

Uso de la inteligencia artificial para el tratamiento del trauma craneoencefálico en niños: revisión de alcance

Use of Artificial Intelligence in traumatic brain injury in children: scoping review

Rogelio Saldaña-Rimarachin^{1, a} , Salvador Segura-Surco^{1, a} ,
Carlos Salazar-Ordoñez^{1, b, c} , Daniel Guillén-Pinto^{1, d, e} 

RESUMEN

La inteligencia artificial (IA) constituye una herramienta significativa en la práctica clínica. El trauma craneoencefálico (TCE) representa una de las principales causas de morbimortalidad infantil, por lo que se espera que la IA mejore los resultados clínicos en esta población. El objetivo de esta revisión fue analizar la literatura existente sobre el uso de IA en el manejo del TCE pediátrico. Se realizó una búsqueda en bases de datos (PubMed/MEDLINE, PMC, Cochrane, Embase, Web of Science, IEEE Xplore, Scopus, SciELO y LILACS). Se incluyeron estudios publicados entre enero de 2015 y junio de 2024 que aplicaron modelos de *machine learning* (ML) para predecir diagnóstico, tratamiento y pronóstico. Se identificaron 1727 artículos, de los cuales se seleccionaron 31, la mayoría publicados entre 2021 y 2024, predominando la procedencia de Estados Unidos (51,6 %) y países asiáticos (29,0 %). Los modelos de aprendizaje supervisado, como bosque aleatorio (RF) y máquina de soporte vectorial (SVM), fueron los más utilizados (51,6 %), seguidos del aprendizaje profundo (32,2 %), donde destacaron las redes neuronales artificiales (ANN). Los modelos de ML se aplicaron principalmente en diagnóstico (64,5 %) y pronóstico (38,7 %). En diagnóstico, se reportó un área bajo la curva (AUC) entre 0,78 y 0,99, destacando las ANN (exactitud de 99 %; precisión de 100 %); mientras que, en pronóstico, se reportó un AUC entre 0,71 y 0,99, sobresaliendo la SVM (exactitud 94 %; precisión 99 %). Se concluye que existe un interés creciente en el uso de la IA para el diagnóstico y pronóstico del TCE pediátrico, con énfasis en modelos de aprendizaje profundo que muestran un rendimiento superior a las herramientas clínicas tradicionales.

Citar como:
Saldaña-Rimarachin R, Segura-Surco S, Salazar-Ordoñez C, Guillén-Pinto D. Uso de la inteligencia artificial para el tratamiento del trauma craneoencefálico en niños: revisión de alcance. Rev Neuropsiquiatr. 2025; 88(4): 388-403. DOI: 10.20453/rnp.v88i4.6389

Recibido: 28-03-2025

Aceptado: 13-09-2025

En línea: 18-12-2025

Correspondencia:

Rogelio Saldaña-Rimarachin
✉ rogelio.saldana@upch.pe



Artículo de acceso abierto, distribuido bajo los términos de la Licencia Creative Commons Atribución 4.0 Internacional.

© Los autores

© Revista de Neuro-Psiquiatría

Palabras clave: *machine learning; inteligencia artificial; trauma craneoencefálico; niños; revisión de alcance.*

¹ Universidad Peruana Cayetano Heredia, Departamento Académico de Clínicas Médicas. Lima, Perú.

^a Médico cirujano.

^b Magíster en Epidemiología Clínica.

^c Médico Internista.

^d Doctor en Medicina.

^e Neurólogo Pediatra.

ABSTRACT

Artificial Intelligence (AI) constitutes a valuable tool in clinical practice. Traumatic brain injury (TBI) in children represents one of the main causes of infant morbidity and mortality. The use of AI is expected to improve clinical outcomes in this population. Objective: To explore and analyze the existing literature on the use of AI in the management of Traumatic brain injury in the pediatric population. We searched PubMed/MEDLINE, PMC, Cochrane, Embase, Web of Science, IEEE Xplore, Scopus, Scielo and Lilacs databases. We included studies that applied Machine Learning (ML) models to predict diagnosis, treatment and prognosis, published between January 2015 and first semester 2024. A total of 1727 articles were identified, of which 31 were selected. The majority were published between 2021 and 2024, from the United States (51,6%) and Asian countries (29%). Supervised learning models, Random Forest and Support Vector Machine (SVM) were the most used (51,6%), followed by deep learning (32,2%), highlighting artificial neural networks (ANN). ML models were applied in diagnosis (64,5%) and prognosis (38,7%). In terms of performance, diagnostic models reported an AUC between 0,78-0,99 and ANN stood out (accuracy 99%, precision 100%); in prognosis, they reported an AUC of 0,71-0,99 and SVM stood out (accuracy 94%, precision 99%). There is an interest in the use of AI in the diagnosis and prognosis of pediatric TBI, highlighting deep learning models, which would outperform traditionally used clinical tools.

Keywords: machine learning; Artificial Intelligence; traumatic brain injury; children; scoping review.

INTRODUCCIÓN

El trauma craneoencefálico (TCE) se define como una disrupción en la función cerebral u otra evidencia de patología cerebral causada por una fuerza externa, que representa una de las principales causas de interrupción del desarrollo normal del niño (1). Según la *Lancet Neurology Commission*, se estima que entre 50 y 60 millones de personas sufren de TCE anualmente y que, para el 2030, seguirá siendo una de las tres primeras causas de muerte y discapacidad (2). En la población pediátrica, una revisión de estudios en cinco continentes, que abarca el período 1995-2015, reportó que la incidencia mundial oscila entre 47 y 280 casos por cada 100 000 habitantes (1).

Las repercusiones clínicas y funcionales de esta patología comprometen el estado de salud a corto y largo plazo. Los desenlaces varían según la gravedad de la lesión. El TCE leve puede generar sintomatología persistente por más de tres meses, lo que prolonga el tiempo de recuperación (3). En casos de TCE moderado a severo, se describen déficits cognitivos, emocionales y conductuales que afectan el desarrollo social (4, 5). El TCE severo, por su parte, presenta una mortalidad anual del 56,6 % y conlleva discapacidad severa en el 71,6 % de los casos (6).

En el Perú, Agramonte (7) reportó que el TCE fue la primera causa de muerte por accidentes en el grupo etario de 1 a 14 años. Asimismo, un estudio en un hospital nacional de Lima (2004-2011) identificó entre 12 y 69 de casos de TCE pediátrico por año; de estos, el 15,8 % ingresó a la unidad de cuidados intensivos y el 14,2 % requirió manejo neuroquirúrgico (8).

En este contexto, la inteligencia artificial (IA), definida como un sistema capaz de simular procesos cognitivos para la resolución de problemas, se presenta como una herramienta de apoyo en el manejo del TCE (9). La IA permite detectar características clínicas asociadas con un mayor riesgo de enfermedad, clasificar a los pacientes según el grado de severidad (10) y analizar imágenes tomográficas para la identificación de lesiones (11). De igual modo, en el campo quirúrgico, sus aplicaciones facilitan la delimitación precisa de las fracturas (12, 13).

En el abordaje de TCE, los modelos de IA han optimizado la estimación del pronóstico, con un rendimiento superior a herramientas clínicas tradicionales como la Escala de Coma de Glasgow (ECG) y la Escala Tomográfica de Marshall (14). Estos modelos permiten identificar pacientes con riesgo de una recuperación prolongada (15). En casos de

discapacidad severa, se han desarrollado sistemas que recolectan datos en tiempo real durante la terapia física para evaluar la funcionalidad del niño y ajustar los niveles de entrenamiento en ejercicios asistidos por exoesqueletos (16).

Actualmente, la literatura carece de una revisión detallada que evalúe la aplicación y el rendimiento de modelos de IA en este grupo poblacional, lo que limita la toma de decisiones basadas en evidencia (17). Por consiguiente, se presenta una revisión de alcance que explora la producción científica existente sobre el uso de IA en el TCE pediátrico, examinando su evolución temporal, los tipos de IA empleados y su utilidad clínica.

MATERIALES Y MÉTODOS

Esta revisión de alcance se realizó conforme a la metodología propuesta en el *JBI Manual for Evidence Synthesis* (18) y la guía *PRISMA-ScR* (19).

Como criterios de inclusión se consideraron estudios observacionales (prospectivos o retrospectivos), ensayos clínicos controlados, revisiones sistemáticas y metaanálisis; estudios en niños y adolescentes

(menores de 18 años); estudios sobre TCE que emplearon modelos de IA; estudios que reportaron el rendimiento de la IA mediante métricas estadísticas (sensibilidad, especificidad, área bajo la curva, puntuación F1 o precisión de la predicción); estudios publicados desde enero de 2015 hasta el primer semestre de 2024; estudios realizados en cualquier región geográfica; y estudios en cualquier idioma. Por otro lado, se excluyeron los estudios no publicados (artículos de conferencias y proyectos de tesis cargados en línea); y los estudios de revisión narrativa, carta a editores y comentarios.

La búsqueda de información se limitó a estudios publicados a partir de enero de 2015, fecha seleccionada para abarcar la era moderna de la IA y el crecimiento exponencial de su literatura médica (20). Se consultaron las bases de datos PubMed/MEDLINE, PubMed Central, Cochrane Library, Embase, Web of Science, Scopus, IEEE Xplore, SciELO y LILACS. Se emplearon términos MeSH y palabras clave, como “traumatic brain injury”, “craniocerebral trauma”, “artificial intelligence” y “child”, según los elementos contexto, condición y población (CoCoPo) (tabla 1).

