

CUERPO EDITORIAL

DIRECTOR

- Dr. Esteban Sanchez Gaitan, Hospital San Vicente de Paúl, Heredia, Costa Rica.

CONSEJO EDITORIAL

- Dr. Cesar Vallejos Pasache, Hospital III Iquitos, Loreto, Perú.
- Dra. Anais López, Hospital Nacional Edgardo Rebagliati Martins, Lima, Perú.
- Dra. Ingrid Ballesteros Ordoñez, Pontificia Universidad Javeriana, Bogotá, Colombia.
- Dra. Mariela Burga, Hospital Nacional Edgardo Rebagliati Martins. Lima, Perú.
- Dra. Patricia Santos Carlín, Ministerio de Salud (MINSA). Lima, Perú.
- Dr. Raydel Pérez Castillo, Centro Provincial de Medicina Deportiva Las Tunas, Cuba.

COMITÉ CIENTÍFICO

- Dr. Zulema Berrios Fuentes, Ministerio de Salud (MINSA), Lima, Perú.
- Dr. Gerardo Francisco Javier Rivera Silva, Universidad de Monterrey, Nuevo León, México.
- Dr. Gilberto Malpartida Toribio, Hospital de la Solidaridad, Lima, Perú.
- Dra. Marcela Fernández Brenes, Caja costarricense del Seguro Social, Limón, Costa Rica
- Dr. Hans Reyes Garay, Eastern Maine Medical Center, Maine, United States.
- Dr. Steven Acevedo Naranjo, Saint- Luc Hospital, Quebec, Canadá.
- Dr. Luis Osvaldo Farington Reyes, Hospital regional universitario Jose María Cabral y Baez, Republica Dominicana.
- Dra. Caridad María Tamayo Reus, Hospital Pediátrico Sur Antonio María Béguéz César de Santiago de Cuba, Cuba.
- Dr. Luis Malpartida Toribio, Hospital Nacional Daniel Alcides Carrión, Callao, Perú.
- Dra. Allison Viviana Segura Cotrino, Médico Jurídico en Prestadora de Salud, Colombia.
- Mg. Luis Eduardo Traviezo Valles, Universidad Centroccidental “Lisandro Alvarado” (UCLA), Barquisimeto, Venezuela.
- Dr. Pablo Paúl Ulloa Ochoa, Instituto Oncológico Nacional “Dr. Juan Tanca Marengo”, Guayaquil, Ecuador.

EQUÍPO TÉCNICO

- Msc. Meylin Yamile Fernández Reyes, Universidad de Valencia, España.
- Lic. Margarita Ampudia Matos, Hospital de Emergencias Grau, Lima, Perú.
- Ing. Jorge Malpartida Toribio, Telefónica del Perú, Lima, Perú.
- Srita. Maricielo Ampudia Gutiérrez, George Mason University, Virginia, Estados Unidos.

EDITORIAL ESCULAPIO

50 metros norte de UCIMED,
Sabana Sur, San José-Costa Rica
Teléfono: 8668002
E-mail: revistamedicasinergia@gmail.com



ENTIDAD EDITORA

SOMEA
SOCIEDAD DE MEDICOS DE AMERICA
Frente de la parada de buses Guácimo, Limón. Costa Rica
Teléfono: 8668002
Sociedaddemedicosdeamerica@hotmail.com
<https://somea.businesscatalyst.com/informacion.html>



