

# ¿Los datos masivos serán el futuro de la psiquiatría?

Javier Fabrissin

*Médico especialista en psiquiatría. Sistema Provincial de Salud, Gobierno de Tucumán.  
Cátedra de Salud Mental II. Carrera de Medicina. Universidad de San Pablo, Tucumán.  
E-mail: jfabrissin@gmail.com*

---

## Resumen

Los datos masivos (DM) son grandes volúmenes de datos variables, complejos y de alta velocidad que requieren técnicas y tecnologías avanzadas para permitir la captura, almacenamiento, distribución, manejo y análisis de la información. Su uso en medicina constituye un campo en expansión que ofrece respuestas probabilísticas o correlaciones estadísticas entre las variables que componen algún fenómeno, para aportar en la toma de decisiones a nivel epidemiológico, clínico, diagnóstico y terapéutico. La psiquiatría podría verse beneficiada con la aplicación de la analítica de los DM en la detección precoz de los trastornos mentales, en el aislamiento de criterios de predicción terapéutica, en la clasificación de la patología mental, etc. En la presente revisión se presentarán sucesivamente los conceptos que definen a los DM, sus fundamentos teóricos, sus posibles aplicaciones en psiquiatría y se discutirá sobre el cambio epistemológico que los DM proponen. Los DM ofrecen una opción promisoriosa que aborda las preguntas y los problemas de la psiquiatría, desde una perspectiva alternativa, basada en la estadística y los algoritmos computacionales.

**Palabras clave:** Datos masivos - Minería de datos - Aprendizaje de máquinas - Epistemología de la psiquiatría.

IS BIG DATA THE FUTURE OF PSYCHIATRY?

## Abstract

Big Data is a term that describes large volumes of high velocity, complex, and variable data that require advanced techniques and technologies to enable the capture, storage, distribution, management, and analysis of information. Big data analytics are a growing field in healthcare, offering probabilistic answers or statistical correlations to specific phenomena which, in turn, could be used to assist in decision-making at an epidemiological, clinical, diagnostic, or therapeutic level. Psychiatry itself also can take advantage of big data by applying its analytics into early detection of mental disorders, in the definition of therapeutic response criteria, for the classification of mental disorders. The aim of this review is to present the theoretical background that define big data, its potential use in psychiatry, and to discuss about the conflicting suggestion of big data as a new epistemology. In conclusion, big data offers an alternative approach to scientific knowledge by answering psychiatric issues and problems from a different perspective, based on statistical and computational algorithms.

**Keywords:** Big data - Data mining - Machine learning - Epistemology of psychiatry.

## Introducción: Psiquiatría por ingenieros

En el año 2014, el Instituto de Ingenieros Eléctricos y Electrónicos organizó su Competencia Anual de Aprendizaje Automático sobre el “Procesamiento de señales en relación con el diagnóstico de Esquizofrenia” (1). El desafío planteado a los grupos competidores fue diseñar un algoritmo computacional que permitiera diferenciar a pacientes con esquizofrenia de controles sanos mediante el análisis de sus resonancias magnéticas. Se repartieron 72 resonancias de cerebro entre los 245 equipos, indicándoles cuáles pertenecían a pacientes con diagnóstico de esquizofrenia y cuáles no. En total, los grupos aislaron unas 2000 características diferenciales con las que cada uno diseñó su propio algoritmo. Luego, se les entregaron otras 72 resonancias aunque sin especificar si eran de pacientes o de controles, para poner a prueba cuál de los algoritmos resultaba más eficiente. Se premió a un equipo cuyo algoritmo pudo diferenciar las neuroimágenes de los pacientes versus las de los controles con un margen de error del 10%. Remarquemos que de la competencia sólo participaban ingenieros electrónicos que no contaban con ninguna información adicional, no había psiquiatras ni datos de la clínica psiquiátrica.

A este panorama nos asomamos cuando entramos en el terreno de los DM. ¿Se trata de un recurso asimilable o antagónico con la clínica? ¿Se trata de una etiqueta de mercadeo o supone un profundo cambio epistemológico? ¿Se trata de algo que viene a revolucionar la psiquiatría?

### Los datos masivos

Un *dato* es la descripción de algo que permite ser registrado, analizado y reorganizado; datificar un fenómeno es, por lo tanto, cuantificarlo, convertirlo en un índice matemático (2). Dado que hoy en día cualquier cosa admite ser expresada en datos -incluso un estado de ánimo-, las fuentes clásicas de información (bases biomédicas, registros de ensayos clínicos, evaluaciones clínicas) se entremezclan con otras, como los registros provenientes del uso de las redes sociales, de lo que producimos con el uso del celular, de una tarjeta de crédito, de un GPS, del *logueo* para transacciones informáticas, del escaneo de pasajes, de imágenes de un circuito cerrado de TV, etc. (3, 4).

Los datos masivos (DM) son “grandes volúmenes de datos, variables, complejos y de alta velocidad que requieren técnicas y tecnologías avanzadas para permitir la captura, almacenamiento, distribución, manejo y análisis de la información” (5). Se los suele glosar en base a “las siete Vs” (6, 7, 8), correspondientes a *volumen* (tamaño de almacenamiento), *velocidad* (adquisición en tiempo real de los datos y disponibilidad inmediata para hacer uso de ellos), *variedad* (orígenes múltiples, diferentes clases), *variabilidad* (el significado cambia de acuerdo al contexto), *veracidad* (importancia de que los datos sean precisos), *visualización* (modo en que los resultados

son presentados) y *valor* (costo de las herramientas para hacer uso de los DM, el ahorro que deriva de su implementación y el valor de (inter)cambio de los DM).