Tabla 1. Descripción de los elementos CoCoPo (Co: contexto; Co: condición; Po: población).

Pregunta de investigación	Contexto	Condición	Población
¿Cómo ha evolucionado la inteligencia artificial en el manejo de trauma encefalocraneano pediátrico en relación con su implementación en diversos escenarios clínicos y geográficos?	Estudios en diversos escenarios clínicos y geográficos con un enfoque en la evolución o implementación de inteligencia artificial en diferentes países del mundo.	Aplicación de modelos de <i>machine learning</i> durante el diagnóstico, tratamiento o pronóstico.	Población pediátrica con trauma craneoencefálico. Los datos utilizados en la inteligencia artificial deben incluir datos humanos reales.

La estrategia se optimizó con operadores booleanos específicos para cada base de datos, utilizando los siguientes términos en inglés: “traumatic brain injur*” OR “mild traumatic brain injur*” OR “brain contusion*” OR “cerebellar contusion*” OR “cerebral concussion*” OR “cerebral contusion*” OR “cerebral trauma” OR “neurosurgery” OR “glasgow coma scale” OR “head impact*”, los cuales se combinaron con “machine learning” OR “deep learning” OR “clinical decision support” OR “prediction tool” OR “prediction model*” OR “random forest” OR “gradient boosting” OR “decision tree*” OR “artificial intelligence” OR “neural network*” OR “cnn” OR “gradient boosting machine” OR “risk prediction”. Además, se incluyeron términos relacionados con la población de interés:

“neonate*” OR “newborn*” OR “infant*” OR “baby” OR “babies” OR “toddler*” OR “child*” OR “adolescen*” OR “teen*” OR “youth*”¹.

Dos autores realizaron de forma independiente la selección inicial por título y resumen mediante el software Rayyan (21) como herramienta para organizar, clasificar y filtrar los estudios. Se descartaron aquellos que no cumplieron con los criterios de elegibilidad. Posteriormente, ambos autores evaluaron los textos

¹ Revisar estrategia de búsqueda completa en: https://docs.google.com/document/d/1TRpxB2hV3GRb7itC_o-hhNrrkzKWfHL/edit?usp=sharing&ouid=116717964450613896562&rtpof=true&sd=true

completos de los artículos potencialmente relevantes a través de un formulario predefinido y registraron los motivos de exclusión. Las discrepancias se resolvieron por consenso, sin la necesidad de un tercer revisor.

La extracción fue realizada por dos revisores en paralelo que utilizaron una plantilla estandarizada. Se recopiló información bibliométrica, característica del estudio, detalles del modelo de *machine learning* (ML) y resultados. Se incluyeron campos adicionales para registrar información complementaria como población, diseño del estudio y tamaño de muestra, tipo de ML, objetivo principal, área de aplicación (diagnóstico, tratamiento, pronóstico), comparador, métricas de rendimiento, significancia del impacto, validación del modelo y limitaciones reportadas. Los datos se gestionaron en Microsoft Excel.

La síntesis se realizó con un enfoque narrativo, y se presentó mediante tablas y gráficos², lo que permitió analizar el desempeño, la validación y la implementación de la IA en diferentes escenarios, así como realizar una comparativa temporal y geográfica. Debido a la naturaleza observacional descriptiva de esta revisión, no se evaluó el riesgo de sesgo de los artículos incluidos.

El proyecto fue registrado por la Dirección Universitaria de Asuntos Regulatorios de la Universidad Peruana Cayetano Heredia. No requirió evaluación ética en humanos ni animales, por lo que se autorizó su ejecución.

RESULTADOS

La búsqueda bibliográfica se realizó en septiembre de 2024 en las bases de datos PubMed/MEDLINE (n = 50), PubMed Central (n = 22), Cochrane Library (n = 201), Embase (n = 710), Web of Science (n = 95), Scopus (n = 534), IEEE Xplore (n = 112), SciELO (n = 0), LILACS (n = 3), identificando un total de 1727 artículos. Se eliminaron 499 estudios duplicados y 78 estudios mediante el software Rayyan, quedando 1150. Estos se evaluaron por título y resumen, excluyendo 1044. De los 106 artículos restantes evaluados a texto completo, se seleccionaron 31 para la revisión final.

El proceso de selección se detalla en el diagrama PRISMA 2020 (figura 1).

De los 31 estudios incluidos (15, 22-51), el más antiguo se publicó en 2015, mientras que el 60 % se difundió entre 2021 y 2024. En cuanto a la distribución geográfica, la mayoría se llevó a cabo en América del Norte (58,0 %) y Asia (29,0 %). Respecto al diseño, el 70,9 % (n = 22) correspondió a cohortes (15, 22-28, 30, 33, 34, 36, 38, 40, 44-51); el 22,5 % (n = 7), a casos y controles (29, 31, 35, 39, 41, 42, 45); el 3,3 % (n = 1), a estudios correlacionales (37); y otro 3,3 % (n = 1), a simulación cuasiexperimental (32). No se hallaron ensayos clínicos ni revisiones sistemáticas. Asimismo, el 74,1 % (n = 23) fueron retrospectivos (15, 22-28, 31-33, 36, 38-42, 44, 46-50); el 19,3 % (n = 6), prospectivos (29, 30, 34, 43, 45, 51); y el 6,6 % (n = 2), transversales (35, 37).

Con relación al tamaño muestral, los estudios incluyeron entre 24 y 885 100 pacientes o registros derivados (datos clínicos, de laboratorio, informes e imágenes radiológicas, y muestras biológicas), con una mediana de 289 pacientes. Sobre el grupo, el 90 % incluyó participantes en edad preescolar y escolar. Respecto a la severidad del TCE, el 48,4 % (n = 15) evaluó exclusivamente TCE leve (15, 24, 28-30, 32-37, 43, 45, 46, 49); el 9,6 % (n = 3), TCE severo (25, 40, 50); y el 13 % (n = 5), todos los grados (leve, moderado y severo) (22, 23, 38, 44, 51). El 25,8 % (n = 7) no especificó la severidad del TCE (26, 27, 39, 41, 42, 47, 48); y no se registraron estudios que evalúen a pacientes solo con TCE moderado.

En cuanto a las áreas de aplicación de la IA en TCE pediátrico, la investigación se centró en el diagnóstico, abordado en el 64,5 % (n = 20) de los estudios (22, 24, 27, 28, 29, 31, 32, 33, 35, 36, 37, 39, 41, 42, 43, 45, 47, 48, 49, 51). En menor medida, se evaluó el pronóstico (38,7 %; n = 12) (15, 23, 25, 26, 30, 34, 38, 40, 43, 44, 46, 50), considerando desenlaces clínicos como mortalidad, discapacidad a largo plazo y estancia hospitalaria. Cabe destacar que también se encontraron estudios que abordaron ambas áreas de aplicación (43); y no se hallaron estudios relacionados con el tratamiento.

²Revisar síntesis completa en: <https://docs.google.com/spreadsheets/d/1-I-XlhCaFQm8yfmF6F0c8FjkCRuQTP3N/edit?usp=sharing&ouid=116717964450613896562&rtpof=true&sd=true>