Inteligencia artificial y aprendizaje automático en medicina

Artificial intelligence and machine learning in medicine



¹Dra. Marianella Álvarez Vega

Investigadora independiente, Heredia, Costa Rica

ID <https://orcid.org/0000-0003-0211-9067>

²Dra. Laura María Quirós Mora

Investigadora independiente, San José, Costa Rica

ID <https://orcid.org/0000-0003-1394-4230>

³Dra. Mónica Valeria Cortés Badilla

Investigadora independiente, San José, Costa Rica

ID <https://orcid.org/0000-0002-7893-9195>

RECIBIDO

27/02/2020

CORREGIDO

23/03/2020

ACEPTADO

01/06/2020

RESUMEN

El aprendizaje automático es una poderosa rama de la Inteligencia Artificial que se ha utilizado con éxito en distintas industrias. En los últimos años con la creciente disponibilidad de información clínica almacenada electrónicamente el campo médico se ha convertido en un ambiente ideal para el desarrollo y aplicación de estas nuevas tecnologías. El aprendizaje automático posee el potencial de mejorar los sistemas de salud, mediante el análisis de millones de datos clínicos se logran crear modelos pronósticos, de tamizaje y diagnósticos. Sin embargo, a pesar de ser evidente que el uso de métodos algorítmicos puede mejorar la calidad de los sistemas de salud y la vida de los pacientes, aún es necesario un adecuado proceso de validación para la implementación de estas tecnologías.

¹Médica general, graduada de la Universidad de Ciencias Médicas (UCIMED), cod. [MED16035](#). mariannella2408@gmail.com

²Médica general, graduada de la Universidad de Ciencias Médicas (UCIMED), cod. [MED16067](#). lauraquiros2495@gmail.com

³Médica general, graduada de la Universidad de Ciencias Médicas (UCIMED), cod. [MED16100](#). monicortes23@hotmail.com

ABSTRACT

Machine learning is a powerful branch of Artificial Intelligence that has been used successfully in different industries. In the last few years with the increasing availability of clinical data stored in electronic format, the medical field has become an ideal environment for the development and application of these technologies. Machine learning has the potential to improve

healthcare system by analyzing millions of clinical data to create prognostic, screening and diagnostic models. However, even though it is evident that the use of these algorithms can improve the quality of healthcare systems and patient's life, an appropriate validation process is needed in order to implement these technologies into the clinical practice.

KEYWORDS: machine learning; artificial intelligence; quality of healthcare.

INTRODUCCIÓN

En los inicios de la medicina los clínicos pensaban en grupo, colegas trabajan juntos con el fin de resolver problemas que resultaban ser extremadamente complejos para un solo individuo, actualmente la medicina se ha tornado aún más compleja, se dispone de muchas más terapias, medicamentos, exámenes, y procesar tales datos exceden la capacidad de comprensión de la mente humana (1), de allí que es necesario buscar una nueva herramienta con la capacidad de integrar enormes cantidades de datos, reconocer patrones y crear modelos que permitan resolver las limitaciones humanas, disminuir carga médica, acelerar la atención, brindar manejos más personalizados y disminuir recursos (2).

El aprendizaje automático ya es una realidad en numerosas áreas y con muy buenos resultados, como lo es en finanzas, mercadotecnia y ciencias sociales para predecir comportamientos. Sin embargo, en medicina su uso aún se encuentra limitado por retos propiamente del desarrollo de los modelos, así como, desafíos legales, éticos y filosóficos (3).

A pesar de estos conflictos, la complejidad de la medicina hace que este sea uno de los campos que más se puede beneficiar con estas técnicas, por lo que en los últimos años distintos modelos y algoritmos se han ido

incorporando en procesos médicos, como por ejemplo en detección de cáncer de mama comparando mamografías (4), detección cáncer de piel con evaluación de imágenes (5) y detección de patologías cardíacas analizando ecocardiogramas (6).

Ante el creciente auge de técnicas de aprendizaje automático en el campo de la medicina, este artículo de revisión bibliográfica posee como objetivo proporcionar una breve introducción al aprendizaje automático, exemplificar los posibles usos en el área de salud y exponer los desafíos aún por resolver para su implementación. Se espera que al final de este escrito el lector obtenga un conocimiento básico en el tema y fomentar el interés por el desarrollo, evaluación e incorporación de estas tecnologías en la medicina.

MÉTODOS

Se obtuvieron artículos con fecha de publicación menor a 5 años de antigüedad en base de datos como PubMed, Medline, DynaMed, DynaMedPlus y de buscadores como Google Scholar. Para la búsqueda de los artículos se utilizaron términos de búsqueda como "Machine learning in Medicine" y "Artificial Intelligence in Medicine". Posteriormente se filtraron

con el fin de utilizar los de mayor afinidad al contenido de este artículo. Y finalmente se revisaron los artículos completos que contenían información de mayor interés para el cumplimiento de los objetivos de este escrito.