### El surgimiento de los datos masivos

Su aparición en la Salud Pública fue por el año 2009 cuando se propuso un sistema de monitoreo de casos nuevos de enfermedad tipo influenza (9). Se trataba del *Google Flu Trends* (GFT), un software que delineaba un mapa de la población potencialmente infectada basándose en las coincidencias entre la frecuencia de la búsqueda en *Google* de ciertos términos (ej: resfrío, fiebre) y las zonas geográficas en las que se hicieron. El sistema señalaba por dónde se había propagado la gripe, superando los métodos oficiales por cuanto su actualización podía hacerse en tiempo real. A pesar de su auspiciosa irrupción, se comprobó que el programa detectaba síndromes del tipo de la influenza más que casos de gripe confirmados (10). Esto permite señalar dos cualidades de la analítica de los DM. La primera de ellas es su practicidad: piénsese en la “simplicidad” de analizar búsquedas de términos claves en *Google* desde un escritorio en lugar de tener que recopilar los registros sanitarios; la segunda es que la propensión a la falla es aceptada de antemano y, por consiguiente, sujeta a perfeccionamiento. Los DM prestan continuamente la otra mejilla porque aun con sus errores, aun con valores predictivos bajos, aun si devuelven un porcentaje de falsos positivos o falsos negativos poco aceptables, la capacidad inherente de aprendizaje, de re-programación de los algoritmos, de recalibración de las herramientas de análisis, conduce a un mejoramiento del sistema. De hecho, al adosarle al GFT original un análisis de redes, se mejoró en más de un 30% la eficacia del método original, logrando anticipar las zonas por las que se propagaría el virus de la influenza (11). Esta vocación de perfeccionamiento de los algoritmos está representada por el concepto de inteligencia artificial y, más específicamente, por el de aprendizaje automático o de máquinas (*machine learning*).

### La analítica de los datos masivos

El “aprendizaje de máquinas” (*machine learning*) o aprendizaje automático es una de las técnicas que se emplean para gestionar los datos de un modo que permita ir más allá de su mera recopilación. Se trata de un área de la inteligencia artificial que focaliza en el diseño de programas capaces de *aprender* por sí solos. Un programa *aprende* si su desempeño en alguna tarea mejora autónomamente con la experiencia, sin la intervención humana. El procedimiento implica la recolección de los datos y la realización de un análisis automático con algoritmos que pueden explorar dichos datos para reconocer patrones y predecir resultados. Los datos iniciales para el aprendizaje provienen de una distribución de probabilidad conocida, por lo que el algoritmo de aprendizaje debe proveer un modelo que le permita producir pro-

nósticos con información nueva (12).

El aprendizaje de máquinas puede ser (13):

- **Supervisado:** los sistemas computacionales se programan para etiquetar (clasificar) elementos nuevos, no presentados previamente, utilizando una entre varias categorías (clases) aprendidas anteriormente. En el concurso de los ingenieros electrónicos, a partir de imágenes etiquetadas (pacientes con esquizofrenia / controles) se confeccionaron algoritmos capaces de clasificar la segunda tanda de imágenes (no etiquetadas) según las categorías aprendidas;
- **No supervisado:** el modelo se va ajustando a las observaciones sin un entrenamiento previo, por lo que a los elementos de entrada (datos no etiquetados) se los aborda como un conjunto de variables aleatorias y, mediante la medición de sus similitudes, se descubren patrones o relaciones entre ellos. Un programa de aprendizaje no supervisado no sería capaz de decir si una imagen dada es de un paciente con esquizofrenia o de un control sano, pero sí podría discriminarlas y agruparlas en clases con rasgos semejantes.

Otra técnica de análisis es la “minería de datos”. Se trata de un programa que *excava* en montañas de datos y busca detectar patrones significativos, relaciones estadísticas, algún cruce de características previamente desconocidos o sólo intuitivos (14), los cuales se podrían traducir en *conocimiento* o en información para alimentar los programas de aprendizaje de máquinas. Mientras que el aprendizaje de máquinas está orientado más bien hacia obtener resultados, la minería de datos propone un análisis exploratorio, observacional, donde el programa vagabundea a través de los datos e intenta identificar algo que pueda resultar importante, sin instrucciones respecto de dónde mirar o qué buscar. Esto último sería suficiente para detectar relaciones relevantes, y deja en un segundo plano o para un segundo momento cualquier antecedente teórico previo desde el cual posicionarse para interpretarlos (15).

## Aplicaciones en medicina

Algunas especialidades médicas vienen haciendo un notable uso de los métodos de análisis mencionados. Uno de los trabajos con resultados más sólidos surgió del entrenamiento de un algoritmo de aprendizaje automático *alimentado* con 129.450 imágenes correspondientes a 2.032 enfermedades cutáneas, evaluando su capacidad para distinguir entre carcinoma versus queratosis seborreica benigna y melanoma maligno versus nevus benigno. El modelo alcanzó el mismo nivel de precisión que dermatólogos expertos que oficiaron de grupo de comparación (16). La elección de estos diagnósticos no es un detalle menor: se trata de los motivos de derivación más frecuentes al especialista en piel (17).

La oftalmología es otra especialidad que cuenta con desarrollos en la aplicación de los DM. Existe cierto apoyo al uso del análisis automatizado de imágenes retinales

como método de *screening* para la retinopatía diabética, discriminando de una forma rápida, segura y costo-efectiva si amerita una consulta adicional con el especialista (18). Incluso hay estudios que ensayan la realización de mediciones de agudeza visual y de toma de fotos de fondo de ojo con el celular del propio paciente, con un nivel de precisión comparable al del oftalmólogo (nivel de concordancia  $\kappa=0,91$ ) (19).