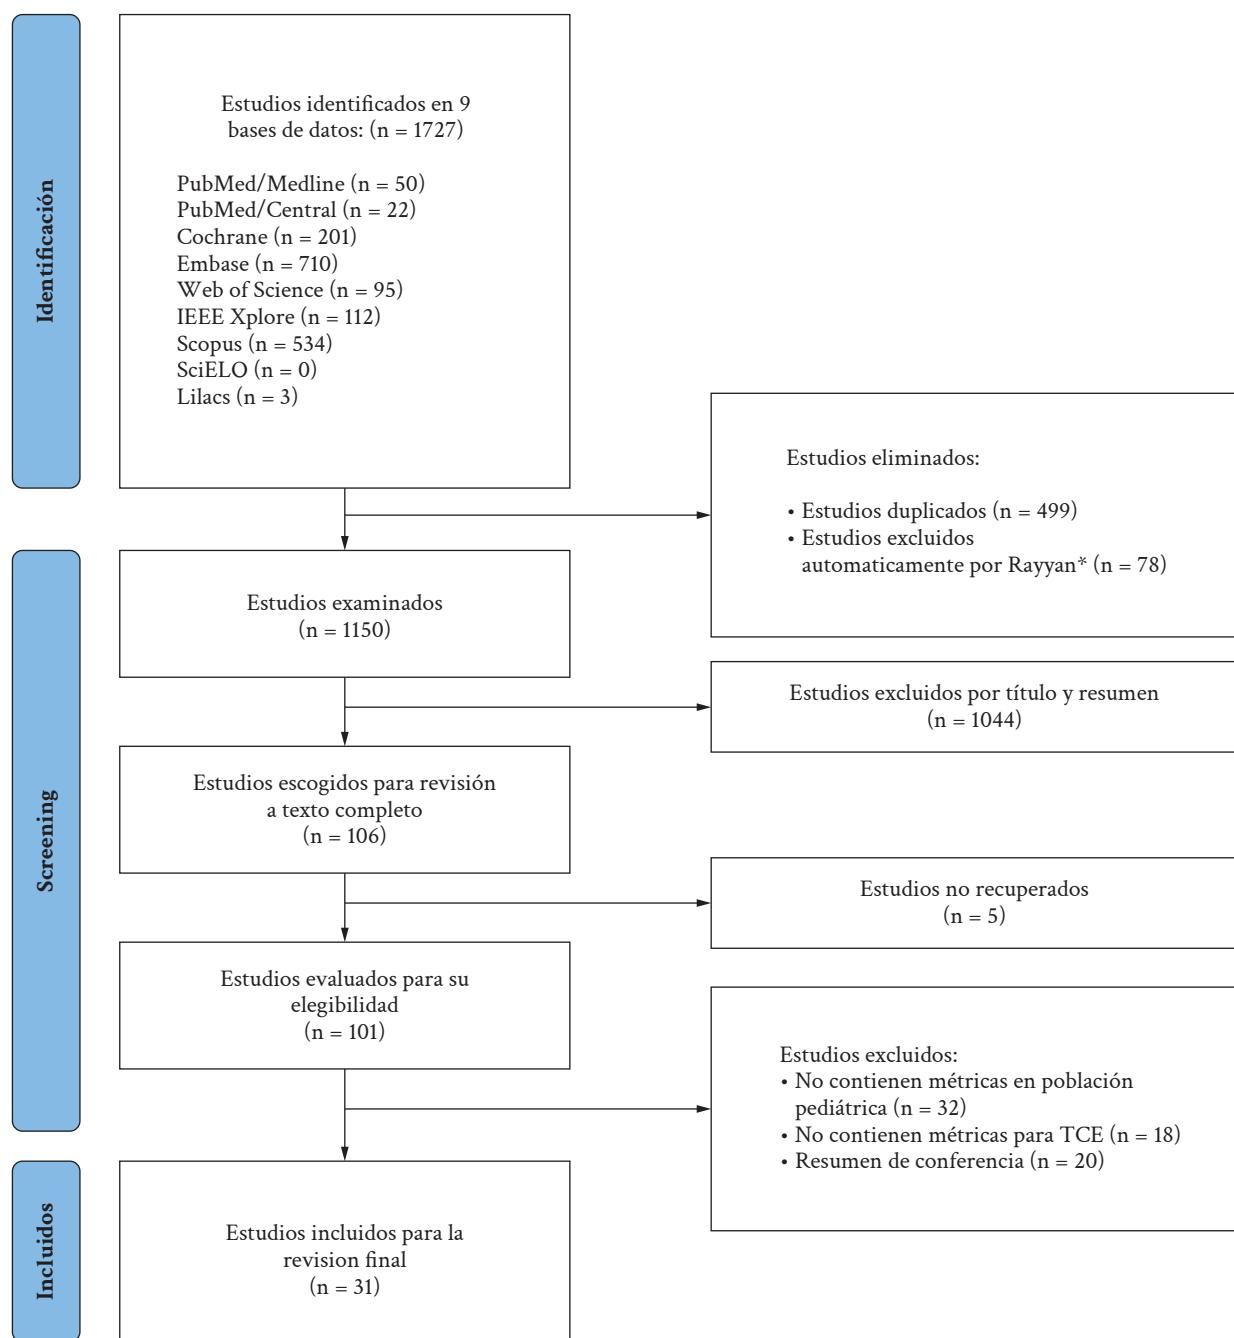
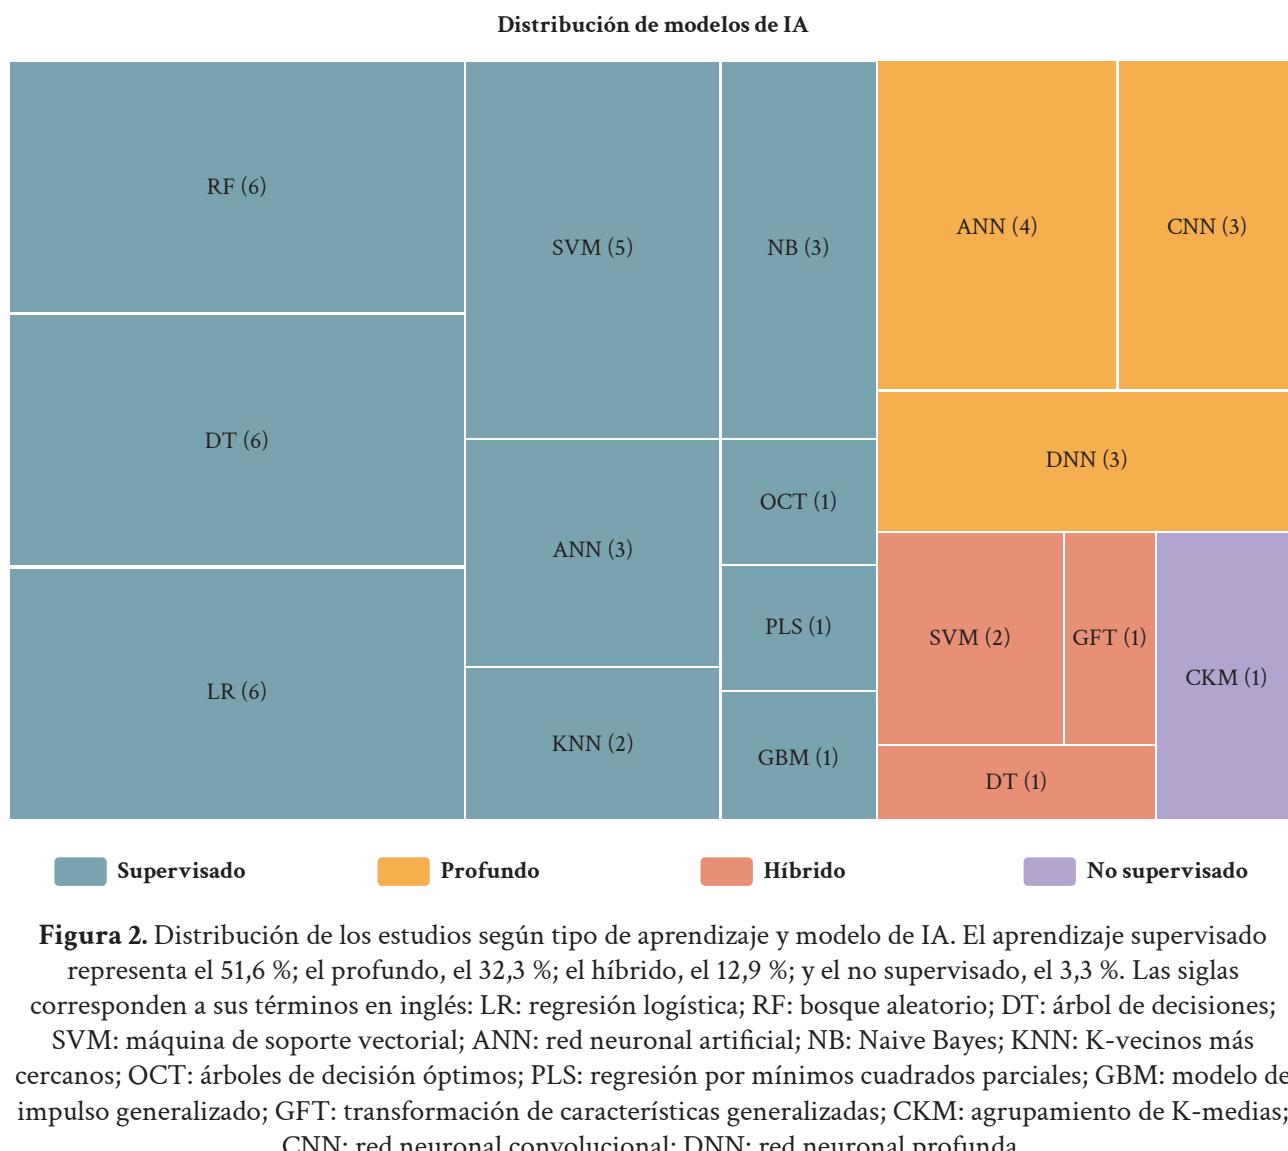


Figura 1. Diagrama de flujo PRISMA del proceso de selección. TCE: trauma craneoencefálico. * Se excluyeron automáticamente registros cuyo título o resumen contenían palabras clave como *animals*, *conference abstract*, *case report*, *retracted publication*, *protocol*, *CONF*, dado que no cumplían con los criterios de elegibilidad.

Clasificación de los estudios según tipos de *machine learning*

En esta revisión se identificaron cuatro tipos de aprendizaje: supervisado, no supervisado, profundo e híbrido. Los modelos se agruparon según el tipo de aprendizaje, tal como se muestra en la figura 2.



Diagnóstico

Al analizar los modelos de ML según su desempeño, se evaluaron los valores mínimos y máximos reportados. El área bajo la curva (AUC) osciló entre 0,78 (35) y 0,99 (47), con una mediana de 92 %. La sensibilidad varió entre 4,8 % (33) y 99,7 % (47), con una mediana

de 89,7 %, mientras que la especificidad se situó entre 60,4 % (24) y 100 % (33), con una mediana de 91,6 %. En términos de precisión, los valores fluctuaron entre 1,8 % (32) y 100 % (24), con una mediana de 84,6 %; por su parte, la exactitud osciló entre 86,3 % (27) y 99,9 % (24), con una mediana de 97,2 % (figura 3).

