

## Modelos Gráficos y Redes en Psicología

Ana María Ruiz-Ruano García <sup>(1)</sup>

Universidad de Granada, España

Jorge López Puga <sup>(2)</sup>

UCAM Universidad Católica de Murcia, España

### INFORMACIÓN ART.

Recibido: 25 febrero 2020  
Aceptado: 3 julio 2020

*Palabras clave*  
modelos gráficos,  
redes bayesianas,  
análisis de redes,  
psicología

*Key words*  
graph models,  
Bayesian networks,  
network analysis,  
psychology

### RESUMEN

El análisis de redes no es una metodología nueva para la psicología. Sin embargo, estamos asistiendo a un auge importante del uso de estos métodos en diferentes áreas del estudio científico del comportamiento. En este trabajo nos remontaremos al origen histórico de la teoría de grafos y analizaremos específicamente dos áreas concretas en las que el análisis de redes ha sido fructífero para la psicología: la cognición causal y la comprensión del trastorno psicológico. Realizaremos un recorrido histórico-filosófico por las contribuciones más importantes en lo relativo a la cognición causal y veremos cómo desembocaron en el uso de las redes bayesianas como herramientas normativas que permiten entender este fenómeno psicológico. También presentaremos una breve contextualización del análisis de redes que permite entender el trastorno mental. Finalmente, señalaremos algunos derroteros que podría tomar la simbiosis entre psicología y modelos gráficos, así como los problemas que habría que tratar de evitar.

### Graph Models and Networks in Psychology

#### ABSTRACT

Network analysis is not a new methodology in psychology. However, network analysis-based methodologies are more and more common nowadays. Here we provide a historical review of two areas in which network analysis has been critical for psychology: causal cognition and psychopathology. We briefly review key points in the history of philosophy contributing to progresses in the scientific research about causal cognition. We show how those progresses evolved to considering Bayes networks as normative models to understand causal cognition. We also provide some notes about how network analysis allows to understand mental disorders. Finally, some future paths development regarding the usage of graphs models are suggested as well as some problems to avoid in the close future into this line of research.

### Teoría de grafos y psicología

Es sabido que el impacto aplicado de las matemáticas no es directo, tiende a ser demorado y suele ponerse de manifiesto en los ámbitos más insospechados (Rowlett, 2011). Las matemáticas puras,

dada su naturaleza abstracta y básica, no son consideradas como una herramienta útil para resolver problemas prácticos en el corto plazo. Sin embargo, los principios matemáticos, a medio o largo plazo, siempre son aprovechados en distintos ámbitos de conocimiento para solventar vicisitudes de diversa índole. Para la psicología,

<sup>(1)</sup> Departamento de Psicología Evolutiva y de la Educación Facultad de Educación, Campus de la Cartuja, Granada

<sup>(2)</sup> Facultad de Ciencias de la Salud, Campus de los Jerónimos, Murcia, email: jpuga@ucam.edu

ISSN: 2445-0928 DOI: <https://doi.org/10.5093/rhp2020a18>

© 2020 Sociedad Española de Historia de la Psicología (SEHP)

Para citar este artículo/ To cite this article:

Ruiz-Ruano García, A.M. & López Puga, J. (2020). Modelos Gráficos y Redes en Psicología. *Revista de Historia de la Psicología*, 41(4), 24-33. Doi: [10.5093/rhp2020a18](https://doi.org/10.5093/rhp2020a18)

Vínculo al artículo/Link to this article:

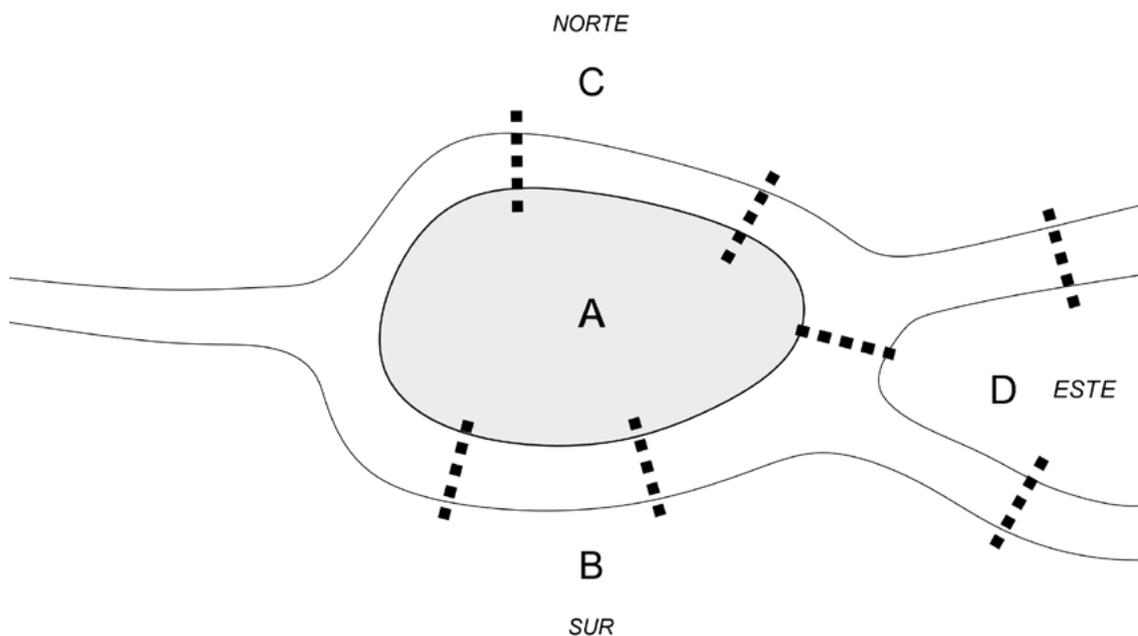
DOI: <https://doi.org/10.5093/rhp2020a18>

las matemáticas también han sido de gran utilidad en la tarea de comprender el comportamiento, la emoción o la cognición tanto a nivel individual como social. En este trabajo queremos resaltar la importancia que ha tenido el matemático de origen suizo Leonhard Euler (1707-1783) para entender la cognición humana y el trastorno psicológico gracias a uno de sus trabajos que dio lugar al análisis contemporáneo de redes o modelos gráficos.

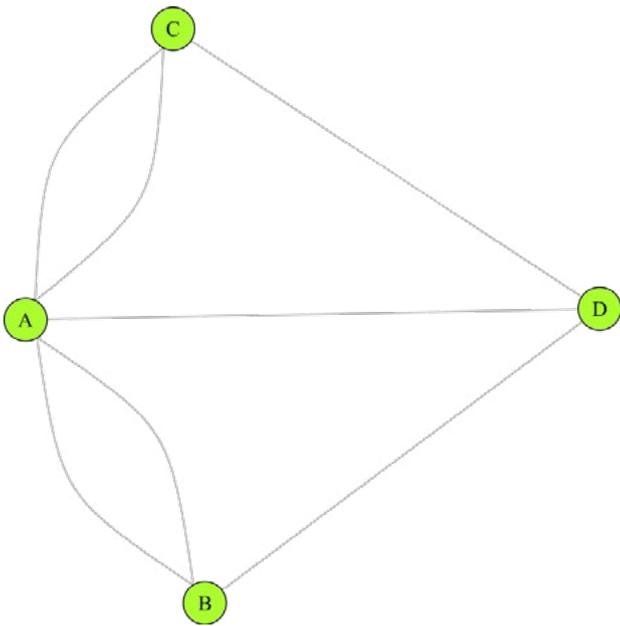
Entre otros, a Euler se le atribuyen contribuciones sobresalientes en el desarrollo del cálculo infinitesimal, la introducción del uso de la letra *e* para referirnos a la base de los logaritmos naturales, haber usado por primera vez la letra griega *p* para referirnos a la relación que se establece entre el diámetro de una circunferencia y su perímetro, o haber planteado la ecuación más “bonita” del mundo (Alonso, 2019; Blasco, 2019; Galeano y Pastor, 2019; Jackson, 2016). Para destacar la contribución que nos incumbe en este trabajo, debemos remontarnos a la primera mitad del siglo XVIII, cuando Euler (1741) publicó su trabajo titulado “*Solutio problematis ad geometriam situs pertinentis*” (*La solución de un problema con relación a la geometría de posición*). Este escrito es considerado como una de sus contribuciones más relevantes a las matemáticas (Gautschi, 2008) y fue elaborado para dar respuesta a un problema o divertimento intelectual de la época. El problema se contextualizó en la ciudad prusiana de Königsberg (hoy denominada Kaliningrado), que es atravesada por el río Pregel (hoy llamado río Pregolya). Llegado a un punto, el río genera una especie de isla y define tres zonas más de la ciudad (Figura 1). En aquel entonces había siete puentes que unían las diferentes áreas de la ciudad que fragmentaba el río. La pregunta que se formulaba era si sería posible dar un paseo por la ciudad empezando en un punto de la misma y volver al punto de partida recorriendo cada uno de los puentes una sola vez.