Lo que estos trabajos sugieren es que, si se obtienen valores aceptables de sensibilidad y especificidad con niveles de concordancia iguales a los del especialista, un recurso tan simple como sacarse una foto de una lesión cutánea y procesarla mediante un algoritmo de esta naturaleza la convertiría en una metodología más costo-efectiva que la consulta directa, clásica con el especialista (18).

Asimismo, desde la perspectiva de la “minería de datos”, se propone el uso de programas que rastreen los registros médicos electrónicos para pesquisar, entre la suma de datos estructurados y no estructurados, patrones que puedan tener alguna relevancia (20), tales como el descubrimiento de modelos individuales y colectivos de predicción (de riesgo, evolutivos, de respuesta), basados en la clínica, los antecedentes, la información personal, etc., de un conjunto de pacientes pertenecientes a un área de cobertura de salud en procura de capturar patrones que asistan en el diagnóstico precoz, la prevención, etc. Algo semejante se propone para la farmacovigilancia (21), ya que por medio del sondeo de la información consignada en los sistemas oficiales de farmacovigilancia, en los registros médicos electrónicos, pero también en archivos no estructurados (consultas realizadas en buscadores, foros, preguntas formuladas en redes sociales, como por ejemplo: “*Estoy tomando este remedio, me está pasando esto, ¿a alguien le pasó lo mismo?*”), podría advertirse sobre reacciones adversas, el uso de un fármaco para patologías diferentes de las que fuera aprobado, el uso en poblaciones especiales, etc. (22).

## Aplicaciones en psiquiatría

La analítica de DM en psiquiatría aparece en estudios que incluyen muestras poblacionales colosales, seguimientos prolongados, variables múltiples. Ejemplo: mortalidad asociada al uso de benzodiazepinas según la base de datos de una empresa de seguro médico que incluyó 1.686.410 pacientes expuestos al fármaco *versus* 1.930.159 controles (23); 73731 pacientes con demencia captados entre 1970 y 2013 *versus* 733.653 controles (24). Mientras que éstos no dejan de ser estudios epidemiológicos a gran escala, la perspectiva de los DM se aprecia en otras aplicaciones algo más controversiales (25).

### a) Detección de la patología mental mediante las redes sociales

Se basa en el rastreo de las redes sociales, asumiendo que los *posteos* contienen información relativa al estado

mental del usuario y que permitirían, incluso, anticiparse al diagnóstico clínico.

- *Depresión y Twitter*. Tomando 279.951 *tuits* correspondientes a 105 usuarios con depresión y 99 controles se observó que los usuarios deprimidos tenían un mayor uso de *palabras negativas* (“no”, “nunca”, “prisión”, “muerte”) y un menor uso de palabras positivas (“alegría”, “playa”, “foto”). Con esto se construyó un modelo predictivo cuyo desempeño fue de 1 solo falso positivo cada 10 pacientes *diagnosticados* con depresión (26).

- *Depresión e Instagram*. A partir de 43.950 fotos publicadas por 166 usuarios de *Instagram* a las que se procesó con un algoritmo que analizaba el color y el contenido de las imágenes se pudieron identificar marcadores de depresión con una confiabilidad mayor al parámetro de referencia que se usó como comparador (el valor predictivo positivo del análisis fue del 70% mientras que el valor de referencia fue del 42%) (27). Las fotos de los usuarios deprimidos tenían un tono de color aumentado junto con una baja saturación del color y bajo brillo, un mayor número de comentarios recibidos pero menor número de *likes*, una mayor probabilidad de publicar imágenes de rostros que paisajes o mascotas, pero con un menor número de caras por foto, una predominancia del filtro *Inkwell*, entre otras. El estudio detectó que 71 de los usuarios estaban clínicamente deprimidos y en un tercio de los casos el modelo computacional “diagnóstico” la depresión antes de que el propio paciente contara con el diagnóstico clínico.

#### **b) Diagnóstico asistido por métodos electrónicos**

- *Diagnóstico de Esquizofrenia*. Se evaluó si el análisis automatizado del habla podía predecir el desarrollo de psicosis en jóvenes con alto riesgo (28). La muestra consistió en 34 participantes con síntomas atenuados de psicosis, de 14 a 27 años, seguidos durante 36 meses. Los autores aplican un análisis computacional de grabaciones del habla, de donde surgen algunos marcadores específicos, tales como la longitud máxima de las frases, el uso de determinantes (*that, what, whatever, which*), la coherencia entre dos frases consecutivas, el máximo número de palabras por frases. Los investigadores alegan que el método pudo predecir con un 100% de precisión el desarrollo de psicosis, superando en exactitud al diagnóstico por métodos estructurados clínicos.

#### **c) Aprendizaje automático para la predicción diagnóstica**

- *Anticipación del consumo problemático de sustancias*. Whelan y cols. emplean el aprendizaje automático para dilucidar si es posible predecir el riesgo de consumo problemático de alcohol (29). Para ello emplearon 2.500 neuroimágenes (RM estructural y funcional) realizadas a 692 adolescentes de 14 años obtenidas mientras se les presentaban tareas cognitivas de control inhibitorio, procesamiento de la recompensa y de respuesta emocio-

nal. El rastreo y la articulación de datos realizados por el algoritmo predijeron con un 70 a 75% de precisión cuál de esos adolescentes tendrían consumo excesivo de alcohol a los 16 años.