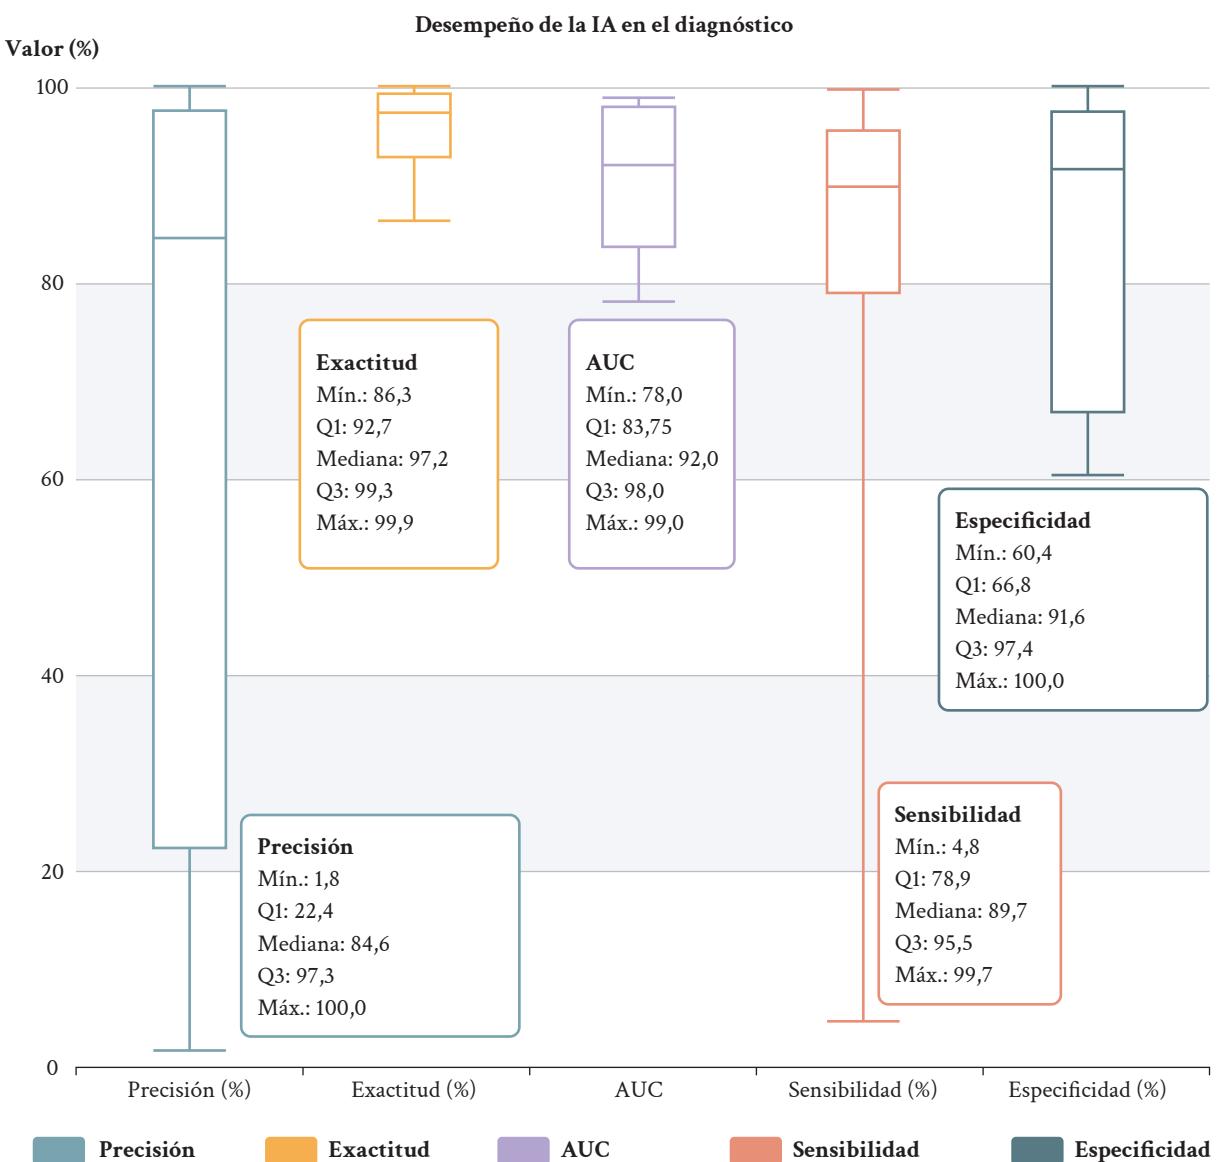


Figura 3. Diagrama de caja (*box plot*) del desempeño de los modelos en diagnóstico. Resumen de los valores obtenidos para cada métrica. Q1: primer cuartil; Q3: tercer cuartil; AUC: área bajo la curva.

Al comparar a los modelos según su categoría de aprendizaje, el rango de AUC para los supervisores osciló entre 0,78 (35) y 0,98 (31). El valor más alto correspondió a un modelo de redes neuronales artificiales (ANN) diseñado para identificar pacientes con TCE moderado a severo (31).

Por su parte, los modelos de aprendizaje profundo presentaron un AUC de 0,79 (33) a 0,99 (47); el

valor máximo correspondió a un modelo de ANN, cuyo objetivo principal fue identificar pacientes con riesgo de desarrollar TCE clínicamente relevante (44). En cuanto a los modelos híbridos, solo dos de los tres estudios reportaron AUC, siendo que el mayor valor (0,98) fue obtenido por un modelo de máquina de soporte vectorial y eliminación recursiva de características (SVM-RFE) aplicado a la interpretación de magnetoencefalografías (43) (tabla 2).

Tabla 2. Desempeño de los modelos de IA utilizados en el diagnóstico del TCE pediátrico.

Denominación del estudio	Año	Tipo de aprendizaje	Objetivo diagnóstico	Modelos de IA	Precisión (%)	Exactitud (%)	AUC	Sensibilidad (%)	Especificidad (%)
Ellethy et al. (24)	2021	Profundo	Necesidad de TC	ANN	100	99,9	-	97,7	100
Farzaneh et al. (27)	2022	Supervisado	Necesidad de TC	RF	3,9	86,3	0,92	84	86
Rowe et al. (28)	2020	Supervisado	Necesidad de TC	RF	-	-	-	-	-
Bahado-Singh et al. (29)	2020	Profundo	Identificación de TCE por marcador	ANN	-	-	0,98	97	95
Chong et al. (31)	2015	Supervisado	Necesidad de TC	ANN	90,2	-	0,98	94,9	97,4
Heo et al. (32)	2022	Profundo	Necesidad de TC	DNN	1,8	-	0,92	95	67,2
Zou et al. (33)	2023	Profundo	Necesidad de TC	DNN	-	91,5	0,79	4,8	100
Zahid et al. (35)	2020	Supervisado	Identificación de TCE por marcador	RL	78,1	-	0,78	75	64,7
Bertsimas et al. (36)	2019	Supervisado	Necesidad de TC	DT	2,7	-	-	94,5	65,6
Ren et al. (39)	2023	Supervisado	Alteración de redes neuronales	NB	-	99,8	-	87,9	-
Choi et al. (41)	2022	Profundo	Identificación de fractura	CNN	-	-	0,87	78,9	91,3
Jeong et al. (42)	2023	Profundo	Identificación de fractura	CNN	-	-	-	37,5	62,5
Huang et al. (43)	2023	Híbrido	Identificación de TCE por marcador	SVM-RFE	-	-	0,98	95,5	90,2
Tunthanathip et al. (23)	2021	Supervisado	Necesidad de TC	RF	79	-	0,80	34	95
Hale et al. (47)	2019	Profundo	Necesidad de TC	ANN	98,19	97,9	0,99	99,7	60,4
Yadav et al. (48)	2016	Híbrido	Necesidad de TC	DT-NLP	-	-	-	89,7	91,9
Miyagawa et al. (49)	2023	Supervisado	Necesidad de TC	DT	95	-	0,85	-	-
Yang et al. (51)	2023	Profundo	Identificación de TCE por video	CNN	99	96,6	-	96,1	97,7

La tabla detalla los tipos de aprendizaje utilizados en los estudios (supervisado, aprendizaje profundo, híbrido y no supervisado) junto con los modelos de IA específicos. Las siglas corresponden a sus términos en inglés: ANN: red neuronal artificial; RF: bosque aleatorio; DNN: red neuronal profunda; RL: regresión logística; SVM: máquina de soporte vectorial; RFE: eliminación recursiva de características; PCA: análisis de componentes principales; DT: árbol de decisión; NB: Naive Bayes; CNN: red neuronal convolucional; NLP: procesamiento de lenguaje natural. TCE: trauma craneoencefálico; TC: tomografía computarizada.

Los valores resaltados en verde indican un desempeño superior, mientras que los destacados en rojo representan el menor valor registrado de cada métrica de desempeño.