Euler concluyó que no era posible responder afirmativamente la cuestión que formulaba el problema de los puentes de Königsberg. Llegó a esa conclusión proponiendo y utilizando un método de trabajo que dio lugar a lo que hoy en día se denomina *teoría de grafos* (Gould, 1988; Harary, 1969; Tutte, 1984). La teoría de grafos es entendida hoy en día como una rama de las matemáticas, estrechamente vinculada con las ciencias de la computación, en la que se estudian los problemas utilizando estructuras gráficas construidas a base de nodos y enlaces o aristas que los unen. Estas estructuras gráficas son denominadas *grafos* o *modelos gráficos* o de grafos dado que sirven para modelar los aspectos clave de ciertos problemas. Euler fue capaz de abstraer el problema de tal manera que trazó un grafo en el que las diferentes zonas de la ciudad eran representadas por nodos y los puentes como aristas, enlaces o arcos (Figura 2). De esta manera, el problema pudo ser resuelto utilizando una lógica en la que la métrica empleada se diferenciaba substancialmente de lo que venía siendo habitual. Esta forma de organizar elementos de manera relativamente independiente a la métrica clásica condujo a Johann Benedict Listing a introducir el término *topología* a mediados del siglo XIX para referirse a un análisis de los problemas en el que las distancias, los ángulos, los tamaños o la alineación de objetos pierden relevancia geométrica (Macho, 2019). La topología puede considerarse como una de las ramas más jóvenes de las matemáticas y, aunque estuvo latente durante más de 150 años, en los años 90 del pasado siglo comenzaron a aparecer aplicaciones de la misma en un amplio espectro de áreas de conocimiento (Collins, 2011). Por ejemplo, mejoras en la comprensión de la estructura molecular del ADN, el desarrollo de computadores cuánticos más eficientes o el desarrollo de ciertas técnicas de neuroimagen son fruto de la aplicación exitosa de los principios topológicos.

**Figura 1.** Representación del río Pregel a su paso por la ciudad de Königsberg y los siete puentes (líneas punteadas) que unen las cuatro regiones (A, B, C y D) de la ciudad. Adaptado de Euler (1741).



**Figura 2.** Representación gráfica del problema de las cuatro zonas (nodos A, B, C y D) de la ciudad de Königsberg y los puentes que las unían (las siete aristas que unen los nodos).

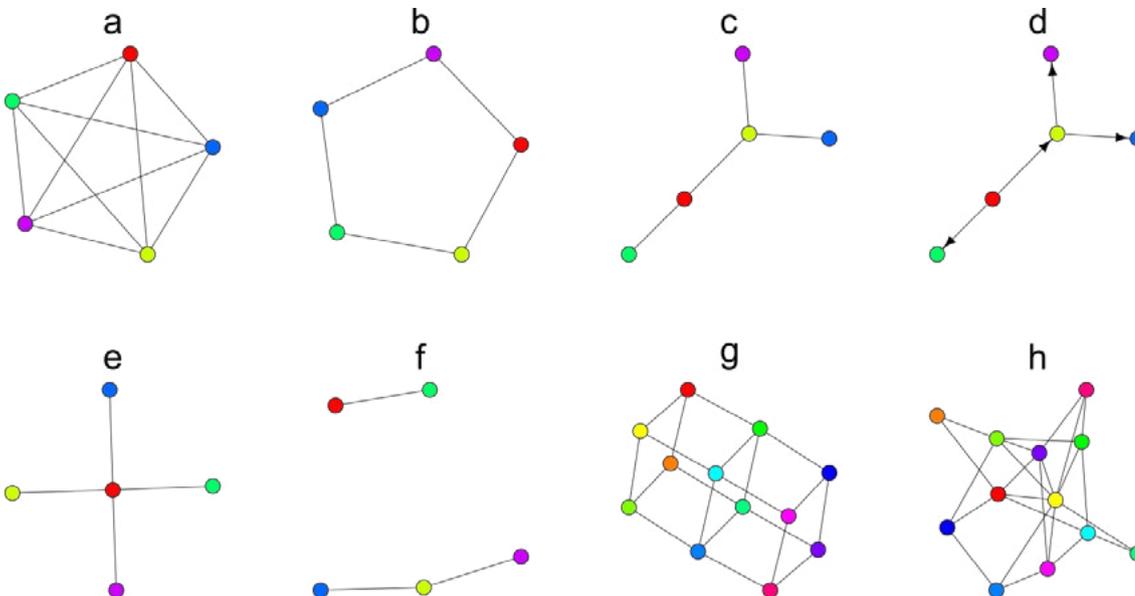


Existe gran diversidad de grafos y pueden utilizarse múltiples criterios para clasificarlos. En la Figura 3 se presentan algunos tipos de gráficos. Por ejemplo, un *grafo completo* es aquel en el que cada uno de los nodos del modelo está conectado con el resto (panel a de la Figura 3). Por su parte, un *grafo regular* es aquel en el que cada nodo tiene el mismo número de enlaces. Normalmente se utiliza la nomenclatura *d-regular* para referirse a este tipo de grafos. Por ejemplo, el grafo representado en el panel b de la Figura 3 es un grafo

2-regular. A este grafo concreto también se le denomina *grafo simple* porque cada par de nodos tiene únicamente un enlace entre ellos. Cuando existen varios enlaces entre un par de nodos nos encontramos ante *multigrafo*. Los *árboles* son grafos que no contienen ciclos (panel c de la Figura 3). Cuando los enlaces entre los nodos tienen dirección (hecho que es representado por flechas) decimos que los grafos son *dirigidos*. En la Figura 3 todos los grafos son no dirigidos excepto el que aparece en el panel d. Los grafos con forma de *estrella* tienen un nodo central en el que confluyen los enlaces con el resto de los nodos del grafo (panel e de la Figura 3). Por su parte, existen grafos *no conexos* en los que existen uno o varios nodos que no están conectados con el resto. Todos los grafos de la Figura 3 son conexos excepto el que aparece en el panel f. Por último, existen grafos que son importantes desde un punto de vista matemático y estadístico porque pueden entenderse como modelos razonables de ciertos fenómenos. Los *grafos de celosía* y de *mundo pequeño* (paneles g y h de la Figura 3) son esenciales para entender la estructura, así como el comportamiento, de redes que se han observado en diferentes ámbitos de la naturaleza (Watts y Strogats, 1998). Para terminar, conviene también destacar la diferencia que se establece entre grafos ponderados y grafos no ponderados. En los *grafos no ponderados* los enlaces entre nodos simplemente apelan a un vínculo entre ellos. Sin embargo, en los *grafos ponderados* cada arista o enlace implica, además, cierto grado o fuerza de asociación entre los nodos. Todos los grafos representados en la Figura 3 son grafos no ponderados pero, como veremos más abajo, los grafos ponderados están teniendo un papel muy importante para la psicología en la actualidad.