#### **d) Aprendizaje automático para predicciones terapéuticas**

- *Predicción del tratamiento de la esquizofrenia*. Con el empleo del aprendizaje automático en un modelo de regresión de validación cruzada, usando la correlación entre las conexiones funcionales corticales entre la corteza temporal superior y otras regiones corticales obtenidas en estado de reposo con RMf, se pudo prever el porcentaje de disminución en el puntaje total de la PANSS, logrando un nivel de predicción de respuesta positiva al tratamiento del 88% (30). Se trataba de un grupo de pacientes con un primer episodio psicótico, libres de medicación, que fueron tratados con risperidona por 10 semanas. El modelo también identificó aquellas conexiones que permitían distinguir pacientes con esquizofrenia de controles sanos, combinando una secuencia típica de la psiquiatría del futuro: diagnóstico y predicción terapéutica en base a biomarcadores.

#### **e) Aprendizaje automático para la clasificación diagnóstica**

- *Clasificación de la Esquizofrenia*. El concepto de análisis guiado por los datos se usó para clasificar subtipos psicóticos (31). Se incluyeron 709 participantes con rasgos psicóticos y 342 controles, tomando en consideración ciertos biomarcadores (desempeño óculo-motor, control cognitivo e inhibición), junto con una escala de funcionamiento e imágenes de RM. El análisis de los datos definió 4 sub-grupos: Grupo 4: respuestas motoras hiperactivas y bajo control cognitivo; Grupo 3: cognición normal y control motor normal pero amplitudes EEG anormalmente bajas en respuesta a los estímulos auditivos; Grupo 2: lentitud en tareas motoras combinado con pobre control cognitivo; Grupo 1: desempeño similar a los controles en todas las tareas. Estos subtipos fueron consistentes y homogéneos con los resultados obtenidos para cada uno de ellos en la Escala de Funcionamiento Social y en las neuroimágenes. En la misma línea, otro estudio analizó imágenes de RM funcional, calculando la intensidad de acople entre tres regiones (corteza visual, corteza pre-frontal dorsolateral y corteza parietal), implicadas en el funcionamiento de la memoria de trabajo (32). Un modelo computacional produjo estimaciones de la intensidad en la conexión entre estas tres zonas, diferenciando a los controles de los pacientes e identificando tres sub-grupos de pacientes que se diferenciaban en términos de arquitectura de la red neuronal. Cabe destacar que esta agrupación se realizó sin contar con información respecto de la sintomatología presente o predominante en los pacientes.

## El valor de los datos masivos

Los datos son índices que necesitan ser procesados para mudar en signo de algo, para portar un significado o una función pragmática; son una mercancía, materia prima la que se le puede dar un valor agregado convirtiéndola en información, y esa transformación le confiere a ese elemento neutro un uso intercambiable cuya aplicación puede distar -y no tener una relación directa- con el punto de origen. Así, mediciones de estados de ánimo colectivos, coleccionados desde los *tuits* y realizadas por programas como *Opinion Finder* o *Google-Profile of Mood States*, se correlacionaron con el comportamiento de las acciones medidas por el *Dow Jones Industrial Average* y su inclusión demostró mejorar significativamente la predicción del comportamiento de las acciones hasta en un 90% (33). Seguramente se puede hallar alguna lógica que conecte el valor de una acción con el humor positivo de los *tuiteos*, pero aquello que justifica su asociación y utilidad, lo que le otorga valor a esos datos, un valor que va más allá de la simple curiosidad, no depende de esa explicación sino del resultado, en este caso económico, que aportaría tal correlación. El dato es información para la toma de decisiones y los resultados de esas decisiones reeditúan financieramente, ergo, la correlación se afirma más.

## Una nueva epistemología

Datos hubo siempre, por lo tanto, ¿qué sería lo novedoso de los DM? Por un lado, vivimos una época en la que se produce una creciente cantidad de datos y su captura se realiza con más celo e interés; por otra parte, el mundo fue atribuyendo una importancia superlativa a los datos, importancia que podría ser intrínseca a ellos mismos o adjudicada por alguna fuente de validación externa. Pero no es sólo una cuestión cuantitativa ni de un mejor aprovechamiento de los datos gracias al desarrollo de herramientas más potentes: los DM son presentados como una aproximación epistemológica nueva en la búsqueda de *conocimiento* (34).

El giro epistemológico radica en que en lugar de testear una hipótesis empleando la experimentación, se apela a una recopilación de datos sin un procesamiento teórico previo muy consistente o, directamente, sin su necesidad, proponiendo la posibilidad de un *conocimiento* vaciado de explicaciones mecanicistas (34). De allí que se afirme que se trata de una nueva era de la producción de conocimiento caracterizada por “el fin de la teoría” (35). Dada la potencia de la estadística masiva, los patrones y las relaciones halladas en los DM producirían conocimientos inherentemente significativos y el método científico se vuelve prescindible. La analítica de los DM es, por tanto, un modo empírico, positivista y no mecanicista en la producción de conocimiento: la correlación es suficiente, no importa la hipótesis (o importa menos), la correspondencia reemplaza la causa, y la

ciencia puede avanzar sin modelos coherentes, teorías unificadas o cualquier tipo de explicación que dé cuenta del fenómeno. Frente a esta proclama contra la teoría, Han (36) la defiende fundamentado en que “la teoría constituye una *decisión* esencial [...] que dictamina qué es pertinente a algo y qué no lo es”, impidiendo que las cosas se mezclen y proliferen y reduciendo la entropía. Para Han, el exceso de información aumenta la entropía y el nivel de ruido; por lo demás, una información no es conocimiento, es “*algo de lo que nos enteramos*”. En verdad, los datos no se captan en un ideal estado salvaje, libres de toda fuerza regulatoria; de por sí los algoritmos se validan según modelos explicativos existentes y, por tanto, están diseñados para capturar sólo *ciertos* tipos de datos (37). ¿Sería por lo tanto una *decisión* epistemológica, acaso moral, volcarse hacia el marco de la razón teórica o hacia el marco de la razón estadística? Y si la información no aporta conocimiento, ¿dónde encontraría un sustento que trascienda el mero *enterarse*?