Pronóstico

Al analizar los modelos de ML según su desempeño, se evaluó el valor mínimo y máximo encontrado. El AUC osciló entre 0,71 (38) y 0,99 (47), con una mediana de 0,87. La sensibilidad varió entre 59,4 % (15) y 100 % (26), con una mediana de 87,3 %,

mientras que la especificidad fluctuó entre 60 % (23) y 99 % (50), con una mediana de 78,7 %. En términos de precisión, los valores fluctuaron entre 35,2 % (38) y 99 % (23), con una mediana de 64,6 %; por su parte, la exactitud osciló entre 0,27 % (44) y 94 % (23), con una mediana de 87 % (figura 4).

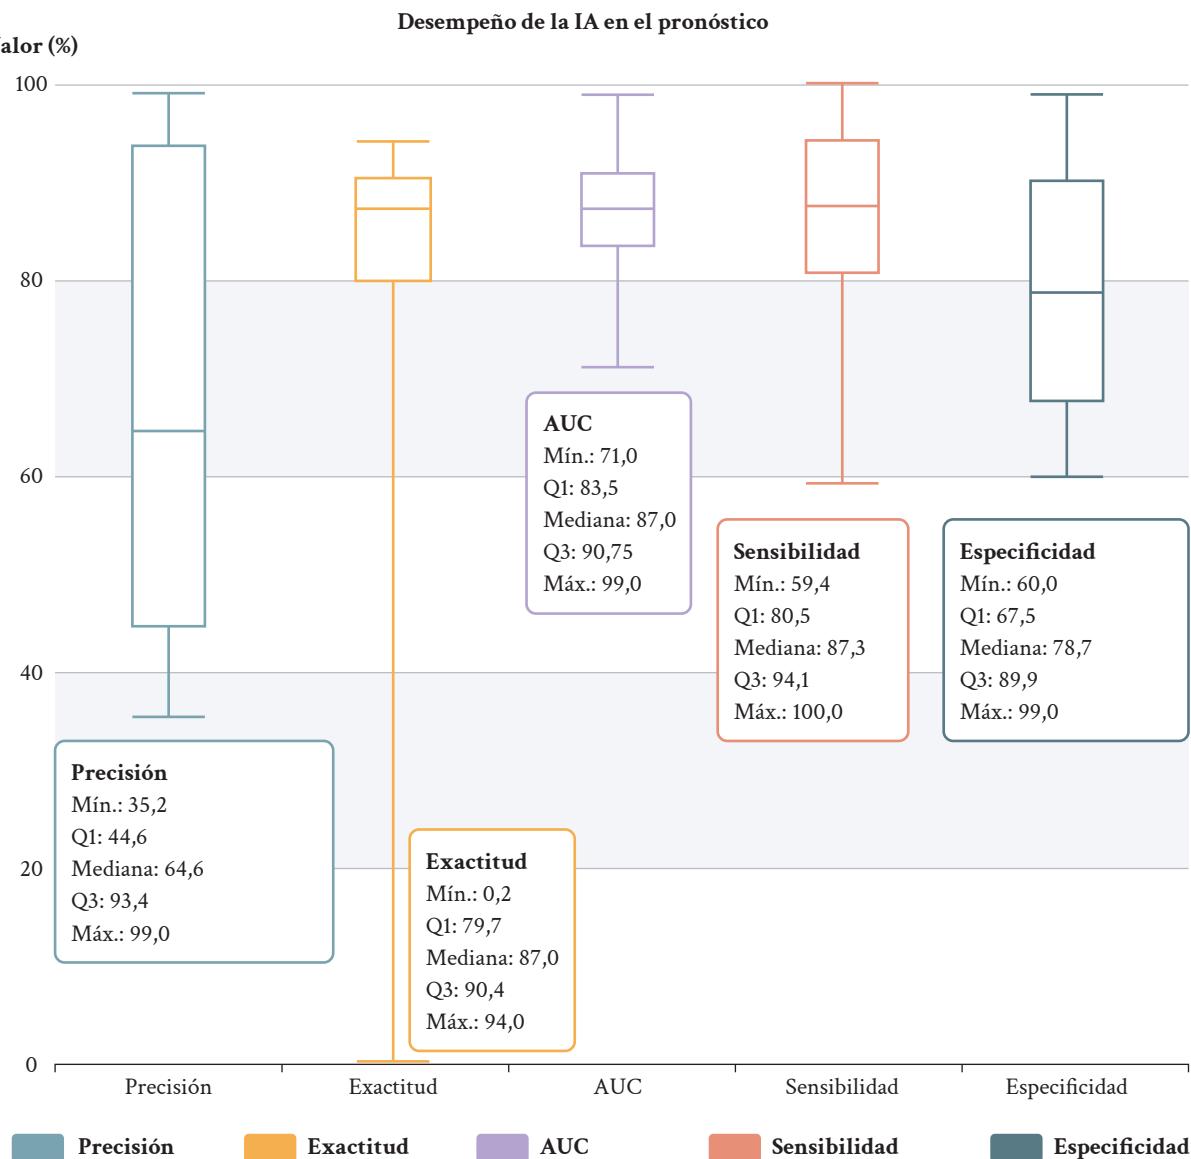


Figura 4. Diagrama de caja (box plot) del desempeño de los modelos en pronóstico. Resumen de los valores obtenidos para cada métrica de desempeño. Q1: primer cuartil; Q3: tercer cuartil; AUC: área bajo la curva.

Al comparar los modelos según su categoría de aprendizaje, aquellos basados en aprendizaje profundo mostraron un rango de exactitud entre 0,27 % (44) y 91,9 % (26). Por otro lado, los modelos supervisados presentaron un rango de precisión de 35,2 % (38) a 99 % (23). Finalmente, en los estudios de modelos

híbridos, se reportó una exactitud de 62,3 % (15) en un sistema diseñado para predecir la recuperación de posconmoción en adolescentes mediante imágenes de tensor de difusión (DTI) obtenidas por resonancia magnética (15) (tabla 3).

Tabla 3. Desempeño de los modelos de IA utilizados en el pronóstico del TCE pediátrico.

Denominación del estudio	Año	Tipo de aprendizaje	Desenlace evaluado	Modelos de IA	Precisión (%)	Exactitud (%)	AUC	Sensibilidad (%)	Especificidad (%)
Daley et al. (25)	2022	Supervisado	Mortalidad	RF	-	82	0,91	-	-
Shahi et al. (26)	2021	Profundo	Mortalidad	ANN	-	91,9	0,96	100	91,8
		Profundo	Falla de NOM	ANN	-	83,8	0,88	91,7	83,5
		Profundo	MT	ANN	-	90,5	0,90	88,9	90,5
		Profundo	Éxito NOM sin intervención	ANN	-	90,3	0,89	90,4	88,2
Fedorchak et al. (30)	2021	Supervisado	Recuperación	RF	-	-	0,86	-	-
Iyer et al. (34)	2019	Supervisado	Recuperación	SVM	-	79	0,86	82	75
Fleck et al. (15)	2021	Híbrido	Recuperación	GFT	-	62,3	-	59,4	65,1
Kim et al. (38)	2021	Supervisado	Desfavorabilidad	DT	50	-	0,83	83,33	78,26
		Supervisado	Necesidad de cirugía	DT	42,86	-	0,71	85,71	63,64
					35,29	-	0,91	100	78,85
Greenan et al. (40)	2019	Supervisado	Mortalidad	DT	79,31	-	0,83	76,6	78,57
		Supervisado	Recuperación	DT	-	90,2	-	68,4	93,6
		Supervisado	Desfavorabilidad	SVM	99	94	0,78	95	60
Hale et al. (44)	2018	Supervisado	Desfavorabilidad	ANN	98,19	0,27	0,99	99	60,4
Maddux et al. (46)	2021	Profundo	Desfavorabilidad	CK-M	-	-	0,85	-	-
Kayhanian et al. (50)	2019	No supervisado	Morbilidad	SVM	-	-	-	80	99

La tabla detalla los tipos de aprendizaje utilizados en los estudios (supervisado, aprendizaje profundo, híbrido y no supervisado) junto con los modelos de IA específicos. Las siglas corresponden a sus términos en inglés: RF: bosque aleatorio; ANN: red neuronal artificial; SVM: máquina de soporte vectorial; DT: árbol de decisiones; GFT: transformación de características generalizadas; CKM: agrupamiento de K-medias. MT: transfusión masiva; TCE: trauma craneoencefálico; TC: tomografía computarizada. Los desenlaces clínicos evaluados incluyen mortalidad, morbilidad, recuperación, desfavorabilidad, necesidad de cirugía y fracaso del manejo no operatorio (NOM, por sus siglas en inglés Non-Operative Management). Los valores resaltados en verde indican un desempeño superior, mientras que los destacados en rojo representan el menor valor registrado de cada métrica de desempeño.

Validación

Se identificaron tres tipos de validación: interna, externa y cruzada. De los 31 estudios incluidos, el 25,8 % (n = 8) (15, 27, 36, 42, 47, 48, 49, 51) utilizó validación interna; el 54,8 % (n = 17) (22-26, 30, 31, 32, 35, 36, 37, 40, 45, 46, 47, 48, 50), validación cruzada; y el 9,6 % (n = 3) (32, 40, 41), validación externa. El 9,6 % (n = 3) (31, 37, 39) no especificó el tipo de validación empleado.

