrid: Turner Noema.
- Pearl, J., and D. Mackenzie. 2018. *The Book of Why. The New Science of Cause and Effect*. New York: Hachette.
- Solís, C., and M. Sellés. 2009. *Historia de La Ciencia*. Madrid: Espasa Calpe.
- Woodward, James. 2016. "Causation and Manipulability." In *The Stanford Encyclopedia of Philosophy*, edited by Edward N. Zalta, Winter 2016. <https://plato.stanford.edu/archives/win2016/entries/causation-mani/>; Metaphysics Research Lab, Stanford University.

Tabla de contenido

Resumen.....	3
La causalidad y el surgimiento del paradigma crítico.....	3
Marco conceptual: la jerarquía de la complejidad.....	4
Las indagaciones filosóficas de Leibniz.....	6
Recepción en el siglo XX de la metafísica de la complejidad leibniziana.....	8
Dificultades para conciliar la metafísica de la complejidad con el paradigma crítico predominante.....	9
Propuestas contemporáneas para pensar filosóficamente el mundo fuera del paradigma crítico.....	11
De la metafísica de la diferencia a la información.....	11
La info-computación como filosofía natural.....	15
Causalidad en sistemas biológicos como computación de información.....	18
Causalidad en Redes Neuronales y Big Data.....	21
Crítica #1: no se capta la complejidad conceptual.....	22
Crítica #2: se enfoca a la búsqueda de correlaciones.....	22
Mecanismos causales en redes neuronales: Jessica Flack.....	25
Causalidad por modelos causales: Judea Pearl.....	27
Conclusión.....	32
Bibliografía.....	33
Tabla de contenido.....	35