La historia de los modelos gráficos en psicología es relativamente corta. Si tuviésemos que señalar un posible pionero en el uso de grafos, aunque de manera muy rudimentaria, podríamos aludir a Kurt Lewin en su intento por definir el campo psicológico que él mismo denominó *espacio vital* y que lo concibió como un área influenciada

**Figura 3.** Algunos tipos de grafos. a: grafo completo, b: anillo o grafo simple, c: árbol, d: grafo dirigido (acíclico), e: grafo estrella, f: grafo no conexo, g: grafo de celosía, y h: grafo de mundo pequeño.



por un nutrido abanico de vectores positivos o negativos (Hothersall, 1995). Como señalábamos más arriba, la eclosión de la teoría de grafos en psicología tiene lugar entre la década de los 80 y 90 del pasado siglo en el ámbito de la psicología social (Wasserman y Faust, 1994). Pese a que el calado de esta perspectiva psicosocial en el ámbito de las ciencias sociales y del comportamiento ha sido modesto, también es cierto que los progresos llevados a cabo en esta área han sido de gran utilidad al área de las ciencias de la computación (véase, por ejemplo, Dimitrova, Petrovski, y Kocarev, 2020; Kolaczyk y Csárdi, 2014). En este trabajo se recorrerán las contribuciones que la teoría de grafos ha generado en dos áreas diferentes de la psicología. En primer lugar, se comentarán los avances que se han producido en el estudio y la comprensión de la cognición causal gracias a un tipo particular de grafos dirigidos acíclicos denominados redes bayesianas. Para ello, se expondrá cómo los derroteros filosóficos y científicos más destacables relacionados con el estudio de la causalidad han desembocado en el uso de modelos gráficos para modelar este aspecto de la cognición. En segundo lugar, se desdibujarán las características más importantes de una propuesta más reciente que sugiere considerar los trastornos psicológicos como grafos no dirigidos. Para terminar, se plantearán algunas ideas generales sobre las rutas futuras que puede tomar el uso de los modelos gráficos en psicología.

### Percepción, razonamiento y aprendizaje causal

El estudio de la causalidad en psicología, junto con temas como el de la personalidad, es uno de los tópicos que más reticencias suscita entre la comunidad científica (Notterman, 2004). Pese a que fenomenológicamente podemos considerar que cualquier ser, humano o no-humano, podría beneficiarse de un mecanismo cognitivo que haya evolucionado para predecir las regularidades que sugieren que unos eventos determinan a otros en nuestro ambiente (Penn y Povinelli, 2011), también es cierto que la idea o concepto de causalidad se nos presenta como algo escurridizo que dificulta su aprehensión y estudio científico o filosófico (Russell, 1912-1913).

Frosini (2006) señala que el establecimiento de relaciones causales de un modo socialmente aceptado pudo haberse fraguado hace más de cuatro o cinco mil años. Por ejemplo, entre los escritos de la Civilización Sumeria (3000 - 2000 a. C.) que surgió en la antigua Mesopotamia se han encontrado vaticinios y predicciones en formato condicional del tipo “si  $x$  ocurre,  $y$  ocurrirá”. Kasak (2000) apunta a la astrología surgida en Mesopotamia como origen común de la ciencia, la pseudo-ciencia y del pensamiento causal contemporáneo. La civilización antigua que vivió a la vera del Tigris y el Eufrates era dada a expresar las predicciones sobre la naturaleza en forma de profecías astrológicas. Durante el curso del tiempo el modo de predicción basado en la astrología trascendió a otro tipo de métodos predictivos debido a los principios religiosos de la Antigua Babilonia basados en los astros, a la universalidad del fenómeno estelar y a la posibilidad que ofrece para predecir configuraciones futuras del cielo. Sin embargo, la antigua astrología durante la época del fatalismo astral no consideraba que el movimiento de los cuerpos celestes fuese la causa de ulteriores fenómenos. Más bien, entendían el movimiento de los planetas como indicios que permitían desenmascarar el devenir.

Utilizando la metáfora propuesta por Kasak (2000), diríamos que la astrología antigua consideraba el comportamiento de los planetas y las constelaciones como las manillas de un reloj, que indica la hora a la que va a suceder un acontecimiento pero que no es la causa de éste. Aunque estas elucubraciones carecían, en la mayor parte de las ocasiones, de validez científica y se basaban en creencias religiosas; son un indicativo de que la humanidad ha estado preocupada desde hace mucho tiempo en esto que llamamos causalidad.

Aristóteles introdujo la idea de que hacer ciencia consiste en identificar las causas de los fenómenos y señaló hacia estas como los elementos distintivos de la verdad. Como indica Hothersall (1995), Aristóteles identificó, al menos, cuatro formas de entender la causalidad que han sido críticas para el ulterior desarrollo científico, así como para el campo de la investigación en cognición causal. En el Libro II-Parte 2 de *Física*, Aristóteles (1995) reconoce la naturaleza polisémica del término “causa”. De manera coloquial, define una causa como esto de lo que algo procede y perdura. En esta obra Aristóteles se centra en la idea de causa primaria, entendida como la respuesta al por qué de las cosas. En *Metafísica*, Aristóteles (1994) retoma el problema de la causa primaria u original y lo contrasta con las ideas de filósofos anteriores a él. En el Libro I-Parte 3 discute, por ejemplo, las cosmovisiones de sus predecesores en torno al origen de todas las cosas. Así, mientras que otros pensadores previos a Aristóteles pensaban que el origen de todas las cosas se debía al agua (como es el caso de Tales de Mileto, que es considerado como el primero que abandona una interpretación mítica del mundo en pos de una interpretación filosófica), al fuego (Anaxímenes y Diógenes), al aire o a la tierra; Aristóteles trata de crear una taxonomía o clasificación de las causas. Por un lado, identifica lo que sería la causa material que, siguiendo con la analogía que él mismo propone, diríamos que la causa material de una estatua cincelada por un artista sobre un bloque de mármol sería el bloque original sin esculpir. Adicionalmente, a la forma o esencia de este bloque original de mármol Aristóteles lo llamó causa formal, mientras que la causa eficiente de la escultura resultante habrían sido los golpes de cincel y martillo que el artista habría propiciado al bloque de mármol para dejar entrever una figura reconocible. Para terminar, Aristóteles propuso que la causa final de la estatua resultante fue la iniciativa y la creatividad del escultor. Para Aristóteles, por tanto, el objetivo de la ciencia era establecer formal e ineludiblemente cuáles son las causas de los fenómenos de la naturaleza. Por ello, en la explicación científica causal no tenía cabida el azar, o la aleatoriedad, aunque en otras esferas de la vida de las personas estos elementos jugasen un papel importante (De los Ríos, 2006). Podríamos entonces considerar a Aristóteles como el personaje de referencia sobre el que se apoya la doctrina determinista que ha florecido, madurado y perdurado en la cultura occidental.

El renacimiento trajo consigo una ola renovada de pensamiento que contribuyó al desarrollo filosófico de la causalidad en Europa. Para Descartes, al igual que para otros pensadores franceses de su tiempo como Blaise Pascal (Villar, 1987), los hechos responden siempre a razones que, ocultas o no a simple vista, sirven para explicarlos. Su concepción sobre el funcionamiento de la naturaleza es profundamente mecánica. Claro ejemplo de ello lo podemos encontrar en la descripción que hace en su *Discurso sobre el método* (Parte IV, páginas 79-81) cuando explica el funcionamiento del corazón y lo

equipara a la maquinaria de un reloj (Descartes, 1649). La propuesta mecanicista y determinista de Descartes ha sido considerada como el antecedente filosófico del enfoque conductual en psicología (Domjan y Burkhard, 1982) y su concepción mecánica del funcionamiento del cuerpo humano ha sido también exportada al ámbito de la psicología.

El siglo XVIII puede considerarse también como un punto arquimédico en la comprensión filosófica de la causalidad que favoreció la evolución de la psicología cognitiva y del aprendizaje. El filósofo asociacionista escocés David Hume es considerado como el antecedente filosófico más influyente en la mayor parte de la investigación llevada a cabo durante las últimas décadas centrada en el campo de la cognición causal. Hume dio continuidad y matizó cualitativamente las ideas de los empiristas británicos asentando las bases para el desarrollo de una psicología cognitiva-experimental preocupada por identificar las leyes que describen la conexión entre los eventos que se dan en la *mente*. La idea básica que popularizó Hume (1739/1987) sugería que establecemos relaciones causales entre eventos porque estamos *acostumbrados* a percibir la causa y el efecto contiguamente en el tiempo y en el espacio. Sin embargo, para Hume, el entendimiento de la relación causal no es nada más que una abstracción de la realidad carente de racionalidad que ha sido el resultado de la experiencia sensible.