La clave que respalda a los DM es su poder estadístico. Las herramientas de procesamiento, se afirma, pueden incluir *todos* los datos pasibles de ser recogidos de un determinado fenómeno (N=todo), lo que supone una disensión con la técnica del muestreo, dado que ésta resulta de la limitación informativa y de las restricciones materiales a la hora de analizar una porción de la realidad. Al emplear *todos* los datos, es posible que surjan detalles que quizás no se hubieran detectados con cantidades restringidas de datos (38) (aunque, por más amplio que sea el universo captado, es una representación (una muestra) moldeada por la tecnología usada) (39). A su vez, se desafía el anhelo de exactitud, puesto que al emplear un número mayor de datos habría más probabilidades de que existan errores de medición, pero incluso así, de detectarse una relación entre dos variables, esto daría cuenta de que *ahí hay algo significativo*, siempre y cuando se pueda captar una tendencia general: lo que se pierde en exactitud en el nivel micro se gana en precisión en el nivel macro (25). En suma, los DM obtienen predicciones, siendo suficiente la correlación estadística. Estas correlaciones no siempre dirán por qué ocurre algo, cuál es la causa de un determinado fenómeno, pero dan la pista de que algo está pasando o que podría pasar, se establece una causa probabilística (40).

Hasta aquí se podría decir que, en rigor, los DM expresan una variante del positivismo y su propuesta de obtener conclusiones generales a partir de observaciones particulares. Sin embargo, donde los positivistas están (o estaban) interesados en que de los hechos de la experiencia surgiera un conocimiento, los ideólogos de los DM discrepan: si surge un conocimiento bienvenido, de lo contrario, no importa, la marcha de la ciencia no se detiene ya que el correlato estadístico basta para *hacer algo*. La analítica de los DM puede no profundizar en responder cómo, cuándo y por qué ocurre algo y sólo decirnos “qué ocurre” (lo que mantendría el análisis a un nivel descriptivo) (41). Si la utilidad y la calidad de

las teorías se valoran en función de su poder explicativo y de su valor predictivo, permitiendo que se pueda anticipar la emergencia de algún fenómeno con algún grado de conocimiento de la relación causa-efecto, pues bien, la analítica de los DM asume que se puede alcanzar una predicción sin una explicación.

Se podría decir que la analítica de los DM no excluye *per se* al método científico (entendido como la observación sistemática, la medición, la experimentación, la formulación, el análisis y la modificación de las hipótesis), pudiéndose asimilar a éste sin inconvenientes. Más bien, la analítica de DM incluye una combinación híbrida de aproximaciones abductivas, inductivas y deductivas, aunque se aparte del diseño experimental tradicional ya que no necesariamente arranca el proceso de investigación a partir de una hipótesis por probar (37).

Por tanto, si ha de reconocerse una nueva epistemología lo será en la relativización de la causalidad como cúspide explicativa y pasión científica. “La sociedad tendrá que desprenderse de parte de su obsesión por la causalidad a cambio de meras correlaciones [...]”, dicen Mayer-Schöenberger y Cukier (38). De acuerdo con los autores, no se precisa *necesariamente* una hipótesis válida sobre un fenómeno para empezar a entender el mundo y no resulta *eficiente* tomar decisiones acerca de qué variables examinar basándose únicamente en hipótesis (38). De este modo, podrían legitimarse datos (¿información?) como indicadores de algún hecho, aunque no guarden una relación directa de causalidad con éste, lo que oficia de cimiento para el desarrollo de una cadena auto-reproducible, que da un sentido, una justificación, una *auto-confirmación* a los resultados que se promulgan.

Desde un punto de vista epistemológico, no es posible investigar sin teoría; digamos más: no es posible tomar contacto con el mundo sin una plantilla adquirida que organice la mirada. Ahora, esa epistemología que dirige la mirada, ¿podría encerrarnos en una miopía que limite la irrupción de una propuesta, como la de los DM, que desdeñe, flexibilice, retuerza o dé por calladamente implícita una teoría dada? Para evitar retroceder varios casilleros y restaurar discusiones antiguas, sugiramos que la analítica de los DM manipula, *samplea* la teoría, al punto de convertirla en parte de otra cosa: está ahí, es un extracto del original, pero es otra cosa, un fragmento puesto al servicio de la construcción de una obra nueva, se vuelve apenas reconocible y en ningún modo determinante.

La perspectiva de los DM podría ser una aproximación tan válida como cualquier otra, y ofrecer el mismo nivel de crédito científico, un nivel de aval equiparable al de otras teorías y prácticas que empleamos cotidianamente. ¿Por qué desatender o desacreditar sus propuestas?, ¿qué haría que se la cuestione más especialmente que a otras? Es cierto, hasta ahora el cuerpo de investigaciones bajo su égida no llegó a un punto de confluencia y coherencia como para transformar la manera de teorizar (en nuestro caso, los padecimientos mentales);

pero, volvemos a remarcarlo, los DM autorizarían una praxis sin un fundamento o una explicación totalmente elucidados, lo que para la psiquiatría implicaría que los resultados estén sostenidos menos en una lógica psicopatológica o en una comprobación biológica que en el respaldo estadístico.