Datos de entrenamiento

Los datos empleados para entrenar y probar los modelos se clasificaron en datos clínicos (demográficos, laboratoriales, interpretación de imágenes),

imágenes, videos, marcadores y aquellos que usaron datos combinados (datos clínicos más imágenes o marcadores). Los datos clínicos fueron los más utilizados, presentes en el 58 % (n = 18) de los estudios (22-28, 31, 32, 33, 36, 40, 44, 46-50). Los estudios que utilizaron imágenes como fuente exclusiva se reportaron en el 16 % (n = 5) (34, 39, 41, 42, 45); solo uno utilizó como biomarcador el *edge density imaging* (45). Por su parte, el análisis de video se utilizó en el 6,5 % (n = 2) (35, 51). Además, un 19,5 % (n = 6) (15, 29, 30, 37, 38, 43) empleó datos combinados. Aquellos que integraron datos clínicos con biomarcadores utilizaron información epigenética, como cambios en la metilación del ADN (29) y ARN no codificante (30).

DISCUSIÓN

El interés de la comunidad médica en el uso de la IA se ha incrementado notablemente en los últimos años; más del 60 % de los estudios encontrados en esta revisión corresponden a los últimos 5 años. Esta tendencia al alza podría relacionarse con la mayor accesibilidad a *hardware* avanzado y el incremento de datos disponibles para el entrenamiento de algoritmos (52). Además, la pandemia de la COVID-19 parece haber actuado como un catalizador para la adopción de la IA y la automatización de procesos en entornos de alta demanda (53).

La distribución geográfica revela un predominio de Estados Unidos (51,6 %), mientras que en regiones como América Latina y África la producción es prácticamente nula. Este desequilibrio refleja disparidades globales en el desarrollo y la aplicación de estas tecnologías, influenciadas por recursos económicos y políticos. Por otro lado, se observa un crecimiento en países asiáticos (Corea del Sur, China y Japón) a partir de 2021, impulsado por políticas estratégicas de innovación (54). En contraste, otros países como Reino Unido, Australia y Turquía presentan una participación limitada, pese a su capacidad tecnológica y de recursos. Las colaboraciones internacionales podrían fomentar la equidad en la implementación de tecnologías avanzadas en salud global. Hallazgos similares en la distribución temporal y geográfica han sido descritos en otras revisiones (55, 56).

En el ámbito de la salud, los modelos de aprendizaje supervisado de ML son los más utilizados en diagnóstico y pronóstico (57). No obstante, las ventajas del aprendizaje profundo han posicionado a estos modelos como objeto de interés en publicaciones recientes (58). En esta revisión, aunque el aprendizaje profundo ocupó el segundo lugar de frecuencia, demostró mayoritariamente un rendimiento superior al resto, lo cual ha incentivado una tendencia creciente hacia su investigación (43).

Se identificaron modelos diagnósticos con alto rendimiento para predecir la necesidad de una TC craneal en niños con TCE leve, con resultados superiores a las reglas de decisión clínica tradicionales. Los modelos basados en aprendizaje profundo presentaron exactitud y precisión cercana al 100 % (24, 44). Asimismo, se reportaron niveles de sensibilidad superiores al 95 % (28, 36, 51), cifras mayores a las de escalas tradicionales como PECARN (83,8 %) o CHALICE (90 %) (59). De igual modo, se hallaron valores de AUC de 0,98 (31) y 0,99 (44), superiores

a los de PECARN (0,81), CHALICE (0,84) y CATCH (0,67) (60).

Los modelos pronósticos de aprendizaje profundo, como las ANN, alcanzaron una exactitud mayor al 90 % en la predicción de mortalidad, transfusión masiva y éxito del manejo no quirúrgico. Esto representa una mejora significativa frente a métodos tradicionales, como el criterio ABCD para predicción de transfusión masiva (exactitud de 77,6 %) (26). Así también, modelos de aprendizaje supervisado, como el SVM, alcanzaron una precisión del 99 % y exactitud del 94 % en la predicción de resultados desfavorables en pacientes con TCE leve, moderado y severo (23), superando a otros modelos supervisados (ANN, bosque aleatorio [RF], Naive Bayes [NB] y K-vecinos más cercanos [KNN]) y a métodos tradicionales como la regresión logística (LR), que obtuvo una precisión de 98% y exactitud del 93%.

En un estudio, se encontró que el modelo no supervisado de agrupamiento de K-medias (CK-M) permitió evaluar el uso de recursos posteriores al alta, generó fenotipos e identificó a los pacientes con una alta carga de morbilidad, reportando un AUC de 0,85; sin embargo, no se comparó su desempeño con métodos tradicionales, como los basados en la Escala de Coma de Glasgow (46). Estos han demostrado limitaciones en la predicción de necesidades a largo plazo en población adulta (10). En este sentido, el modelo CK-M representa una herramienta potencial para la estratificación de pacientes, aunque su ventaja sobre los modelos tradicionales aún requiere validación.

A pesar de los resultados favorables, la aplicación de ML presenta brechas que limitan su implementación clínica. No se identificaron estudios en América Latina ni en África, regiones que enfrentan barreras como la falta de infraestructura tecnológica y deficiencias en la gestión de datos. Asimismo, se evidenció una notable ausencia de ensayos clínicos, escasez de estudios prospectivos, tamaños de muestras reducidos, falta de validación de los modelos y un empleo mínimo del aprendizaje no supervisado.

Por otro lado, el uso de biomarcadores y video como datos de entrenamiento fue escaso, pese a haber demostrado un buen desempeño. Algunos estudios utilizaron los marcadores *edge density imaging* y bandas delta-gamma, respectivamente, a partir de magnetoencefalogramas (43, 45). Ambas herramientas mostraron un desempeño notable (AUC de 0,98), logrando identificar alteraciones en el tejido cerebral

que no son detectables mediante TC (43). De igual manera, se demostró la capacidad de seis modelos de ML para identificar pacientes con TCE a partir de biomarcadores, como la metilación del ADN de leucocitos en sangre. La capacidad del ML para interpretar cambios epigenéticos, identificar distintas enfermedades y generar predicciones ha sido descrita ampliamente (61, 62).

En términos de aplicabilidad, si bien la IA no sustituye el juicio clínico, los hallazgos de esta revisión respaldan su exploración cautelosa como herramienta de apoyo a la decisión. Para el diagnóstico, los modelos ANN resultan prometedores para optimizar la indicación de TC craneal en niños con TCE leve, con el potencial de reducir la exposición a la radiación (24, 44). Para el pronóstico, se sugiere evaluar la integración de modelos de aprendizaje supervisado (tipo ANN) que complementen las escalas tradicionales de predicción de mortalidad y resultados adversos. No obstante, esta recomendación está condicionada a futuras investigaciones que confirmen el impacto y la seguridad de los modelos en el entorno clínico real, mediante estudios prospectivos y ensayos clínicos con validación externa, así como el uso de datos heterogéneos (biomarcadores moleculares, imágenes y videos).

Entre las limitaciones del presente estudio, se registra un sesgo geográfico y poblacional, dado que los estudios recuperados provienen predominantemente de Norteamérica y Asia, todos publicados en inglés. Esta concentración en regiones específicas, con una ausencia de estudios en América Latina, compromete la generalización de los resultados y su aplicabilidad a nuestra realidad local. Otra limitación fue que no se evaluó el riesgo de sesgo de los estudios incluidos, lo que implica que el alto rendimiento reportado de algunos modelos podría estar sobreestimado debido a debilidades en el diseño o análisis de los estudios primarios. Finalmente, la heterogeneidad entre los estudios encontrados impidió realizar un análisis cuantitativo tipo metaanálisis que permita sintetizar los resultados obtenidos.

CONCLUSIONES

Se destaca el creciente interés por la integración de la IA en el manejo del TCE pediátrico. Se identificaron cuatro categorías de aprendizaje, siendo el supervisado y el profundo las más utilizadas. Dentro de esas categorías, los modelos de ANN y SVM han demostrado tener un desempeño más eficiente, superando incluso a las herramientas tradicionales. Sin embargo, persiste la falta de estudios que validen su aplicación en la práctica

clínica real y se mantienen brechas importantes como la escasa evaluación del TCE moderado.

Conflictos de intereses: Los autores declaran no tener conflictos de interés.

Financiamiento: Autofinanciado.

Contribución de autoría:

RSR: conceptualización, administración del proyecto, análisis formal, visualización, investigación, redacción de borrador original).

SSS: conceptualización, análisis formal, investigación, visualización, redacción de borrador original).

CSO: metodología, validación, redacción (revisión y edición).

DGP: supervisión, validación, administración del proyecto, redacción (revisión y edición).