En la sección XV de la tercera parte que aparece en el primer libro de su tratado sobre la naturaleza humana, Hume (1739/1987) señaló un conjunto de reglas que tendrían que ser consideradas para identificar relaciones causales entre eventos. En primer lugar, hizo referencia a la idea de contigüidad espacio-temporal, refiriéndose a que la causa y el efecto deben de aparecer seguidos en el tiempo en unas mismas coordenadas espaciales. La segunda de sus reglas afianzaba la idea de causa final introducida previamente por Aristóteles; esto es, la causa siempre debe ser anterior al efecto. Para Hume la unión entre causa y efecto debía de ser constante, representando esta constancia la esencia constituyente de la relación causal. Hoy en día podríamos interpretar esta regla en términos estadísticos refiriéndonos a la covariación estadística entre el evento potencialmente causante y el evento resultado. Como es asumido hoy en día, que dos fenómenos covaríen conjuntamente es un elemento necesario, aunque no suficiente, para determinar que existe relación causal entre eventos. Por ello, las ciencias experimentales se afanan por aislar y/o controlar variables extrañas con el ánimo de observar relaciones causales genuinas entre variables que covarían en contextos experimentales. La cuarta, quinta y sexta regla presentada por Hume para identificar fenómenos causales hacen referencia a la idea de *similaridad*. Así, indica que la misma causa siempre desencadena el mismo efecto y que este efecto no puede derivarse de otra causa. Además, sugiere que cuando un efecto ha sido generado por un conjunto de causas, podríamos suponer que hay algo en las causas que las hace similares y que, por tanto, son capaces de hacer aparecer el efecto conjuntamente. Aludiendo a esta misma idea de similaridad, Hume postula que efectos que muestran cierto parecido tendrían que haber sido motivados por causas similares. Por último, Hume trata el tema de las causas potenciales no observadas aludiendo a eventos que coadyuvan o apoyan la explicación de eventos que no son explicados por causas genuinamente etiquetadas.

El inicio de la investigación sobre los modelos formales de

aprendizaje y razonamiento causal surgió en el contexto del cálculo de probabilidades. Podríamos destacar el uso del parámetro  $\lambda$ , también denominado *contingencia*, como el primer intento de modelar formalmente los procesos de juicio causal. Este parámetro venía a consolidar estadísticamente los postulados asociacionistas introducidos por Hume (1739/1987) hacía más de dos siglos. Concretamente, la propuesta de Jenkins y Ward (1965) consistía en comparar la probabilidad condicionada referida a la aparición conjunta del efecto y la causa frente a la probabilidad condicionada referida a la aparición del efecto en ausencia de la ocurrencia de la causa potencial, lo cual quedaría expresado formalmente del siguiente modo:

$$\Delta P = |P(e^+|c^+) - P(e^+|c^-)|, \quad (1)$$

donde  $e^+$  y  $c^+$  son variables dicotómicas que se refieren al efecto y la causa respectivamente, y donde los símbolos  $+$  y  $-$  se refieren a la presencia y ausencia del evento respectivamente. Desafortunadamente, el método de contingencia estadística no tiene en cuenta la probabilidad basal del efecto en ausencia de la causa potencial y tiende a generar predicciones que no se ajustan al comportamiento humano evidenciado en tareas experimentales.

Con posterioridad, Rescorla y Wagner (1972) introdujeron uno de los modelos asociacionistas que más ha influenciado el estudio del aprendizaje de relaciones causales entre eventos. La propuesta de Rescorla-Wagner (1972) es un ejemplo, aun teniendo un origen probabilístico, de modelo lineal donde se estima la fuerza de asociación entre el efecto y la causa potencial actualizando un gradiente que cambia a medida que se suceden una serie de ensayos. Según este modelo, la variación en la fuerza de asociación ( $\Delta V_i$ ) entre la causa potencial  $c_i$  y el efecto  $e_i$  en el ensayo  $i$  viene dada por

$$\Delta V_i^t = \alpha_i \times \beta_n \times (\lambda - \Delta V_i^{t-1}), \quad (2)$$

donde  $\alpha_i$  y  $\beta_n$  son parámetros que representan factores de aprendizaje vinculados a la causa potencial y al efecto observado respectivamente, es una asíntota teórica referida al máximo grado de asociación posible entre la causa y el efecto, y  $\lambda$  se refiere a la fuerza de asociación entre ambos eventos en el ensayo  $i$ .

Desafortunadamente, las teorías asociacionistas, como el modelo Rescorla-Wagner, no eran capaces de modelar, tanto en animales como en humanos, ciertos fenómenos de reevaluación retrospectiva (Penn y Povinelli, 2007). La reevaluación retrospectiva se refiere a un conjunto de situaciones en las que las fuerzas de asociación entre estímulos condicionados e incondicionados varían como consecuencia de ensayos en los que el estímulo condicionado no está presente en fases críticas de evaluación. Por ejemplo, aunque el modelo Rescorla-Wagner (1972) fue desarrollado para dar cuenta del efecto de bloqueo, donde se produce un bloqueo en el aprendizaje de la asociación entre un estímulo nuevo emparejado a un estímulo condicionado previamente y el estímulo condicionado, es el efecto de bloqueo hacia atrás el que genera más problemas a las teorías asociacionistas clásicas. En el efecto de bloqueo hacia atrás primero se asocian un par de estímulos condicionados (por ejemplo, AX) con un estímulo incondicionado (p. e., una descarga eléctrica). Seguidamente, se presenta un único estímulo de la pareja (por ejemplo, A) seguido de la descarga eléctrica. Por último, se evalúa la respuesta condicionada

que genera el otro estímulo condicionado en la primera fase (X). En este caso, como sucede en el efecto de bloqueo, la respuesta al estímulo X es bloqueada.

Más tarde, Cheng (1997) trató de corregir los problemas que presentaba la ecuación de la contingencia descrita anteriormente y postuló la teoría PC del aprendizaje-razonamiento causal introduciendo un parámetro que controlaba la probabilidad basal de la aparición del efecto cuando la causa potencial no estaba presente y diferenciando entre causas potenciales generativas y preventivas. La teoría hace cuatro suposiciones teóricas para explicar cómo las personas aprenden las relaciones causales entre eventos. En primer lugar, dos causas potenciales provocan un evento independientemente. En segundo lugar, una causa potencial puede provocar un efecto, pero no inhibirlo al mismo tiempo. Tercero, las fuerzas de asociación entre eventos son independientes de la frecuencia de ocurrencia de la causa potencial. Por último, un fenómeno ocurre si y sólo si éste ha sido causado. Bajo estas condiciones, la fuerza de asociación causal para una causa generativa respecto a su efecto vendría dada por la ecuación

$$q_G = \frac{\Delta P}{1 - P(e^+|c^-)}, \quad (3)$$

donde se refiere a la expresión presentada en la ecuación (1); mientras que la potencia causal preventiva para la causa sería estimada con

$$q_P = \frac{-\Delta P}{P(e^+|c^-)}. \quad (4)$$

El inicio del siglo XX trajo consigo una nueva perspectiva de estudio de la cognición causal surgida al amparo de las ciencias de la computación, la filosofía y la psicología en la que se aúnan todos estos conceptos presentados anteriormente tomando los modelos gráficos como punto normativo de referencia (Pearl, 2000; Spirtes, Glymour, y Scheines, 2000). Los trabajos teórico-filosóficos de Glymour (2001, 2003) pueden considerarse pioneros en este sentido. En síntesis, estos trabajos sugieren que la percepción, el aprendizaje y el razonamiento causal pueden ser modelados eficientemente por un tipo de modelo probabilístico en forma de grafo dirigido acíclico denominado red bayesiana (Cowell, Dawid, Lauritzen, y Spiegelhalter, 1999; Puga, Krzywinski, y Altman, 2015). Una red bayesiana está definida por un conjunto de nodos o vértices que representan distribuciones de probabilidad condicional y que están conectados por enlaces o aristas dirigidas. Además, este tipo de grafos tienen la particularidad de que no están permitidos los ciclos. Es decir, si se comienza un camino dirigido a partir de un nodo o variable, no es posible volver al nodo de origen. Cuando dos variables, por ejemplo, A y B, están unidas por un enlace dirigido, A @ B, se asume que A es la causa de B o que B es el efecto de A.

