

# APRENDIZAJE AUTOMÁTICO EN SALUD: APLICACIONES, LIMITACIONES E IMPLICANCIAS ÉTICAS

## MACHINE LEARNING IN HEALTH: APPLICATIONS, LIMITATIONS AND ETHICAL IMPLICATIONS

Victor Moquillaza Alcántara <sup>1,3,a</sup>, Paulo Camilo Alberto Vela Anton <sup>2,3,a</sup>

1. Obstetra
2. Ingeniero mecatrónico
3. Becario de la Maestría en Informática Biomédica en Salud Global
4. Facultad de Salud Pública y Administración, Universidad Peruana Cayetano Heredia. Lima, Perú.



*“¿Por qué recién ahora nos damos cuenta que los datos son tan poderosos? Porque se está dando la tormenta perfecta, por un lado se está dando un crecimiento en la cantidad de los datos... y por el otro, nuestra capacidad de procesarlos también crece exponencialmente”*

Nicolas Loeff (Gerente de Ingeniería, Google)

Gran parte de las decisiones que asumimos en las ciencias de la salud, desde la salud pública hasta la práctica asistencial, son respaldadas por información obtenida a partir de datos. En las últimas décadas, las instituciones han buscado aglomerarlos en amplias bases, con el objetivo de generar nuevos conocimientos. Sin embargo, el dato como tal es inútil, puesto que requieren un análisis mediante el uso de algoritmos para obtener resultados. Durante el siglo XXI estos algoritmos han tenido un notable desarrollo, siendo aún más potentes que la estadística clásica.<sup>1</sup>

El aprendizaje automático (*Machine learning*) es aquella disciplina de la Inteligencia artificial que reconoce patrones en una base de datos, para generar con ella algoritmos informáticos con capacidad predictiva.<sup>2</sup> Sin embargo, es preciso entender que estos algoritmos no son sistemas infalibles; Obermeyer Z y Emanuel EJ ejemplifican que el aprendizaje automático se comporta como el estudiante que inicia su rotación hospitalaria, donde la atención de cada nuevo paciente le permite reconocer qué características, al combinarse, pronostican un resultado de manera confiable.<sup>1</sup> Es así como la destreza del estudiante, al igual que la del algoritmo, será un producto de la cantidad de veces que ha puesto su capacidad en práctica, donde el error permite “ajustar” nuestro conocimiento y tener una mayor precisión.

La “*New England Journal of Medicine*” destaca tres aspectos del aprendizaje automático sobre la salud: i) Los nuevos algoritmos permitirían una prevención más eficaz, puesto que los modelos actuales (e.g., el puntaje APGAR) se

### Correspondencia

Victor Hugo Moquillaza Alcántara  
victor.moquillaza@upch.pe

### Proceso editorial

Recibido: 31 de Diciembre del 2019  
Aprobado: 31 de Diciembre del 2019

### Cita bibliográfica

Moquillaza-Alcántara. V, Vela-Anton P. Aprendizaje automático en salud: Aplicaciones, limitaciones e implicancias éticas. Rev Int Salud Matern Fetal. 2019; 4(4): 1-3.

restringen a una cantidad limitada de variables; esto podría cambiar debido a que se podrían extraer gran cantidad de datos clínicos de los pacientes y así determinar, en un paciente en particular, una predicción sobre su diagnóstico; ii) seguidamente, esta tecnología desplazará en gran medida a quiénes interpretan resultados, puesto que una computadora permitiría mejor precisión, rendimiento y velocidad para la misma tarea, sin trabas como el sueño o distracciones. Por último, iii) se mejoraría la precisión del diagnóstico en aquellas complicaciones cuya detección es brindada por la subjetividad del profesional, aunque es necesario ser cuidadosos en la inclusión de modelos en la decisión clínica de cada diagnóstico.<sup>1</sup>

Un ejemplo del uso de estos modelos en el campo de la salud es la aplicación del análisis de imágenes en el ultrasonido. Bajo un sistema clásico, podríamos asumir que una ecografía puede darnos resultados “positivos” o “negativos” sobre una complicación, la cual es determinada por un profesional que, bajo la subjetividad humana, puede cometer errores en su diagnóstico. Sin embargo, el aprendizaje automático apunta a que cada pixel de la imagen sea una variable, las cuales interaccionan entre sí para generar líneas y figuras que un algoritmo “aprende”, hallando patrones con alta probabilidad de representar un resultado positivo o negativo.<sup>1,3</sup>

En salud pública se viene utilizando el aprendizaje automático para mejorar los sistemas de vigilancia epidemiológica, donde se busca hallar las tendencias de ciertas enfermedades, con el fin de brindar recursos en momentos oportunos y manteniendo, de este modo, saludable a la población.<sup>4</sup> Asimismo, se han generado modelos que permiten predecir comportamientos, pensamientos o sentimientos en base al uso de dispositivos portátiles o computadoras.<sup>5</sup> Todo esto ha sido aprovechado, junto a otras utilidades más, para incluir soportes de decisiones clínicas a las historias clínicas electrónicas, con lo cual se consigue una oportuna atención tomando en cuenta características predictivas que antes podrían haber pasado desapercibidas.<sup>6</sup>