## El adiós a la clínica

Imaginemos que se propone una clasificación de los trastornos mentales basada en circuitos neuronales putativamente patológicos, identificados mediante neuroimágenes y establecidos más allá de toda duda gracias al respaldo de la correlación estadística. Si esto ocurriera, se podría afirmar algo así como: “De ahora en más, se definirá como Esquizofrenia la anisotropía fraccional reducida en las regiones correspondientes al fascículo longitudinal superior y en la rodilla del cuerpo caloso (42)”. Si esto prevaleciera, diagnosticar sería detectar señales, captar un *fenómeno real* del cual el síntoma sería un simple correlato superficial, una vislumbre deslucida de esas alteraciones neurobiológicas.

Aun cuando esto sea especulación, no es ningún disparate pensar que la dimensión clínica de la psiquiatría se va (a ir) perdiendo y que el terreno que deja vacante será conquistado por otras aproximaciones, como viene ocurriendo en otras especialidades. Es que si la clínica psiquiátrica se basa en un entrenamiento anamnésico y semiológico y en una sistematización que provea una conceptualización y un sentido a los síntomas, hay, al menos, tres hechos que atentan contra ella: 1) la relativa escasez de psiquiatras (43), lo que tarde o temprano repercutirá en que el encuentro médico-paciente se vea resentido por algo tan básico como la falta de tiempo; 2) el declive del Maestro que enseña a ver lo que se tiene delante, sumado a la simplificación de los conceptos clínicos a la que lleva la psiquiatría contemporánea; 3) el impulso por que la psiquiatría adopte un perfil neurocientífico (44). Una manera de paliar la falta de psiquiatras y el deterioro de la clínica es que la participación humana en la evaluación se apoye en métodos diagnósticos y terapéuticos que dependan menos de la intervención del médico. No es inimaginable, y de hecho es bien probable, que el futuro de la medicina y la psiquiatría sea uno en el que se monitoree pasivamente registros electrónicos (historias clínicas, estudios complementarios digitalizados), *posteos* en redes sociales, para detectar índices que puedan resultar de importancia sanitaria (45). De hecho, un estudio basado en 700.000 registros médicos electrónicos de un sistema de salud desarrolló un método automatizado que predice la probabilidad, sin interposición humana, de que un paciente de dicho sistema de salud desarrolle diferentes patologías, entre ellas la esquizofrenia (46).

¿A dónde nos llevaría todo esto? Por un lado, a que la psiquiatría avance sin que importe una teoría del enfermar y que el “saber” se organice según los preceptos de los DM, lo que podría ser el umbral de un nuevo pa-

radigma psiquiátrico. El contexto es favorable habida cuenta que la perspectiva de los DM se ajusta a las premisas para erigir un paradigma psiquiátrico y que, incluso, sería una prolongación coherente del paradigma biomédico descrito por Stagnaro (47). La triada Clasificación + Etiología o etiopatogenia + Terapéutica, se puede verificar en una *clasificación* de aquello que se tomará por patológico surgida de un agrupamiento de síntomas, antecedentes personales y demográficos, comprobaciones biológicas, etc., amalgamados con el cemento de la estadística, el *establecimiento de una causa* -no etiológica ni etiopatogénica- sustentada por la correlación estadística entre los elementos constituyentes de las entidades resultantes, y la posibilidad de un *diagnóstico y un tratamiento* asistidos por algoritmos computacionales. Y si en el camino se pierden conocimientos que cimentaron la psiquiatría desde su albor, ¿importará si los resultados son efectivos?

Por otro lado, las nuevas tecnologías podrían alcanzar el *sumun* de la medicina: la prevención y la detección precoz. Después de todo, ¿qué otra cosa es la capacidad de predicción de la que se ufana la analítica de los DM? Recordemos los algoritmos que analizan los *tuits* y diagnostican a los usuarios deprimidos, incluso prediciendo el desarrollo de depresión con una anticipación de varios meses al diagnóstico clínico (26). ¿Se dará lugar a su empleo a pesar de que no cuente con un asiento en la clínica, de que anule la subjetividad, de que carezca de una psicopatología?

Se objetará que se está muy cerca de la vigilancia y el control, que a fin de cuentas los DM no dejan de estar constituidos a partir de algún cuadro teórico-clínico, que las tendencias y patrones que se *descubren* con los DM pueden no ser suficientemente sensibles o específicos para tener utilidad a nivel de la salud pública... Aposillemos que una cualidad sagaz de estas nuevas aproximaciones es la capacidad de aprendizaje, de perfeccionamiento, de modo que lo que hoy podría funcionar mal sería susceptible de mejoras; y, cualidad aún más artera, que las afirmaciones estadísticamente prepotentes de los DM puedan crear *una versión de la realidad*, lo que a la larga puede ser *la realidad*.

Por lo demás, ni el objeto de la psiquiatría ni la manera adecuada de comprenderlo están delimitados de modo indiscutible: ¿se podría decir con certeza que hay un modo inapelable de entender lo-que-hoy-llamamos síntoma o enfermedad mental, que la clínica prescribe la forma correcta de ver, la más autorizada, la más ética, la más comprobable, la más simpática; que lo biológico se reproduce idénticamente y confluye homogéneamente en cada uno de los estudios destinados a valorar, eventualmente confirmar, hallazgos pretéritos u obtener constataciones nueva sobre algún aspecto de la patología mental; o que se progresó sustancialmente en el anhelo de establecer una relación biunívoca entre un sustato orgánico y un síntoma o dimensión sintomática?