REFERENCIAS

1. Dewan MC, Mummareddy N, Wellons JC, Bonfield CM. Epidemiology of global pediatric traumatic brain injury: qualitative review. *World Neurosurg* [Internet]. 2016; 91: 497-509.e1. Disponible en: <https://doi.org/10.1016/j.wneu.2016.03.045>
2. Maas AI, Menon DK, Manley GT, Abrams M, Åkerlund C, Andelic N, et al. Traumatic brain injury: progress and challenges in prevention, clinical care, and research. *Lancet Neurol* [Internet]. 2022; 21(11): 1004-1060. Disponible en: [https://doi.org/10.1016/S1474-4422\(22\)00309-X](https://doi.org/10.1016/S1474-4422(22)00309-X)
3. Lumba-Brown A, Yeates KO, Sarmiento K, Breiding MJ, Haegerich TM, Gioia GA, et al. Centers for disease control and prevention guideline on the diagnosis and management of mild traumatic brain injury among children. *JAMA Pediatr* [Internet]. 2018; 172(11): e182853. Disponible en: <https://doi.org/10.1001/jamapediatrics.2018.2853>
4. Goh MS, Looi DS, Goh JL, Sultana R, Goh SS, Lee JH, et al. The impact of traumatic brain injury on neurocognitive outcomes in children: a systematic review and meta-analysis. *J Neurol Neurosurg Psychiatry* [Internet]. 2021; 92(8): 847-853. Disponible en: <https://doi.org/10.1136/jnnp-2020-325066>
5. Blackwell LS, Grell R. Pediatric traumatic brain injury: impact on the developing brain. *Pediatr Neurol* [Internet]. 2023; 148: 215-222. Disponible en: <https://doi.org/10.1016/j.pediatrneurol.2023.06.019>
6. Fulkerson DH, White IK, Rees JM, Baumanis MM, Smith JL, Ackerman LL, et al. Analysis of long-

- term (median 10.5 years) outcomes in children presenting with traumatic brain injury and an initial Glasgow Coma Scale score of 3 or 4. *J Neurosurg Pediatr* [Internet]. 2015; 16(4): 410-419. Disponible en: <https://thejns.org/pediatrics/view/journals/j-neurosurg-pediatr/16/4/article-p410.pdf>
7. Agramonte JS. Aspectos epidemiológicos en pacientes que sufrieron trauma pediátrico [tesis de título profesional en Internet]. Lima: Universidad Nacional Mayor de San Marcos; 2002. Disponible en: <https://hdl.handle.net/20.500.12672/1994>
 8. Guillén-Pinto D, Zea-Vera A, Guillén-Mendoza D, Situ-Kcomt M, Reynoso-Osnayo C, Milla-Vera LM, et al. Traumatismo encefalocraneano en niños atendidos en un hospital nacional de Lima, Perú 2004-2011. *Rev Peru Med Exp Salud Pública* [Internet]. 2013; 30(4): 630-634. Disponible en: http://www.scielo.org.pe/scielo.php?script=sci_arttext&pid=S1726-46342013000400015
 9. Uparela-Reyes MJ, Villegas-Trujillo LM, Cespedes J, Velásquez-Vera M, Rubiano AM. Usefulness of Artificial Intelligence in traumatic brain injury: a bibliometric analysis and mini-review. *World Neurosurg* [Internet]. 2024; 188: 83-92. Disponible en: <https://doi.org/10.1016/j.wneu.2024.05.065>
 10. Folweiler KA, Sandsmark DK, Diaz-Arrastia R, Cohen AS, Masino AJ. Unsupervised machine learning reveals novel traumatic brain injury patient phenotypes with distinct acute injury profiles and long-term outcomes. *J Neurotrauma* [Internet]. 2020; 37(12): 1431-1444. Disponible en: <https://doi.org/10.1089/neu.2019.6705>
 11. Hibi A, Jaberipour M, Cusimano MD, Bilbily A, Krishnan RG, Aviv RI, et al. Automated identification and quantification of traumatic brain injury from CT scans: Are we there yet? *Medicine* [Internet]. 2022; 101(47): e31848. Disponible en: <https://doi.org/10.1097/MD.00000000000031848>
 12. Kang D. Evaluating the accuracy and reliability of blowout fracture area measurement methods: a review and the potential role of Artificial Intelligence. *J Craniofac Surg* [Internet]. 2023; 34(6): 1834-1836. Disponible en: <https://doi.org/10.1097/SCS.0000000000009486>
 13. Bao XL, Zhan X, Wang L, Zhu Q, Fan B, Li GY. Automatic identification and segmentation of orbital blowout fractures based on Artificial Intelligence. *Transl Vis Sci Technol* [Internet]. 2023; 12(4): 7. Disponible en: <https://doi.org/10.1167/tvst.12.4.7>
 14. Wang J, Yin MJ, Wen HC. Prediction performance of the machine learning model in predicting mortality risk in patients with traumatic brain injuries: a systematic review and meta-analysis. *BMC Med Inform Decis Mak* [Internet]. 2023; 23(1): 142. Disponible en: <https://doi.org/10.1186/s12911-023-02247-8>
 15. Fleck DE, Ernest N, Asch R, Adler CM, Cohen K, Yuan W, et al. Predicting post-concussion symptom recovery in adolescents using a novel Artificial Intelligence. *J Neurotrauma* [Internet]. 2021; 38(7): 830-836. Disponible en: <https://doi.org/10.1089/neu.2020.7018>
 16. Choo YJ, Chang MC. Use of machine learning in stroke rehabilitation: a narrative review. *Brain Neurorehabil* [Internet]. 2022; 15(3): e26. Disponible en: <https://doi.org/10.12786/bn.2022.15.e26>
 17. Moore L, Abdeljelil AB, Tardif PA, Zemek R, Reed N, Yeates KO, et al. Clinical practice guideline recommendations in pediatric mild traumatic brain injury: a systematic review. *Ann Emerg Med* [Internet]. 2024; 83(4): 327-339. Disponible en: <https://doi.org/10.1016/j.annemergmed.2023.11.012>
 18. Peters MD, Godfrey C, McInerney P, Munn Z, Tricco AC, Khalil H. Scoping Reviews (2020). En: Aromataris E, Lockwood C, Porritt K, Pilla B, Jordan Z, editors. *JBI Manual for Evidence Synthesis*. JBI; 2024. Cap. 10. Disponible en: <https://doi.org/10.46658/JBIMES-24-09>
 19. Tricco AC, Lillie E, Zarin W, O'Brien KK, Colquhoun H, Levac D, et al. PRISMA extension for scoping reviews (PRISMA-ScR): checklist and explanation. *Ann Intern Med* [Internet]. 2018; 169(7): 467-473. Disponible en: <https://doi.org/10.7326/M18-0850>
 20. Xie Y, Zhai Y, Lu G. Evolution of Artificial Intelligence in healthcare: a 30-year bibliometric study. *Front Med* [Internet]. 2025; 11: 1505692. Disponible en: <https://doi.org/10.3389/fmed.2024.1505692>
 21. Ouzzani M, Hammady H, Fedorowicz Z, Elmagarmid A. Rayyan-a web and mobile app for systematic reviews. *Syst Rev* [Internet]. 2016; 5(1): 210. Disponible en: <https://doi.org/10.1186/s13643-016-0384-4>
 22. Tunthanathip T, Duangsawan J, Wattanakitrungroj N, Tongman S, Phuenpathom N. Comparison of intracranial injury predictability between machine learning algorithms and the nomogram in pediatric traumatic brain injury. *Neurosurg Focus* [Internet]. 2021; 51(5): E7. Disponible en: <https://doi.org/10.3171/2021.8.FOCUS2155>