Para Glymour (2001, 2003) las personas codificarían la percepción, el aprendizaje, el razonamiento y el juicio sobre relaciones causales de manera análoga a como lo establece el formalismo de las redes bayesianas. Esta propuesta, por un lado, converge con las observaciones de Premack (1959, 1962) en las que la naturaleza probabilística del aprendizaje se pone de manifiesto y, por otro, coincide con la demostración de que la percepción causal está

basada en el comportamiento físico de la realidad (Michotte, 1946; Yela, 1953). Además, la propuesta de Glymour está en consonancia con los postulados filosóficos de Gustavo Bueno ya que considera el comportamiento basado en esquemas de reforzamiento como una cristalización de procesos eminentemente causales (Fuentes, 1989, 2019). Por otro lado, además de superar algunas de las debilidades del modelo propuesto por Cheng (1997) en lo que respecta al razonamiento causal bajo incertidumbre (Krynski y Tenenbaum, 2007), los modelos gráficos de razonamiento causal permitieron modelar el aprendizaje de relaciones causales diferenciando entre la percepción de patrones de covariación y la intervención sobre el ambiente para modificarlo (véase, por ejemplo, Lagnado y Sloman, 2004; Pearl 2002; Waldman y Hagmayer, 2005).

La suposición de que el funcionamiento de nuestro sistema cognitivo se acomoda a lo que sugiere el formalismo de las redes bayesianas se puso de relieve en estudios de laboratorio con niños pequeños (Gopnik et al., 2004; Gopnik y Schulz, 2004). Estudios como los de Gopnik, Sobel, Schulz, y Glymour (2001) o Sobel, Tenenbaum, y Gopnik (2004) pusieron de manifiesto que el razonamiento de niños de preescolar se acomoda a lo predicho por los modelos gráficos bayesianos. Los autores concluyeron que el comportamiento de los niños cuando eran desafiados por ciertos patrones de covariación entre variables se ajustaba a lo esperado desde el punto de vista que sugieren los modelos gráficos bayesianos. Estos estudios se basan en un paradigma experimental en el que se usan *blickets*. A los niños se les hacía creer que los *blickets*, que son simplemente pequeños bloques de madera, eran la causa de que se activase un mecanismo que generaba luces y sonidos cuando eran colocados sobre un “detector de *blickets*”. Por ejemplo, en uno de los experimentos, los investigadores pedían a los niños que modificasen una situación concreta para producir un efecto específico y los niños conseguían hacerlo pese a no haber observado previamente esa combinación de eventos. Es decir, se solicitaba a los niños que produjesen un fenómeno previamente no observado. Esto no puede ser explicado desde los modelos clásicos de covariación, pero sí desde el punto de vista de los modelos gráficos causales ya que implica manipular el ambiente y razonar sobre la estructura causal subyacente al fenómeno (Pearl, 2000; 2002).

En los estudios de cognición animal también aparecieron evidencias que sugerían que el comportamiento de los animales obedece a lo que postulan los modelos gráficos bayesianos cuando se enfrentan a tareas de aprendizaje y razonamiento causal (Blaisdell, Sawa, Leising, y Waldmann, 2006). En este sentido, algunos autores como Clayton y Dickinson (2006) llegaron a sugerir que los animales podrían ser capaces de llevar a cabo razonamientos más complejos de lo que se suponía hasta el momento.

Tomados en conjunto, todos estos estudios sugieren que los modelos gráficos, especialmente aquellos análogos a las redes bayesianas, suponen un modelo normativo de referencia que ha permitido comprender con más profundidad la cognición causal humana y animal. Aunque todavía estamos lejos de responder a las profundas preguntas que se planteaban los filósofos griegos o nuestros ancestros sumerios, el marco de referencia matemático de los grafos nos ha servido para aproximarnos un poco más al modo en que nuestra mente representa la información causal que nuestros sentidos son capaces de procesar.

### Análisis de redes y trastorno psicológico

La aplicación más reciente de los modelos gráficos en psicología ha tenido que ver con el ámbito de la psicopatología. En este caso, los modelos gráficos han servido para desarrollar una nueva teoría sobre la naturaleza del trastorno mental (Borsboom y Cramer, 2013; Borsboom, 2017; Cramer, Waldrop, van der Maas, y Borsboom, 2010). En este caso, los autores proponen que el trastorno mental puede ser considerado como una red dinámica de síntomas. Estos síntomas se relacionarían unos con otros y esa interacción daría lugar al trastorno mental. Inicialmente se aludía únicamente a que los “trastornos son redes de síntomas y relaciones causales entre ellas” (Cramer et al., 2010, p. 138). Sin embargo, más recientemente se ha precisado que la salud mental puede ser entendida como “el estado estable de una red débilmente conectada” (p. 9), mientras que, contrariamente, el trastorno mental sería el producto de una red de síntomas altamente conectados (Borsboom, 2017).

Numerosos trabajos en los que se han aportado evidencias sobre la utilidad de esta perspectiva han sido publicados hasta el momento. Podemos aludir a algunos de ellos mencionando, por ejemplo, los trastornos depresivos mayores o los trastornos de ansiedad generalizada que han sido objeto exitoso de análisis teórico bajo esta perspectiva (Cramer et al., 2010). El trastorno por estrés posttraumático (Phillips, Wilson, Sun, VA Mid-Atlantic MIRECC Workgroup, y Morey, 2018), el insomnio y la depresión (Blanken, van der Zweerde, van Straten, van Someren, Borsboom, y Lancee, 2019) también son ejemplos de trastornos cuyo comportamiento puede ser modelado por redes psicológicas de síntomas. Para una lista más detallada, exhaustiva, y actualizada de los trastornos que han sido modelados con análisis de redes sugerimos que se consulte el trabajo de Fonseca-Pedrero (2017). En nuestro contexto más cercano podemos destacar varias iniciativas pioneras destinadas a utilizar las redes psicológicas como modelos de los trastornos psicológicos. Por ejemplo, el lector interesado puede consultar los trabajos de Fonseca-Pedrero et al. (2018) y de Fonseca-Pedrero, Ortuño-Sierra, Inchausti, Rodríguez-Testal y Debbané (2020).

Desde un punto de vista matemático-estadístico habría que resaltar que esta perspectiva se centra en proponer una alternativa al *modelo de variable latente común* que subyace en los modelos nosológicos de clasificación diagnóstica de trastornos mentales. El modelo de variable latente asume que el trastorno psicológico es la causa común que provoca los síntomas observados (Adam, 2013). Sistemas de clasificación diagnóstica como el del *Manual Diagnóstico y Estadístico de los Trastornos Mentales* o *DSM 5* se basan en esta lógica (American Psychiatric Association, 2013). Los modelos de red y el análisis estadístico que en ellos subyace suponen un desafío a este tipo de sistemas de clasificación diagnóstica (Blanco, Contreras, Valiente, Espinosa, Nieto, y Vázquez, 2019; Vázquez, Roca, Poyato, y Pascual, 2017). Así, mientras el *DSM 5* asumiría que el trastorno mental es la causa de un conjunto de síntomas independientes, la propuesta de las redes psicológicas (Epskamp, Borsboom y Fried, 2018) asumiría que los síntomas tienen entidad causal por sí mismos y que no existe relación jerárquica entre el trastorno y los síntomas; sino que, más bien, la propia interacción entre los síntomas a lo largo del tiempo sería la que haría que el trastorno se manifestase.

En términos de modelos gráficos podríamos decir que el modelo de variable latente común sería una red dirigida de tipo divergente de la que se desprenden o provocan los síntomas, mientras que para el modelo de redes psicológicas los modelos de red serían no-dirigidos y que evolucionan en el tiempo.

Por otro lado, como ha sido comentado, los modelos de red psicológica son redes no dirigidas. Es decir, que los enlaces que unen a las variables (síntomas) no son flechas, sino que son líneas que no indican dirección causal. En este sentido, las flechas representan estadísticos de correlación parcial o condicional y, por tanto, se trata de redes ponderadas. Como señalan Cohen, Cohen, West y Aiken (2003) la idea de utilizar grafos para representar estructuras de covariación es originaria de Wright (1921). El trabajo de Wright (1921) es pionero al usar el coeficiente de correlación parcial como parámetro vinculado a la arista de un grafo dirigido que representaba la influencia causal de un predictor sobre una variable dependiente. Esta iniciativa puede considerarse el germen del desarrollo de los modelos de ecuaciones estructurales (Batista y Coenders, 2000; Ruiz, Pardo, y San Martín, 2010). Pues bien, esta misma idea de representar correlaciones parciales como parámetros que representan la relación entre variables en modelos gráficos surgida hace aproximadamente un siglo es la piedra angular sobre la que se apoya la propuesta de comprender el trastorno mental con base en la teoría de grafos (Fonseca-Pedrero, 2017, 2018), aunque como hemos señalado, en las redes psicológicas los enlaces son de tipo no dirigido.