FUNDAMENTOS DE MACHINE LEARNING

Machine learning, también conocido como aprendizaje automático o aprendizaje máquina, es un concepto acuñado en 1959 por Arthur Samuel (7, 8). Samuel fue un pionero en el uso aprendizaje automático programando una computadora en el juego de damas que era capaz de comparar las mejores opciones de movimiento, además de recordar todas las posiciones de encuentros previos que permitían a la máquina aprender y mejorar con cada juego (8). En su artículo en el apartado de inteligencia artificial Samuel describe el aprendizaje automático como una tecnología que utiliza técnicas estadísticas y algoritmos computacionales para proporcionar a los ordenadores la capacidad de aprender, es decir, mejorar sus resultados en una tarea específica tras procesar datos en suficiente cantidad y sin instrucciones explícitas externas proporcionadas por el programador (7).

El aprendizaje automático se reconoce como una rama de la inteligencia artificial debido a que aprende analizando datos y posteriormente genera su propia decisión por medio de algoritmos, es decir, su razonamiento en la resolución de tareas involucra características de la inteligencia humana (9). Las técnicas de aprendizaje automático son parte del campo de la informática que involucra la evolución de

sistemas de reconocimiento de patrones permitiendo a las computadoras aprender de errores y predecir resultados (10, 11).

Estas herramientas se basan en conjuntos de procedimientos matemáticos que describen las relaciones entre variables conocidos como: algoritmos (12, 11).

Por medio de machine learning las computadoras poseen la capacidad analizar datos y crear algoritmos que permiten que la computadora aprenda y cree predicciones sin ser programadas reglas explícitas (7, 13). A diferencia de métodos estadísticos convencionales donde el aprendizaje es por medio de reglas, en el aprendizaje automático computadoras aprenden con ejemplos y entre más exposición a datos la herramienta va mejorando y aprendiendo con la experiencia (13,14).

En ocasiones puede resultar confuso el límite entre métodos estadísticos convencionales y el aprendizaje automático, sin embargo, aunque técnicas estadísticas tradicionales como la regresión lineal y logística son capaces de crear predicciones su objetivo es meramente hacer inferencias sobre las relaciones entre variables, en cambio los métodos de aprendizaje automático buscan comprender las relaciones entre variables (10).

CATEGORÍAS DE MACHINE LEARNING

La mayoría de los métodos de aprendizaje automático se pueden clasificar en tres categorías según el tipo técnica de aprendizaje utilizada: supervisado, no supervisado y aprendizaje por refuerzo (7,13, 15).

- **Aprendizaje supervisado:** inicialmente se entrena la máquina, proporcionando entradas o características (inputs o features) que están asociadas a un resultado conocido o etiqueta (outputs o label) determinado por expertos humanos (12, 13, 14, 16). La meta de estos algoritmos es aprender reglas generales que mapean inputs con outputs (13,14).
En medicina se puede utilizar un modelo para relacionar características de lesiones en piel (por ejemplo: tamaño, color, forma) con un resultado determinado (siguiendo con el ejemplo, clasificar como: lesión benigna o maligna). En el aprendizaje supervisado la computadora gana experiencia con millones de datos proporcionados, aprende los patrones y posteriormente se introduce un registro nuevo con el cual se pone a prueba la capacidad de predicción del modelo (12,13).
- **Aprendizaje no supervisado:** a diferencia del anterior, en este caso no se proporciona información previa al sistema, sino más bien se introducen grandes cantidades de datos no etiquetados y el sistema se encarga de encontrar tendencias o patrones escondidos y separar la información en grupos de manera automática (7,12, 13, 14). Por ejemplo, en medicina se pueden proporcionar imágenes de tumores cerebrales y el sistema se encarga de separar las imágenes en grupos de acuerdo con los patrones observados (16).
- **Aprendizaje por refuerzo:** esta tercera variante de machine learning se introduce al sistema en un ambiente dinámico, se proporcionan datos etiquetados, así como sin etiquetar, el sistema interactúa con el entorno y recibe recompensas negativas o positivas (feedback) de acuerdo con sus acciones lo cual permite que se perfeccione, desarrollando mejores caracterizaciones y clasificaciones (7, 13, 16); por lo tanto, la computadora “aprende” sin recibir instrucciones explícitas. Las recién mencionadas son las categorías principales de machine learning, y se subclasifican en distintos tipos de aprendizaje automatizado según la meta que se desee lograr. Entre las técnicas de aprendizaje supervisado se encuentran: decision trees, K-nearest neighbours, support vector machine, naive bayes, linear regression, neutral networks, entre otros; y en el aprendizaje no supervisado existen: hierarchical clustering, k-means clustering, linear discriminant analysis (13, 16). Lo antes citado son ejemplos de subcategorías, sin embargo, desarrollar cada una de estas técnicas no es parte de los objetivos de este artículo. Entre ellos un método que ha sido de gran interés es: deep learning, esta herramienta ha ganado atención rápidamente y proporciona excelentes resultados (10). Modelos basados en deep learning utilizan redes neuronales artificiales de múltiples capas, las capas se encuentran conectadas por un conjunto de neuronas formando una