Sin embargo, el desarrollo de algoritmos tiene ciertas limitaciones. Tal como se ha mencionado, la cantidad de datos influye significativamente en desarrollo de modelos óptimos, llegando a requerir hasta más de un millón de observaciones para alcanzar un rendimiento aceptable. De igual modo, al ser materia prima la base de datos es preciso que estos no presenten sesgos en su recopilación, lo cual en muchas situaciones es difícil o imposible de determinar.<sup>1</sup> Por otro lado, los modelos predictivos suelen describirse como “cajas negras”, debido a que la forma cómo se generan es usualmente desconocida, lo cual puede llegar a generar dudas sobre su comprobación.<sup>4</sup>

Otra limitación es asumir como principal objetivo el corroborar la prueba de hipótesis, utilizado ampliamente en la estadística clásica, la cual es reemplazada por la predicción como indicador final del estudio. Es así como el “valor p” puede brindar indicadores favorables de una aparente asociación o correlación entre variables que, para modelos de aprendizaje automático, no tienen utilidad si no llegan a predecir correctamente un desenlace. Por ello, los modelos priman el uso de la “exactitud”, la cual es determinada como la proporción de resultados pronosticados correctamente (positivos verdaderos + negativos verdaderos) sobre el total de los datos.<sup>4</sup>

Finalmente, debe entenderse que el proceso de generar modelos predictivos debe tener una etapa de validación con evaluaciones tan estrictas como lo podría tener un ensayo clínico. Esto debido a que los resultados obtenidos del aprendizaje automático pueden deberse a correlaciones espurias o estimaciones inestables, dando como consecuencia exageradas u optimistas afirmaciones sobre el rendimiento de un algoritmo que realmente no se asemeja con el mundo real. Este proceso debe asumirse con la seriedad y preocupación que amerita, para lo cual se

requiere, necesariamente, probar el modelo con datos ajenos a los que generaron el algoritmo. Este principio ha llegado a ser tan importante, que los medios de difusión científica como las revistas, solicitan a los investigadores que carguen en la web los datos con los que generaron y validaron un modelo, a fin de que pueda seguir siendo evaluado por cualquier otra persona.<sup>1</sup>

Otra consideración ética a tener en cuenta es que, en vista que los modelos son producto del análisis de un colectivo de datos, estos estarán supeditados a las características de la población mayoritaria, generando sesgos si no existe una muestra representativa. Char D refiere que ha habido modelos predictivos de complicaciones cardiovasculares que han sido generados en base a datos norteamericanos, los cuales en poblaciones no blancas han generado sobreestimaciones de los riesgos.<sup>7</sup>

Actualmente, el aprendizaje automático viene siendo una herramienta indispensable para resolver problemas complejos en diversos campos como la biología y la astrología. Sin embargo, los estudios aplicados a la salud vienen presentando aún escasa evidencia para su uso definitivo como asistencia diagnóstica. Queda en los profesionales de salud dedicados a la investigación el aprender y emplear este método informático, y desplegar su potencial para llevar la atención médica al siguiente nivel.

La Revista Internacional de Salud Materno Fetal (ISSN 2519-9994) se encuentra alojada en:



## REFERENCIAS BIBLIOGRÁFICAS

1. Obermeyer Z, Emanuel EJ. Predicting the future: Big data, Machine learning and Clinical medicine. *N Engl J Med.* 2016; 375(13): 1216-1219. [\[Link\]](#)
2. Deo RC. Machine learning in medicine. *Circulation.* 2018; 132 (20): 1920-1930. [\[Link\]](#)
3. Poostchi M, Silamut K, Maude R, Jeager S, Thoma G. Image analysis and machine learning for detecting malaria. *Transl Res.* 2019; 194: 36-55. [\[Link\]](#)
4. Mooney SJ, Pejaver V. Big data in public health: Terminology, machine learning and privacy. *Annu Rev Public Health.* 2018; 39(1): 95-112. [\[Link\]](#)
5. Mohr D, Zhang M, Schueller S. Personal Sensing: Understanding Mental Health Using Ubiquitous Sensors and Machine Learning. *Annu Rev Clin Psychol.* 2017; 13: 23-47. [\[Link\]](#)
6. Gianfrancesco M, Tamang S, Yazdany J, Schmajuk G. Potential Biases in Machine Learning Algorithms Using Electronic Health Record Data. *JAMA Intern Med.* 2018; 178(11): 1544-1547. [\[Link\]](#)
7. Char DS, Shah NH, Magnus D. Implementing Machine Learning in Health Care – Addressing Ethical Challenges. *N Engl J Med.* 2018; 378(11): 981-983. [\[Link\]](#)