Aunque el modelo teórico de redes inicialmente propuesto por Cramer et al. (2010) aludía específicamente a redes de síntomas para comprender el trastorno psicológico, también se dejaba entrever que otro tipo de variables podrían ser consideradas para aproximarnos al trastorno mental. Esta idea tiene sentido en un esquema multinivel en el un amplio espectro de variables (genéticas, neuropsicológicas, neurocognitivas y/o psicométricas, entre otras) pueden ser consideradas para modelar los trastornos psicológicos (Yordanova, Kolev, Kirov, y Rothenberger, 2010). Así, por ejemplo, autores como Blanco et al. (2019) postulan la necesidad considerar modelos de red en los que, además de los síntomas, se incluyan procesos psicológicos posteriores, diferentes aspectos de las relaciones sociales o variables relacionadas con el bienestar. La inclusión de este tipo de variables, según estos autores, podría tener ventajas considerables tanto desde el punto de vista psicopatológico como a nivel clínico.

### Perspectivas de los modelos gráficos y la Psicología

El análisis de redes, entendido como una metodología de análisis de datos aplicada sobre ciertos datos, no es algo realmente novedoso para la psicología. Estas metodologías de análisis han surgido al auspicio de ciertas perspectivas teóricas en las que se han concebido modelos de red de diferente índole (por ejemplo, redes neurales, redes de mundo pequeño o redes autoorganizadas). Como señala Quinlan (1991) la filosofía de red que influenció más profundamente a la psicología estuvo condicionada por el desarrollo de la primera neurona artificial en los años 50 del pasado siglo y coincidió con el apogeo conexionista en psicología. Este primer modelo computacional de neurona desarrollado por el neurobiólogo Warren McCulloch y el estadístico

Walter Pitts sirvió para dar sustrato formal al condicionamiento instrumental descrito por Ivan Pavlov y sus colaboradores (Pavlov, 1927). La década de los noventa del pasado siglo vino a corroborar que los principios básicos del aprendizaje modelados por las redes neurales artificiales se dan a nivel neural siguiendo lo que ha sido denominado como *principio de estabilización selectiva* o *principio de convergencia sincrónica* (Carlson, 1993/2000; Kandel, Schwartz, y Jessell, 1995/1997). Es por ello por lo que la parte más biologicista de la psicología dispone de un modelo abstracto y normativo que permite entender tanto los procesos psicológicos básicos, los procesos complejos, la emoción y el comportamiento humano apoyándose en la filosofía de red.

Los modelos gráficos o de red han sido muy útiles en el pasado más reciente de la psicología, pero todavía existen algunos aspectos que no han sido solventados completamente. No podemos olvidar que los modelos de red son precisamente eso, modelos. En ningún caso un modelo es la realidad, lo que implica que hay que tratarlo en consecuencia (Edwards, 1998). De hecho, todavía existen lagunas o aspectos que han de ser mejorados a diferentes niveles para que los modelos de red sean más útiles a la psicología. Por ejemplo, a nivel del modelado formal de la cognición causal, existen cuestiones conceptuales y teóricas que aún no están resueltas (véase Borsboom, 2002). Por su parte, en lo que respecta al modelado de los procesos psicopatológicos por medio de modelos de red, creemos que existen aspectos relativos a la evolución de los trastornos en el tiempo que todavía no han encontrado el consenso suficiente. Quizá los modelos probabilísticos dinámicos basados en estructuras de Markov puedan arrojar luz sobre ello (Grewal, Krzywinski, y Altman, 2019a, 2019b, 2020). La introducción paulatina de modelos dinámicos tendría una utilidad práctica destacada en el contexto de la monitorización y tratamiento psicológico ambulatorio.

En el contexto educativo los modelos de red también tienen utilidad práctica. Un ámbito en el que este tipo de modelos han sido utilizados con éxito es en los modelos de tutorización inteligente (véase Puga y García, 2008, para una revisión sobre el uso de redes bayesianas en este contexto). Además, otro tipo de aplicaciones podrían desarrollarse en los próximos años. Por ejemplo, los modelos de red social podrían ser utilizados para analizar, predecir y minimizar el acoso o ciberacoso escolar. Por último, sin desligarnos de ello, pero en un contexto más general, las redes también seguirán siendo esenciales para entender el comportamiento de los grupos sociales, especialmente en todo aquello relativo a redes sociales virtuales (véase, por ejemplo, Palla, Barabási y Vicsek, 2007). A este nivel, quizá este tipo de modelos sean útiles para abordar amenazas híbridas que acechan en las sociedades contemporáneas (Ruiz-Ruano y Puga, 2018, 2019). Como se señala en la revisión sistemática llevada a cabo Contreras, Nieto, Valiente, Espinosa y Vázquez (2019) en la que se incluyeron los estudios que utilizaron análisis de redes entre 2010 y 2017; el análisis de redes implica una forma innovadora de identificar rasgos cruciales de los trastornos mentales. Esta nueva y radical potencialidad abre nuevas posibilidades para seguir aproximándonos a la naturaleza y dinámica de los trastornos psicopatológicos.

De todos modos, los modelos de red o gráficos no son la panacea, tienen sus limitaciones. No podemos olvidar, como señala Fonseca-Pedrero (2018), que estas herramientas de trabajo no están

totalmente consolidadas desde el punto de vista psicométrico. Y, lo que es más, como señala este mismo autor, tenemos que evitar caer en una sobrevaloración de la tecnología para no caer en un “metodologismo” exacerbado que nos conduzca a artefactos metodológicos o reduccionismos formales para explicar, por ejemplo, el trastorno mental. Como señalan Contreras et al. (2019), pese a los resultados prometedores que ponen de manifiesto el potencial del análisis de redes, todavía existen limitaciones importantes que han de ser superadas. Como señalan estos autores, la mayor preocupación quizá esté relacionada con la validez clínica de los resultados que arrojan estas técnicas estadísticas. Shah (2020) ha explicado muy claramente los efectos perniciosos que podría tener una confianza ciega en la tecnología sin tener en cuenta aspectos eminentemente humanos frente a la resolución de problemas acuciantes de la humanidad. Smaldino (2019) también ha aludido a ese mismo fenómeno recordándonos que “no hay nada más práctico que una buena teoría”, usando los términos literales que se atribuyen a Kurt Lewin, y que no podemos escondernos tras el método para evitar pensar, razonar y favorecer el desarrollo de la ciencia. De lo contrario, si no construimos la ciencia psicológica con base en teorías sensatas y consistentes podríamos favorecer el desarrollo de una “mala” forma de hacer ciencia anquilosada en métodos de trabajo deficientes que se propagan en el tiempo (Smaldino y McElreath, 2016).