red que permite que se aprendan relaciones extremadamente complejas entre características y etiquetas inspirado en la red neurológica humana estos modelos han excedido la capacidad humana en algunos campos como, por ejemplo: la clasificación de imágenes (11,13, 15).

CONSTRUCCIÓN DE UN SISTEMA DE MACHINE LEARNING

El entendimiento de estas tecnologías definitivamente no es un tema familiar para los clínicos, la confección de técnicas de aprendizaje automatizado posee un origen en la estadística y el lenguaje de la programación, por lo que únicamente se explicará de manera superficial la ruta para poner en funcionamiento un sistema de machine learning ante un problema específico.

- **Preprocesamiento:** inicialmente se verifica la calidad de los datos, se reducen los datos ruidosos, se eliminan características irrelevantes y se reparan problemas de inconsistencias.

Es un trabajo complejo el cual prepara la gran base de datos que posteriormente será procesada por el modelo correspondiente (7,17). Por ejemplo, se creó una base de datos de ecocardiografía del Hospital de Stanford que contenía imágenes, reportes médicos e información clínica; en la fase inicial se eliminaron todos los datos innecesarios, como: información relacionada con la adquisición de imágenes, información de identificación y cualquier otro dato

que estuviese que no fuera del sector de imágenes (6).

- **Cálculo de características:** en este paso se extraen aquellas características importantes para la toma de decisiones. Se asigna o se representa mediante un valor numérico a cada variable (10, 16), sin embargo, la forma en que son calculadas las características va más allá del propósito de este escrito. Por ejemplo, en radiología se extraen características como: forma, textura, contornos y se calculan valores numéricos que representen el contenido visual de una imagen radiológica (10).
- **Selección de características:** en el paso anterior se puede extraer una gran cantidad características, sin embargo, tener demasiadas características puede impedir aprender la verdadera base de una decisión (16), por lo que es importante reducir el número de características que se utilizarán en el proceso de entrenamiento, en este paso se seleccionan características que generarán mejores predicciones y verdaderamente tendrán un impacto en el modelo, sin perder información valiosa (7, 10, 16).
- **Entrenamiento, prueba y validación:** una vez que el conjunto de datos se encuentre reducido y organizado en un formato adecuado es posible comenzar el entrenamiento (12). Se decide el tipo de muestreo y se divide la base de datos, un subgrupo de datos será



utilizado para el entrenamiento, otro para poner a prueba el rendimiento de los algoritmos y otro para el proceso de validación. (7, 16).

- **Seleccionar algoritmo de aprendizaje:** escoger distintos algoritmos de machine learning y comparar resultados entre sí, se selecciona el modelo entrenado que mejor se adapte a los requerimientos. Y por último se ha de emplear el modelo seleccionado en casos nuevos evaluando su funcionamiento (7,12).