### El futuro de la psiquiatría

Volvamos a la competencia de los ingenieros electrónicos por ver quién diseñaba el mejor algoritmo diagnóstico. “*Diagnóstico*” tal vez no sea el término adecuado, ya que estos algoritmos lo que hacen es clasificar, diferenciar, hallar correspondencias, sin necesariamente saber qué es lo que está clasificando. El detalle aquí es que todos estos procesos, como se dijo, pueden terminar en una espiral de autovalidación, originando nuevas formas de lo normal y lo patológico, mucho más si por algún medio (estadístico, financiero) se determina su eficiencia. El recorrido sería: 1°) poner en vecindad un dato (palabras de contenido negativo en *Twitter*, circuitos neuronales patológicos en las neuroimágenes) con algún trastorno (depresión, esquizofrenia); 2°) buscar constatar que estos datos están fuertemente asociados con el trastorno; 3°) producir la metonimia merced a la cual se propone que las palabras o las neuroimágenes son *equivalentes* al mismo diagnóstico que servían para diagnosticar; 4°) desprenderse del diagnóstico original, de modo que “palabras negativas”, “circuitos neuronales patológicos” terminarán convirtiéndose en aquello que haya que diagnosticar, y para lo que no hará falta el psiquiatra clínico.

Seguramente nos dolerá si ese termina siendo el futuro de la psiquiatría. ■

### Referencias bibliográficas

1. Silva RS, Castro E, Gupta CN, Cetin M, Arbabshirani M, Potluru VK, et al. The tenth annual MLSP competition: Schizophrenia classification challenge. Machine Learning for Signal Processing (MLSP) 2014; IEEE International Workshop on, pp. 1-6.
2. Raghupathi W, Raghupathi V. Big data analytics in healthcare: promise and potential. *Health Information Science and Systems*, 2014; 2:3.
3. Starren J, Williams MS, Bottinger EP. Crossing the omic chasm: a time for omic ancillary systems. *JAMA*, 2013; 309: 1237-8.
4. Glenn T, Monteith S. New measures of mental state and behavior based on data collected from sensors, smartphones, and the Internet. *Curr Psychiatry Rep*, 2014; 16:523.
5. Institute for Health Technology Transformation. Transforming Health Care Through Big Data. Strategies for leveraging big data in the health care industry. 2013. [Internet] Disponible en: [http://c4fd63cb482ce6861463-bc6183f1c18e748a49b87a25911a0555.r93.cf2.rackcdn.com/iHT2\\_BigData\\_2013.pdf](http://c4fd63cb482ce6861463-bc6183f1c18e748a49b87a25911a0555.r93.cf2.rackcdn.com/iHT2_BigData_2013.pdf)
6. Boyd D, Crawford K. Critical questions for big data. *Information, Communication and Society* 2012; 15(5): 662-79.