## Referencias

- Adam, D. (2013, 25 de abril). Mental health: on the spectrum. *Nature*, 496, 416-418. <https://doi.org/10.1038/496416a>
- Alonso, D. (2019). *Logaritmos y número e. Una mirada exponencial a la realidad* [Logarithms and number e. An exponential look at reality]. Madrid: EMSE EDAPP y Prisanoticias.
- Borsboom, D. (2002). Revisión del libro *The mind's arrows. Bayes nets and graphical causal models in psychology*. *Acta Psychologica*, 111, 355-357.
- American Psychiatric Association. (2013). *Diagnostic Statistical Manual of Mental Disorders* (5th ed.). Washington, DC: American Psychiatric Association.
- Aristóteles (1994). *Metafísica* [Metaphysics]. Madrid: Gredos.
- Aristóteles (1995). *Física* [Physics]. Madrid: Gredos.
- Blasco, F. (2019). *Más allá de la razón aurea. Las constantes matemáticas* [Beyond the golden ratio. The mathematical constants]. Madrid: EMSE EDAPP y Prisanoticias.
- Blaisdell, A. P., Sawa, K., Leising, K. J., y Waldmann, M. R. (2006). Causal reasoning in rats. *Science*, 311, 1020-1022.
- Batista, J. M., y Coenders, G. (2000). *Modelos de ecuaciones estructurales* [Structural equation models]. Madrid: La Muralla/Hespérides.
- Blanco, I., Contreras, A., Valiente, C., Espinosa, R., Nieto, I., Vázquez, C. (2019). El análisis de redes en psicopatología: conceptos y metodología [Network analysis in psychopathology: concepts and methodology]. *Psicología Conductual*, 27, 87-106.
- Blanken, T. F., van der Zweerde, T., van Straten, A., van Someren, E. J. W., Borsboom, D., y Lancee, J. (2019). Introducing network intervention analysis to investigate sequential, symptom-specific treatment effects: a demonstration in co-occurring insomnia and depression. *Psychotherapy and Psychosomatics*, 88, 52-54. <https://doi.org/10.1159/000495045>
- Borsboom, D. (2017). A network theory of mental disorders. *World Psychiatry*, 16, 5-13. <https://doi.org/10.1002/wps.20375>
- Borsboom, D., y Cramer, A. O. J. (2013). Network analysis: an integrative approach to the structure of psychopathology. *Annual Review of Clinical Psychology*, 9, 1-121. <https://doi.org/10.1146/annurev-clinpsy-050212-185608>

- Carlson, N. R. (2000). *Fisiología de la conducta* [Physiology of behavior] (3ª ed.). Barcelona: Ariel.
- Cheng, P. W. (1997): From covariation to causation: a causal power theory. *Psychological Review*, 104, 367–450. <https://doi.org/10.1037/0033-295X.104.2.367>
- Clayton, N., y Dickinson, A. (2006). Rational rats. *Nature Neuroscience*, 9, 472–474.
- Cohen, J., Cohen, P., West, S. G., y Aiken, L. S. (2003). *Applied multiple regression/correlation analysis for the behavioral sciences* (3ª ed). Mahwah, NJ: Laurence Erlbaum.
- Collins, J. (2011). The unplanned impact of mathematics. From bridges to DNA. *Nature*, 475(169). <https://doi.org/10.1038/475166a>
- Contreras, A., Nieto, I., Valiente, C., Espinosa, R., y Vazquez, C. (2019). The study of psychopathology from the network analysis perspective: a systematic review. *Psychotherapy and Psychosomatics*, 88, 71–83. <https://doi.org/10.1159/000497425>
- Cowell, R. G., Dawid, A. P., Lauritzen, S. L., y Spiegelhalter, D. J. (1999). *Probabilistic networks and expert systems*. Harrisonburg, VA: Springer.
- Cramer, A. O. J., Waldrop, L. J., van der Mass, H. L. J., y Borsboom, D. (2010). Comorbidity: a network perspective. *Behavioral Brain Sciences*, 33, 137–193. <https://doi.org/10.1017/S0140525X09991567>
- De los Ríos, I. (2006). *El concepto de azar en la filosofía de Aristóteles* [The concept of chance in Aristotle's philosophy]. Madrid: Liceus.
- Descartes, R. (1649). *A discourse of a method for the well guiding of reason, and the discovery of truth in the sciences*. Londres: Thomas Newcombe.
- Dimitrova, T., Petrovsky, K., y Kocarev, L. (2020). Graphlets in multiplex networks. *Scientific Reports*, 10, 1928. <https://doi.org/10.1038/s41598-020-57609-3>
- Domjan, M., y Burkhard, B. (1982): *The principles of learning and behavior*. Belmont, CA: Brooks-Cole.
- Edwards, W. (1998). Hailfinder. Tools for and experiences with Bayesian normative modeling. *American Psychologist*, 53, 416–428.
- Euler, L. (1741). *Solutio problematis ad geometriam situs pertinentis* [The solution of a problem relating to the geometry of position]. *Commentarii Academiae Scientiarum Petropolitanae*, 8, 128–140.
- Epskamp, S., Borsboom, D., y Fried, E. I. (2018). Estimating psychological networks and their accuracy: a tutorial paper. *Behavior Research Methods*, 50, 195–212. <https://doi.org/10.3758/s13428-017-0862-1>
- Fonseca-Pedrero, E. (2017). Análisis de redes: ¿una nueva forma de comprender la psicopatología? [Network analysis: a new way of understanding psychopathology?] *Revista de Psiquiatría y Salud Mental*, 10, 206–215. <https://doi.org/10.1016/j.rpsm.2017.06.004>
- Fonseca-Pedrero, E. (2018). Análisis de redes en psicología [Network analysis in psychology]. *Papeles del Psicólogo*, 39(1), 1–12. <https://doi.org/10.23923/pap-psicol2018.2852>
- Fonseca-Pedrero, E., Debbané, M., Ortuño-Sierra, J., Chan, R. C. K., Cicero, D. C., Zhang, L. C., ..., Jablensky, A. (2018). The structure of schizotypal personality traits: a cross-national study. *Psychological Medicine*, 48, 451–462. <https://doi.org/10.1017/S0033291717001829>
- Fonseca-Pedrero, E., Ortuño-Sierra, J., Inchausti, F., Rodríguez-Testal, J. F., y Debbané, M. (2020). Beyond clinical high-risk state for psychosis: the network structure of multidimensional psychosis liability in adolescents. *Frontiers in Psychiatry* 10:967 <https://doi.org/10.3389/fpsy.2019.00967>
- Frosini, B. V. (2006). Causality and causal models: a conceptual perspective. *International Statistical Review*, 74, 305–334.
- Fuentes, J. B. (1989). Nota sobre la causalidad apotética a la escala psicológica, acompañada de algunas observaciones [Note on apotetic causality on the psychological scale, accompanied by some observations]. *El Basilíco: Revista de Materialismo Filosófico*, 1, 57–64.
- Fuentes, J. B. (2019). El aprendizaje como contexto determinante de la psicología científica: metodología biológica versus metodología psicológica [Learning as a determining context of scientific psychology: biological methodology versus psychological methodology]- *Revista de Historia de la Psicología*, 40 (2), 27–41. <https://doi.org/10.5093/rhp2019a7>
- Galeano, J., y Pastor, J. M. (2019). *De los puentes de Königsberg a las redes sociales. Teoría de grafos y redes complejas* [From the Königsberg bridges to social networks. Theory of complex graphs and networks]. Madrid: EMSE EDAPP y Prisanoticias.
- Gautschi, W. (2008). Leonhard Euler: his life, the man, and his works. *SIAM Review*, 50, 3–33.
- Glymour, C. (2001). *The mind's arrows. Bayes nets and graphical causal models in psychology*. Cambridge, MA: MIT Press.
- Glymour, C. (2003). Learning, prediction and causal Bayes nets. *Trends in Cognitive Sciences*, 7, 43–48. [https://doi.org/10.1016/S1364-6613\(02\)00009-8](https://doi.org/10.1016/S1364-6613(02)00009-8)
- Gopnik, A., Glymour, C., Sobel, D. M., Schulz, L. E., Kushnir, T., y Danks, D. (2004). A theory of causal learning in children: causal and bayes nets. *Psychological Review*, 111, 3–32.
- Gopnik, A., Sobel, D. M., Schulz, L., y Glymour, C. (2001). Causal learning mechanisms in very young children: two, three, and four-years-old infer causal relations from patterns of variation and covariation. *Developmental Psychology*, 37, 620–629.
- Gopnik, A., y Schulz, L. (2004). Mechanisms of theory formation in young children. *Trends in Cognitive Sciences*, 8, 371–377.
- Gould, R. (1988). *Graph theory*. Menlo Park, CA: Benjamin/Cummings.
- Grewal, J. K., Krzywinski, M., y Altman, N. (2019a). Markov models – Markov chains. *Nature Methods*, 16, 663–664. <https://doi.org/10.1038/s41592-019-0476-x>
- Grewal, J. K., Krzywinski, M., y Altman, N. (2019b). Markov models – hidden Markov models. *Nature Methods*, 16, 795–796. <https://doi.org/10.1038/s41592-019-0532-6>
- Grewal, J. K., Krzywinski, M., y Altman, N. (2020). Markov models – training and evaluation of hidden Markov models. *Nature Methods*, 17, 121–122. <https://doi.org/10.1038/s41592-019-0702-6>
- Harary, F. (1969). *Graph theory*. Philippines: Westview Press.
- Hothersall, D. (1995). *History of psychology* (3ª ed.). México: McGraw-Hill.
- Hume, D. (1987). *A treatise of human nature*. Oxford: Oxford University Press.
- Jackson, T. (2016). *Matemáticas. Una historia ilustrada de los números* [Mathematics: an illustrated history of numbers]. Madrid: Librero.
- Jenkins, H. M., y Ward, W. C. (1965). Judgement of contingency between responses and outcomes. *Psychological Monographs: General and Applied*, 79, 1–17.
- Kandel, E. R., Schwartz, J. H., y Jessell, T. M. (1997). *Neurociencia y conducta* [Neuroscience and behaviour]. Madrid: Prentice Hall.
- Kasak, E. (2000). Ancient astrology as a common root for science and pseudo-science. *Folklore*, 15, 84–103.
- Kolaczyk, E. D., y Csárdi, G. (2014). *Statistical analysis of network data with R*. New York: Springer. <https://doi.org/10.1007/978-1-4939-0983-4>
- Krynski, T. R., y Tenenbaum, J. B. (2007). The role of causality in judgment under uncertainty. *Journal of Experimental Psychology: General*, 136, 430–450.
- Lagnado, D. A., y Sloman, S. (2004). The advantage of timely intervention. *Journal of Experimental Psychology: Learning, Memory, and Cognition*, 30, 856–876.
- Macho, M. (2019). *Topología. La geometría de la plastilina* [Topology. The geometry of the plasticine]. Madrid: EMSE EDAPP y Prisanoticias.
- Michotte, A. E. (1946). *La perception de la causalité* [Causality perception]. Louvain: L'Institut Supérieur de Philosophie.
- Notterman, J. M. (2004). Persistent conceptual issues in psychology. A selective update. *Theory and Psychology*, 14, 239–260. <https://doi.org/10.1177/0959354304042019>
- Pavlov, I. P. (1927). *Conditioned reflexes*. Londres: Oxford University Press.
- Palla, G., Barabási, A. L., y Vicsek, T. (2007, 5 de abril). Quantifying social group evolution. *Nature*, 466, 664–667. <https://doi.org/10.1038/nature05670>
- Pearl, J. (2000). *Causality. Models, reasoning and inference*. New York: Cambridge University Press.
- Pearl, J. (2002). Causal inference in the health sciences: a conceptual introduction. *Health Services and Outcomes Research Methodology*, 2, 189–220.