ÁREAS DE IMPLEMENTACIÓN DE MACHINE LEARNING

- **Pronóstico**

Machine learning posee el potencial de predecir la susceptibilidad de un sujeto a padecer una enfermedad, recurrencia de una enfermedad, esperanza de vida (2). Este tipo de herramienta permitiría ofrecer a los pacientes una medicina de precisión (13). Uno de los campos que más ha estudiado el uso de machine learning en predicción de pronósticos es la oncología. Se ha reportado que el uso de métodos de machine learning mejoraba el entre un 15-25% las predicciones de pronóstico de cáncer (2). Los estudios pronósticos de machine learning en cáncer utilizan datos genómicos, clínicos, histológicos, imágenes, demográficos o epidemiológicos (17). Por ejemplo, se han utilizado algoritmos de machine learning en estudios para predecir la recurrencia de cáncer colorrectal estadio IV posterior a la

resección tumoral (18). Otras investigaciones predicen riesgo de padecer una enfermedad, por ejemplo, Ghorbani et al describen la forma en que entrenaron un modelo de redes neuronales convencional con millones de imágenes de ecocardiogramas de pacientes con el fin de identificar estructuras cardíacas y estimar la función cardiaca y predecir factores de riesgo (6).

- **Screening y diagnóstico**

El Instituto de medicina, ahora conocido como la Academia nacional de medicina publicó un reporte conocido como “Errar es de Humanos”; en este escrito se concluye que al menos en una ocasión de la vida un paciente será mal diagnosticado (15), por lo que una técnica de aprendizaje automático capaz de tamizar pacientes, estadificar pacientes por riesgo y asistir médicos en toma de decisiones sería de gran ayuda para el día a día del médico (2).

Los sistemas algorítmicos de machine learning podrían ser de ayuda para el personal médico en escenarios donde el diagnóstico no esté claro, o simplemente para agilizar sistemas de salud, se pretende utilizar la capacidad de los sistemas de aprendizaje automático para de identificar probables diagnósticos mediante la integración de datos disponibles electrónicamente de cada paciente (11).

Los avances en machine learning prometen aplicaciones en el reconocimiento de patrones en



imágenes médicas, por lo que poseen un gran potencial en campos como radiología y patología. Estudios demuestran la capacidad de entrenar modelos de aprendizaje automático que sirvan de apoyo en la práctica clínica para evaluar imágenes de láminas patológicas completas en cáncer de próstata, carcinoma de células basales y metástasis de cáncer de mama a ganglios linfáticos axilares (19). Asimismo, en el campo de la radiología, estudios demuestran el potencial de modelos de deep learning en el tamizaje de mamografías al reducir la carga de trabajo de radiólogos y mejorar la especificidad sin dañar la sensibilidad (4).

Otras investigaciones prometedoras se realizan en el campo de la dermatología, donde se han clasificado lesiones cutáneas utilizando redes neuronales convencionales entrenando los modelos directamente con imágenes y comparando su desempeño con dermatólogos certificados (5). Incluso se pretende poner a disposición de las personas aplicaciones que puedan utilizar en un dispositivo como un smartphone y que por medio de una fotografía se evalúe la necesidad de referir a un especialista.

TRATAMIENTO

Los modelos de machine learning pueden aprender a identificar el mejor tratamiento para un paciente, basándose en información objetiva (2). Asimismo, herramientas de aprendizaje automático pueden mejorar el descubrimiento y

desarrollo de nuevos medicamentos (20). Por ejemplo, se aplican nuevas técnicas de aprendizaje automático en detección virtual (campo computacional que ayuda en estudios experimentales a detectar interacciones desconocidas en nuevos fármacos), sin embargo, hoy en día el rendimiento de predicción continúa siendo bajo (21).

- **Reducción de carga clínica y acceso a sistema de salud**

La disponibilidad de información clínica almacenada electrónicamente se ha convertido en una herramienta importante en los sistemas de salud (11). Tener al alcance datos médicos almacenados virtualmente abre la posibilidad de simplificar la atención médica, reducir costos y tiempo de diagnóstico (2, 15). Por ejemplo, Wall et al desarrolló un modelo capaz de evaluar y diagnosticar pacientes con autismo, este estudio visualiza aplicar el modelo con el fin de captar de manera preliminar los pacientes y posteriormente derivar al médico, pretendiendo aliviar el trabajo clínico y hacer más eficiente el sistema (2).