7. Kayyali B, Knott D, Van Kuiken S. The big-data revolution in US health care: Accelerating value and innovation. 2013. [Internet] Disponible en: <https://www.mckinsey.com/industries/healthcare-systems-and-services/our-insights/the-big-data-revolution-in-us-health-care>
8. Mc Nulty E. Understanding Big Data: The Seven v's. 2014. [Internet] Disponible en: <http://dataconomy.com/2014/05/seven-vs-big-data/>
9. Ginsberg J, Mohebbi MH, Patel RS, Brammer L, Smolinski MS, Brilliant L. Detecting influenza epidemics using search engine query data. *Nature*, 2009; 457, 1012–4.
10. Ortiz JR, Zhou H, Shay DK, Neuzil KM, Fowlkes AL, Goss CH. Monitoring influenza activity in the United States: a comparison of traditional surveillance systems with Google Flu Trends. *PLoS ONE* 2011; 6: e18687
11. Davidson MW, Haim DA, Radin JM. Using Networks to Combine Big Data and Traditional Surveillance to Improve Influenza Predictions. *Scientific Reports*, 2015; 5: 8154.
12. Elragal A, Klischewski R. Theory-driven or process-driven prediction? Epistemological challenges of big data analytics. *J Big Data*, 2017; 4:19.
13. Zapata Cáceres S. Técnicas de Minería de Datos basadas en Aprendizaje automático. Extracción de conocimiento KDD. [Internet] Disponible en: <https://santiagozapatakdd.wordpress.com/2011/03/25/introduccion/>
14. Neesha Jothi N, Rashid NAA, Husain W. Data Mining in Healthcare. *Procedia Computer Science* 2015; 72: 306-13.
15. Fayyad U, Piatetsky-Shapiro G, Smyth P. The KDD process of extracting useful knowledge from volumes of data. *Commun ACM*, 1996; 39(11):27–34.
16. Esteva A, Kuprel B, Novoa RA, Ko J, Swetter SM, Blau HM, et al. Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 2017; 542: 115–8.
17. Castillo-Arenas E, Garrido V, Serrano-Ortega S. Skin conditions in primary care: an analysis of referral demand. *Actas Dermosifiliogr*, 2014; 105(3):271-5.
18. Tufail A, Rudisill C, Egan C, Kapetanakis VV, Salas-Vega S, Owen CG, et al. Automated diabetic retinopathy image assessment software: diagnostic accuracy and cost-effectiveness compared with human graders. *Ophthalmology*, 2017; 124: 343–51.
19. Toy BC, Myung DJ, He L, Pan CK, Chang RT, Polkinhorne A, et al. Smartphone-based dilated fundus photography and near visual acuity testing as inexpensive screening tools to detect referral warranted diabetic eye disease. *Retina*, 2016; 36(5):1000-8.
20. Sato Y, Takeuchi H, Hoshi K, Uramoto N, Satoh T, Inaoka N, et al. The Effectiveness of the Text Mining and Similar Document Search System for Evidence-Based Guideline Development. *Japan Association for medical Informatics*, 2004; 24 (2): 315-22.
21. Henriksson A, Kvista M, Dalianis H, Duneld M. Identifying adverse drug event information in clinical notes with distributional semantic representations of context. *Journal of Biomedical Informatics*, 2015; 57: 333-49.
22. Hauben M, Madigan D, Gerrits CM, Walsh L, Van Puijenbroek EP. The role of data mining in pharmacovigilance. *Expert Opin Drug Saf*, 2005; 4(5):929-48.
23. Patorno E, Glynn RJ, Levin R, Lee MP, Huybrechts KF. Benzodiazepines and risk of all cause mortality in adults: cohort study. *BMJ*, 2017; 358: j2941.
24. Kessing LV, Gerds TA, Knudsen NN, Jørgensen LF, Kristiansen SM, Voutchkova D, et al. Association of Lithium in Drinking Water With the Incidence of Dementia. *JAMA Psychiatry*, 2017; 74(10):1005-10.
25. Monteith S, Glenn T, Geddes J, Bauer M. Big data are coming to psychiatry: a general introduction. *Int J Bipolar Disord*, 2015; 3:21.
26. Reece AG, Reagan AJ, Lix KLM, Sheridan Dodds P, Danforth CM, Langer EJ. Forecasting the onset and course of mental illness with Twitter data. *Scientific Reports*, 2017; 7: 13006.
27. Reece AG, Danforth CM. Instagram photos reveal predictive markers of depression. *Data Science*, 2017; 6:15.
28. Bedi G, Carrillo F, Cecchi GA, Fernández Slezak D, Sigman M, Mota NB, et al. Automated analysis of free speech predicts psychosis onset in high-risk youths. *Schizophrenia*, 2015; 1: 15030.
29. Whelan R, Watts R, Orr CA, Althoff RR, Artiges E, Banaschewski T, et al. Neuropsychosocial profiles of current and future adolescent alcohol misusers. *Nature*, 2014; 512(7513):185-9.
30. Cao B, Cho RY, Chen D, Xiu M, Wang L, Soares JC, Zhang XY. Treatment response prediction and individualized identification of first-episode drug-naïve schizophrenia using brain functional connectivity. *Mol Psychiatry*, 2018; doi: 10.1038/s41380-018-0106-5.
31. Huang LY, Sweeney JA, Hamm JP, Ethridge LE, Pearlson GD, Keshavan MS, et al. Data-Driven Approach Identified Functionally and Physiologically Distinct Psychosis Subtypes. *Schizophr Bull*, 2017; 43(Suppl 1): S232–33.
32. Brodersen KH, Deserno L, Schlagenhaut F, Lin Z, Penny WD, Buhmann JM, et al. Dissecting psychiatric spectrum disorders by generative embedding. *Neuro Image Clinical*, 2014; 4: 98–111.
33. Bollen J, Mao H, Zen X. Twitter mood predicts the stock market. *Journal of Computational Science*, 2011; 2 (1): 1-8.
34. Kitchin R. Big Data, new epistemologies and paradigm shifts. *Big Data & Society*, 2014; 1-12.
35. Anderson C. The end of theory: The data deluge makes the scientific method obsolete. 2008. [Internet] Disponible en: [http://www.wired.com/science/discoveries/magazine/16-07/pb\\_theory](http://www.wired.com/science/discoveries/magazine/16-07/pb_theory)
36. Han BC. *La Agonía del Eros*. Barcelona, Herder Editorial, 2014.
37. Leonelli S. Introduction: Making sense of data-driven research in the biological and biomedical sciences. *Studies in History and Philosophy of Biological and Biomedical Sciences* 2012; 43(1): 1-3.
38. Mayer-Schönberger V, Cukier K. *Big Data. A Revolution That Will Transform How We Live, Work and Think*. London, Murray, 2013.
39. Kitchin R. Big data and human geography: Opportunities, challenges and risks. *Dialogues in Human Geography*, 2013; 3(3): 262–67.
40. Varian HR. Beyond big data. *Bus Econ*, 2014; 49:27–31.
41. Colquitt J, Zapata-Phelan C. Trends in theory building and theory testing: a five-decade study of the Academy of Management Journal. *AcadManag Rev*, 2007; 50(6):1281–03
42. Shergill SS, Kanaan RA, Chitnis XA, O'Daly O, Jones DK, Frangou S, et al. A diffusion tensor imaging study of fasciculi in schizophrenia. *Am J Psychiatry*, 2007; 164(3):467-73



43. Katschnig H. Are psychiatrists an endangered species? Observations on internal and external challenges to the profession. *World Psychiatry*, 2010; 9(1):21-8.
44. Insel TR, Quirion R. Psychiatry as a Clinical Neuroscience Discipline. *JAMA*, 2005; 294(17):2221-4.
45. Chekroud AM. Bigger Data, Harder Questions—Opportunities Throughout Mental Health Care. *JAMA Psychiatry*, 2017; 74(12): 1183-4.
46. Miotto R, Li L, Kidd BA, Dudley JT. Deep patient: an unsupervised representation to predict the future of patients from the electronic health records. *SciRep*, 2016; 6: 26094.
47. Stagnaro JC. La formación actual de especialistas en psiquiatría: un desafío epistemológico. *Vertex, Rev Arg de Psiquiatría*. 2013; XXIV: 206-14.