- Penn, D. C. y Povinelli, D. J. (2011). Causal cognition in human and nonhuman animals: a comparative, critical review. *Annual Review of Psychology*, 58, 97-118. <https://doi.org/10.1146/annurev.psych.58.110405.085555>
- Phillips, R. D., Wilson, S. M., Sun, D., VA Mid-Atlantic MIRECC Workgroup, y Morey, R. (2018). Posttraumatic stress disorder symptom network analysis in U.S. military veterans: examining the impact of combat exposure. *Frontiers in Psychiatry*, 9:608. <https://doi.org/10.3389/fpsy.2018.00608>
- Premack, D. (1959). Toward empirical behavior laws. I. *Psychological Review*, 66, 219-233.
- Premack, D. (1962). Reversibility of the reinforcement relation. *Science*, 136, 255-257.
- Puga, J. L., Krzywinski, M., y Altman, N. (2015). Bayesian networks. *Nature Methods*, 12, 799-800. <https://doi.org/10.1038/nmeth.3550>
- Puga, J. L., y García, J. (2008). Sistemas de tutorización inteligente basados en redes bayesianas [Intelligent tutoring systems based on Bayesian networks]. *Revista Electrónica de Metodología Aplicada*, 13 (1), 13-25. <https://doi.org/10.17811/rema.13.1.2008.13-25>
- Quinlan, P. (1991). *Connectionism and psychology: a psychological perspective on new connectionist research*. Hertfordshire: Cambridge University Press.
- Rescorla, R. A. y Wagner, A. R. (1972): A theory of Pavlovian conditioning: variations in the effectiveness of reinforcement and nonreinforcement. En A. H. Black y W. F. Prokasy (Eds.), *Classical conditioning II: Current research and theory* (pp. 64-99). New York: Appleton-Century-Crofts.
- Ríos, S. (1995). *Modelización* [Modelling]. Madrid: Alianza Universidad.
- Rowlett, P. (2011). The unplanned impact of mathematics. *Nature*, 475, 166-167. <https://doi.org/10.1038/475166a>
- Ruiz, M. A., Pardo, A., y San Martín, R. (2010). Modelos de ecuaciones estructurales [Structural equation models]. *Papeles del Psicólogo*, 31(1), 34-45.
- Ruiz-Ruano, A. M., y Puga, J. L. (2018). Seguridad informática e inteligencia artificial en la era de la información masiva [Information security and artificial intelligence in the massive information era]. En C. A. Giner, J. J. Delgado (dir.), E. J. García, y C. A. Payá (Coords.), *Conflictos y diplomacia, desarrollo y paz, colaboración y medio ambiente* [Conflicts and diplomacy, development and peace, collaboration and the environment] (pp. 711-724). Pamplona: Aranzadi.
- Ruiz-Ruano, A. M., y Puga, J. L., y Delgado-Morán, J. J. (2019). El componente social de la amenaza híbrida y su detección con modelos bayesianos [The social component of the hybrid threat and its detection with bayesian models]. *URVIO. Revista Iatinoamericana de Estudios de Seguridad*, 25, 57-69. <https://doi.org/10.17141/urvio.25.2019.3997>
- Russell, B. (1912). On the notion of cause. *Proceedings of the Aristotelian Society*, 13, 1-26.
- Shah, H. (2020). Global problems need social science. *Nature*, 577, 295. <https://doi.org/10.1038/d41586-020-00064-x>
- Smaldino, P. (2019, 7 de noviembre). Better methods can't make up for mediocre theory. *Nature*, 575, 9. <https://doi.org/10.1038/d41586-019-03350-5>
- Smaldino, P. E., y McElreath, R. (2016). The natural selection of bad science. *Royal Society Open Science*, 3:160384 <https://doi.org/10.1098/rsos.160384>
- Sobel, D. M., Tenenbaum, J. B., y Gopnik, A. (2004). Children's causal inferences from indirect evidence: backwards blocking and bayesian reasoning in preschoolers. *Cognitive Science*, 28, 303-333.
- Spirtes, P., Glymour, C., y Scheines, R. (2000). *Causation, prediction and search* (2ª ed.). Cambridge, MA: MIT Press.
- Tutte, W. T. (1984). *Graph theory*. Cambridge: Cambridge University Press.
- Vázquez, C., Roca, P., Poyato, N., y Pascual, T. (2017). Teoría de redes en psicopatología: una alternativa radical a los sistemas diagnósticos [Network theory in psychopathology: a radical alternative to diagnostic systems]. En R. Fernández-Ballesteros (Ed.), *Progresos y crisis en Psicología clínica: Tratamientos basados en la evidencia y crisis del diagnóstico* [Progress and Crisis in Clinical Psychology: Evidence-Based Treatments and Diagnostic Crises] (pp. 59-83). Madrid: Pirámide.
- Villar, A. (1987). *Pascal: ciencia y creencia* [Pascal: Science and Belief]. Madrid: Cincel.
- Waldman, M. R., y Hagmayer, Y. (2005). Seeing versus doing: two modes of accessing causal knowledge. *Journal of Experimental Psychology: Learning, Memory, and Cognition*, 31, 216-227.
- Wasserman, S., y Faust, K. (1994). *Social network analysis: methods and applications*. New York: Cambridge University Press.
- Watts, D. J., y Strogatz, S. H. (1998). Collective dynamics of 'small-world' networks. *Nature*, 393, 440-442.
- Wright, S. (1921). Correlation and causation. *Journal of Agricultural Research*, 20, 557-485.
- Yela, M. (1953). La percepción de la causalidad a distancia [The perception of causality from the distance]. *Revista de Psicología General y Aplicada*, 26, 227-257.
- Yordanova, J., Kolev, V., Kirov, R., y Rothenberger, A. (2010). Comorbidity in the context of neural networks properties. *Behavioral and Brain Sciences*, 33, 176-177. <https://doi.org/10.1017/S0140525X1000083X>