Algoritmos de machine learning aún no se encuentran integrados en sistemas de salud, sin embargo, existen proyectos de aprendizaje automatizado para extender el alcance del acceso a servicios médicos (13). Estudios novedosos destacan la posibilidad de utilizar modelos de aprendizaje automático para proporcionar evaluación médica desde un dispositivo electrónico (2,15).

A pesar de que estas tecnologías aún no se encuentran al alcance médico, no cabe duda de su potencial de mejorar acceso a servicios, reducción de consultas innecesarias, brindar

comodidad de los usuarios, reducción de la carga de trabajo y reducción de costos (2,12,13).

LIMITACIONES Y DESAFÍOS

- **Recopilación de datos de alta calidad**

Un desafío clave en la construcción de sistemas de aprendizaje automático es la necesidad de incluir datos diversos y representativos, entre más acceso a información de alta calidad que se adapte a las intenciones del modelo mayor será la exactitud (11, 15, 17).

Se ha demostrado que no sólo es necesario grandes volúmenes de datos, si no datos de alta calidad, por lo que resulta fundamental escoger adecuadamente el subconjunto de características más informativo para entrenar el modelo (13, 17). Por ejemplo, si se entrena el sistema con un conjunto de datos mayoritariamente de personas blancas y poca representación de afroamericanos, dependiendo de la patología el modelo podría generar predicciones erróneas (22).

El entrenamiento de los sistemas de machine learning es necesario involucrar médicos habilidosos y estudios objetivos que realicen distinción entre los datos valiosos. Se debe vigilar cuidadosamente la información introducida en el modelo por el riesgo a reproducir sesgos humanos, debido a que el aprendizaje retrospectivo. Velar porque el sistema aprenda patrones objetivos, terapias novedosas en vez

de aprender según prácticas médicas con bases subjetivas (1,13,17).

- **Traducción de resultados**

Una de las fortalezas del aprendizaje automático es la habilidad de reconocer patrones fuera del alcance humano entre la inmensidad de datos proporcionados, pero al mismo tiempo esta característica no es del todo milagrosa, ya que, los patrones identificados puede que no representen necesidades de los sistemas de salud y/o los usuarios. Inclusive puede que los sistemas de aprendizaje pasen por alto variables que sí sean modificables (12, 14).

Un término mencionado ampliamente en machine learning es: "caja negra" o "black box" que hace referencia a la complejidad de las funciones y la dimensionalidad de los sistemas de aprendizaje automático que a menudo dificulta la interpretación de resultados, lo que limita su utilidad (11, 13). Investigadores continúan trabajando en la solución a este problema con el fin de encontrar modelos que arrojen resultados significativos y modificables (2, 12).

- **Normativas, legislaciones y problemas éticos**

Los algoritmos de machine learning requieren de gran cantidad de datos para el perfeccionamiento de sus modelos, por lo que tener acceso a gran cantidad de registros médicos es de gran importancia, de allí que regulaciones en cuanto quién tendrá acceso a esta información y normativas para la protección de la

confidencialidad son de suma importancia. Por estas razones en distintos países ya cuentan con sistemas de protección de datos, por ejemplo, en Europa se crea European General Data Protection Regulation (GDPR) que se encargar de velar que los sujetos en estudio permitan mediante consentimiento informado el uso de sus datos y que conozcan sus derechos (7, 22). En Estados Unidos una institución similar es conocida como: Health Insurance Portability and Accountability Act (HIPAA) (7).

Se requiere una estructura robusta de supervisión, regulación legal y guías locales para cada etapa; desde consentimiento para el uso de datos durante el desarrollo, hasta normas de uso y monitoreo los sistemas de aprendizaje automático (22). Particularmente la Administración de Drogas y Alimentos de los Estados Unidos (FDA) se encuentra trabajando en vías regulatorias apropiadas que establezcan estándares para la validación de modelos de aprendizaje automático (13, 14). Por ejemplo, la FDA ha comenzado un programa piloto de precertificación para evaluar software médico, basándose en cinco criterios de excelencia (22).

Adicionalmente, existen desafíos éticos, se teme que tanto médicos como futuros usuarios de sistemas de aprendizaje automático confíen ciegamente en la decisión de un modelo. Sin embargo, los modelos de automatización pretenden ser una herramienta de asistencia, se debe ser consciente que estas técnicas poseen sus limitaciones (9, 23).

• Rol del Médico

La inteligencia artificial y técnicas como el aprendizaje automático se están introduciendo gradualmente en el sistema de salud (2, 22). En otros tiempos cuando no se podía entender qué ocurría dentro de un paciente se inventaron instrumentos como estetoscopios, oftalmoscopios, técnicas de rayos X, TAC, RM (1); hoy en día que cada paciente es dueño de un sin número de exámenes, diagnósticos y tratamientos, es aún más necesario crear una herramienta que brinde apoyo al médico compensando sus limitaciones. Sin embargo, el resultado proporcionado por un software continúa siendo una sugerencia, la indicación final debe de ser emitida por un profesional calificado (13, 15).

Machine learning se perfila como un soporte para los médicos y para el sistema de salud en general, pero aún resulta necesario la mano médica en cada decisión sobre la salud de un paciente. Es por esto que distintos escritos reiteran que no se espera que aprendizaje automático reemplace los médicos, sino que sea una herramienta que ayude a mejorar el flujo de trabajo y la precisión diagnóstica (2, 13, 15, 22).

CONCLUSIONES

Machine learning es una herramienta que se encuentra ampliamente en investigación en el área de la medicina. Durante la búsqueda del material bibliográfico se encontró gran variedad de estudios que aplican modelos de

aprendizaje automático para predecir pronósticos y proveer diagnósticos. Especialmente actividades médicas que requieran trabajo repetitivo y manipulación de muchos datos son áreas prometedoras para el uso de estas tecnologías. Sin embargo, a pesar de los prometedores alcances de machine learning, aún existen grandes desafíos, entre ellos: dificultad de acceso a datos de alta calidad, conflictos éticos y legales. Hoy en día ya existen políticas

de protección de datos, no obstante, aún se está trabajando normativas minuciosas que regulen todo el proceso de desarrollo, validación y supervisión de estos sistemas. Creemos que la inteligencia artificial es una herramienta muy valiosa que en los próximos años cambiará la forma en que se práctica la medicina, por lo que profesionales en salud deben prepararse, aprender y adaptarse.

REFERENCIAS

1. Obermeyer Z, Lee T. Lost in Thought — The Limits of the Human Mind and the Future of Medicine. *New England Journal of Medicine*. 2017;377(13):1209-1211. <https://doi.org/10.1056/NEJMp1705348>
2. Gui C, Chan V. Machine learning in medicine. *University of Western Ontario Medical Journal*. 2017;86(2):76-78. <https://doi.org/10.5206/uwomj.v86i2.2060>
3. Char D, Shah N, Magnus D. Implementing Machine Learning in Health Care — Addressing Ethical Challenges. *New England Journal of Medicine*. 2018;378(11):981-983. <https://doi.org/10.1056/NEJMp1714229>
4. Yala A, Schuster T, Miles R, Barzilay R, Lehman C. A Deep Learning Model to Triage Screening Mammograms: A Simulation Study. *Radiology*. 2019;293(1). <https://doi.org/10.1148/radiol.2019182908>
5. Esteva A, Kuprel B, Novoa R, Ko J, Swetter S, Blau H et al. Dermatologist-level classification of skin cancer with deep neural networks. *Nature*. 2017;542: 115-118. <https://doi.org/10.1038/nature21056>
6. Ghorbani A, Ouyang D, Abid A, He B, Chen J, Harrington R et al. Deep learning interpretation of echocardiograms. *Npj Digit Med*. 2020;3(10). <https://doi.org/10.1038/s41746-019-0216-8>
7. Núñez Reiz A, Armengol de la Hoz M, Sánchez García M. Big Data Analysis y Machine Learning en medicina intensiva. *Medicina Intensiva [Internet]*. 2019 [Citado 25 febrero 2020];43(7):416-426. Disponible en: <https://www.medintensiva.org/es-big-data-analysis-machine-learning-articulo-S0210569118303139>
8. Chadha B. Clinical Oracle: Machine Learning in Medicine. *Berkeley Scientific Journal*;23(2). <https://escholarship.org/uc/item/1kt5029r>
9. Adamson A, Welch H. Machine Learning and the Cancer-Diagnosis Problem — No Gold Standard. *New England Journal of Medicine*. 2019;381(24):2285-2287. <https://doi.org/10.1056/NEJMp1907407>
10. Koenigkam M, Ferrei J, Tadao D, Magalhães A, Nogueira M, Mazzoncini de Azevedo P. Artificial intelligence, machine learning, computer-aided diagnosis, and radiomics: advances in imaging towards to precision medicine. *Radiol Bras*. 2019;52(6):387-396. <https://doi.org/10.1590/0100-3984.2019.0049>
11. Camacho D, Collins K, Powers R, Costello J, Collins J. Next- Generation Machine Learning for Biological Networks. *Cell*. 2018;173 (7): 1581-1592. <https://doi.org/10.1016/j.cell.2018.05.015>



12. Sidey-Gibbons J, Sidey-Gibbons C. Machine learning in medicine: a practical introduction. *BMC Med Res Metodol.* 2019;19(64). <https://doi.org/10.1186/s12874-019-0681-4>
13. Choy G, Khalilzadeh O, Michalski M, DO S, Samir A, Pianykh O et al. Current Applications and Future Impact of Machine Learning in Radiology. *Radiology.* 2018;288(2):318-328. <https://doi.org/10.1148/radiol.2018171820>
14. Deo R, Machine Learning in Medicine. *Circulation.* 2015;132(20):1920-1930. <https://doi.org/10.1161/CIRCULATIONAHA.115.001593>
15. Rajkomar A, Dean J, Kohane I. Machine Learning in Medicine. *New England Journal of Medicine.* 2019;380(14):1347-1358. <https://doi.org/10.1056/NEJMra1814259>
16. Erickson B, Korfiatis P, Akkus Z, Kline T. Machine Learning for Medical Imaging. *RadioGraphics.* 2017;37(2):505-515. <https://doi.org/10.1148/rg.2017160130>
17. Kourou K, Exarchos T, Exarchos K, Karamouzis M, Fotiadis D. Machine learning applications in cancer prognosis and prediction. *Computational and Structural Biotechnology Journal.* 2015;13:8-17. <https://doi.org/10.1016/j.csbj.2014.11.005>
18. Xu Y, Ju L, Tong J, Zhou C, Yang J. Machine Learning Algorithms for Predicting the Recurrence of Stage IV Colorectal Cancer After Tumor Resection. *Sci Rep.* 2020;10(2519). <https://doi.org/10.1038/s41598-020-59115-y>
19. Campanella G, Hanna M, Geneslaw L, Miraflor A, Krauss V, Busam K et al. Clinical-grade computational pathology using weakly supervised deep learning on whole slide images. *Nat Med.* 2019;25:1301-1309. <https://doi.org/10.1038/s41591-019-0508-1>
20. Vamathevan J, Clark D, Czodrowski P, Dunham I, Ferran E, Lee G et al. Applications of machine learning in drug discovery and development. *Nat Rev Drug Discov.* 2019;18:463-477. <https://doi.org/10.1038/s41573-019-0024-5>
21. Rifaioglu A, Atas H, Martin M, Cetin-Atalay R, Atalay V, Doğan T. Recent applications of deep learning and machine intelligence on in silico drug discovery: methods, tools and databases. *Briefings in Bioinformatics.* 2018;20(5):1878-1912. <https://doi.org/10.1093/bib/bby061>
22. Vayena E, Blasimme A, Cohen I. Machine learning in medicine: Addressing ethical challenges. *PLoS Med.* 2018; 15(11): e1002689. <https://doi.org/10.1371/journal.pmed.1002689>
23. Greene J, Lea A. Digital Futures Past — The Long Arc of Big Data in Medicine. *New England Journal of Medicine.* 2019;381(5):480-485. <https://doi.org/10.1056/NEJMmss1817674>