23. Tunthanathip T, Oearsakul T. Application of machine learning to predict the outcome of pediatric traumatic brain injury. *Chin J Traumatol* [Internet]. 2021; 24(6): 350-355. Disponible en: <https://doi.org/10.1016/j.cjtee.2021.06.003>
24. Ellethy H, Chandra SS, Nasrallah FA. The detection of mild traumatic brain injury in paediatrics using artificial neural networks. *Comput Biol Med* [Internet]. 2021; 135: 104614. Disponible en: <https://doi.org/10.1016/j.compbioemed.2021.104614>
25. Daley M, Cameron S, Ganesan SL, Patel MA, Stewart TC, Miller MR, et al. Pediatric severe traumatic brain injury mortality prediction determined with machine learning-based modeling. *Injury* [Internet]. 2022; 53(3): 992-998. Disponible en: <https://doi.org/10.1016/j.injury.2022.01.008>
26. Shahi N, Shahi AK, Phillips R, Shirek G, Bensard D, Moulton SL. Decision-making in pediatric blunt solid organ injury: a deep learning approach to predict massive transfusion, need for operative management, and mortality risk. *J Pediatr Surg* [Internet]. 2021; 56(2): 379-384. Disponible en: <https://doi.org/10.1016/j.jpedsurg.2020.10.021>
27. Farzaneh CA, Schomberg J, Sullivan BG, Guner YS, Nance ML, Gibbs D, et al. Development and validation of machine learning models for the prediction of blunt cerebrovascular injury in children. *J Pediatr Surg* [Internet]. 2022; 57(4): 732-738. Disponible en: <https://doi.org/10.1016/j.jpedsurg.2021.11.008>
28. Rowe C, Wiesendanger K, Polet C, Kuppermann N, Aronoff S. Derivation and validation of a simplified clinical prediction rule for identifying children at increased risk for clinically important traumatic brain injuries following minor blunt head trauma. *J Pediatr X* [Internet]. 2020; 3: 100026. Disponible en: <https://doi.org/10.1016/j.ympdx.2020.100026>
29. Bahado-Singh RO, Vishweswaraiah S, Er A, Aydas B, Turkoglu O, Taskin BD, et al. Artificial Intelligence and the detection of pediatric concussion using epigenomic analysis. *Brain Res* [Internet]. 2020; 1726: 146510. Disponible: <https://doi.org/10.1016/j.brainres.2019.146510>
30. Fedorchak G, Rangnekar A, Onks C, Loeffert AC, Loeffert J, Olympia RP, et al. Saliva RNA biomarkers predict concussion duration and detect symptom recovery: a comparison with balance and cognitive testing. *J Neurol* [Internet]. 2021; 268(11): 4349-4361. Disponible en: <https://doi.org/10.1007/s00415-021-10566-x>
31. Chong SL, Liu N, Barbier S, Ong ME. Predictive modeling in pediatric traumatic brain injury using machine learning. *BMC Med Res Methodol* [Internet]. 2015; 15: 22. Disponible en: <https://doi.org/10.1186/s12874-015-0015-0>
32. Heo S, Ha J, Jung W, Yoo S, Song Y, Kim T, et al. Decision effect of a deep-learning model to assist a head computed tomography order for pediatric traumatic brain injury. *Sci Rep* [Internet]. 2022; 12: 12454. Disponible en: <https://doi.org/10.1038/s41598-022-16313-0>
33. Zou B, Mi X, Stone E, Zou F. A deep neural network framework to derive interpretable decision rules for accurate traumatic brain injury identification of infants. *BMC Med Inform Decis Mak* [Internet]. 2023; 23(1): 58. Disponible en: <https://doi.org/10.1186/s12911-023-02155-x>
34. Iyer KK, Zalesky A, Barlow KM, Cocchi L. Default mode network anatomy and function is linked to pediatric concussion recovery. *Ann Clin Transl Neurol* [Internet]. 2019; 6(12): 2544-2554. Disponible en: <https://doi.org/10.1002/acn3.50951>
35. Zahid A, Hubbard ME, Lockyer J, Podolak O, Dammavalam VM, Grady M, et al. Eye Tracking as a biomarker for concussion in children. *Clin J Sport Med* [Internet]. 2020; 30(5): 433-443. Disponible en: <https://doi.org/10.1097/JSM.0000000000000639>
36. Bertsimas D, Dunn J, Steele DW, Trikalinos TA, Wang Y. Comparison of machine learning optimal classification trees with the pediatric emergency care applied research network head trauma decision rules. *JAMA Pediatr* [Internet]. 2019; 173(7): 648-656. Disponible en: <https://doi.org/10.1001/jamapediatrics.2019.1068>
37. Guberman GI, Stojanovski S, Nishat E, Ptito A, Bzdok D, Wheeler AL, et al. Multi-tract multi-symptom relationships in pediatric concussion. *eLife* [Internet]. 2022; 11: e70450. Disponible en: <https://doi.org/10.7554/eLife.70450>
38. Kim YT, Kim H, Lee CH, Yoon BC, Kim JB, Choi YH, et al. Intracranial densitometry-augmented machine learning enhances the prognostic value of brain ct in pediatric patients with traumatic brain injury: a retrospective pilot study. *Front Pediatr* [Internet]. 2021; 9: 750272. Disponible en: <https://doi.org/10.3389/fped.2021.750272>
39. Ren Y, Osborne N, Peterson CB, DeMaster DM, Ewing-Cobbs L, Vannucci M. Bayesian varying-effects vector autoregressive models for inference of brain connectivity networks and covariate effects in pediatric traumatic brain

- injury. *Hum Brain Mapp* [Internet]. 2024; 45(10): e26763. Disponible en: <https://doi.org/10.1002/hbm.26763>
40. Greenan K, Taylor SL, Fulkerson D, Shahlaie K, Gerndt C, Krueger EM, et al. Selection of children with ultra-severe traumatic brain injury for neurosurgical intervention. *J Neurosurg Pediatr* [Internet]. 2019; 23(6): 670-679. Disponible en: <https://doi.org/10.3171/2019.1.PEDS18293>
41. Choi JW, Cho YJ, Ha JY, Lee YY, Koh SY, Seo JY, et al. Deep learning-assisted diagnosis of pediatric skull fractures on plain radiographs. *Korean J Radiol* [Internet]. 2022; 23(3): 343-354. Disponible en: <https://doi.org/10.3348/kjr.2021.0449>
42. Jeong TS, Yee GT, Kim KG, Kim YJ, Lee SG, Kim WK. Automatically diagnosing skull fractures using an object detection method and deep learning algorithm in plain radiography images. *J Korean Neurosurg Soc* [Internet]. 2023; 66(1): 53-62. Disponible en: <https://doi.org/10.3340/jkns.2022.0062>
43. Huang MX, Angeles-Quinto A, Robb-Swan A, De-la-Garza BG, Huang CW, Cheng CK, et al. Assessing pediatric mild traumatic brain injury and its recovery using resting-state magnetoencephalography source magnitude imaging and machine learning. *J Neurotrauma* [Internet]. 2023; 40(11-12): 1112-1129. Disponible en: <https://doi.org/10.1089/neu.2022.0220>
44. Hale AT, Stonko DP, Brown A, Lim J, Voce DJ, Gannon SR, et al. Machine-learning analysis outperforms conventional statistical models and CT classification systems in predicting 6-month outcomes in pediatric patients sustaining traumatic brain injury. *Neurosurg Focus* [Internet]. 2018; 45(5): E2. Disponible en: <https://doi.org/10.3171/2018.8.FOCUS17773>
45. Raji CA, Wang MB, Nguyen N, Owen JP, Palacios EM, Yuh EL, et al. Connectome mapping with edge density imaging differentiates pediatric mild traumatic brain injury from typically developing controls: proof of concept. *Pediatr Radiol* [Internet]. 2020; 50(11): 1594-1601. Disponible en: <https://doi.org/10.1007/s00247-020-04743-9>
46. Maddux AB, Sevick C, Cox-Martin M, Bennett TD. Novel claims-based outcome phenotypes in survivors of pediatric traumatic brain injury. *J Head Trauma Rehabil* [Internet]. 2021; 36(4): 242-252. Disponible en: <https://doi.org/10.1097/HTR.0000000000000646>
47. Hale AT, Stonko DP, Lim J, Guillamondegui OD, Shannon CN, Patel MB. Using an artificial neural network to predict traumatic brain injury. *J Neurosurg Pediatr* [Internet]. 2019; 23(2): 219-226. Disponible en: <https://doi.org/10.3171/2018.8.PEDS18370>
48. Yadav K, Sarioglu E, Choi HA, Cartwright WB, Hinds PS, Chamberlain JM. Automated outcome classification of computed tomography imaging reports for pediatric traumatic brain injury. *Acad Emerg Med* [Internet]. 2016; 23(2): 171-178. Disponible en: <https://doi.org/10.1111/acem.12859>
49. Miyagawa T, Saga M, Sasaki M, Shimizu M, Yamaura A. Statistical and machine learning approaches to predict the necessity for computed tomography in children with mild traumatic brain injury. *PLoS One* [Internet]. 2023; 18(1): e0278562. Disponible en: <https://doi.org/10.1371/journal.pone.0278562>
50. Kayhanian S, Young AM, Mangla C, Jalloh I, Fernandes HM, Garnett MR, et al. Modelling outcomes after paediatric brain injury with admission laboratory values: a machine-learning approach. *Pediatr Res* [Internet]. 2019; 86(5): 641-645. Disponible en: <https://doi.org/10.1038/s41390-019-0510-9>
51. Yang Z, Tsui B, Wu Z. Assessment system for child head injury from falls based on neural network learning. *Sensors* [Internet]. 2023; 23(18): 7896. Disponible en: <https://doi.org/10.3390/s23187896>
52. Bajwa J, Munir U, Nori A, Williams B. Artificial Intelligence in healthcare: transforming the practice of medicine. *Future Healthc J* [Internet]. 2021; 8(2): e188-e194. Disponible en: <https://doi.org/10.7861/fhj.2021-0095>
53. Clipper B. The influence of the COVID-19 pandemic on technology: adoption in health care. *Nurse Lead* [Internet]. 2020; 18(5): 500-503. Disponible en: <https://doi.org/10.1016/j.mnl.2020.06.008>
54. Pasricha M, Thakur V, Ghosh D. The future of work, artificial intelligence, and digital government: policy perspectives for Asia [Internet]. No. 202-20 (September). ADBInstitute; 2024. Disponible en: <https://doi.org/10.56506/TRYI4372>
55. Han R, Acosta JN, Shakeri Z, Ionannidis JP, Topol EJ, Rajpurkar P. Randomised controlled trials evaluating artificial intelligence in clinical practice: a scoping review. *Lancet Digit Health* [Internet]. 2024; 6(5): e367-e373. Disponible en: [https://doi.org/10.1016/S2589-7500\(24\)00047-5](https://doi.org/10.1016/S2589-7500(24)00047-5)
56. Abbasi MH, Somai M, Saber H. The trend of Artificial Intelligence application in medicine and

- neurology; the state-of-the-art systematic scoping review 2010-2022. *Intell-Based Med* [Internet]. 2024; 10: 100179. Disponible en: <https://doi.org/10.1016/j.ibmed.2024.100179>
57. Ono S, Goto T. Introduction to supervised machine learning in clinical epidemiology. *Ann Clin Epidemiol* [Internet]. 2022; 4(3): 63-71. Disponible en: <https://doi.org/10.37737/ace.22009>
58. Egger J, Gsaxner C, Pepe A, Pomykala KL, Jonske F, Kurz M, et al. Medical deep learning-A systematic meta-review. *Comput Methods Programs Biomed* [Internet]. 2022; 221: 106874. Disponible en: <https://doi.org/10.1016/j.cmpb.2022.106874>
59. Meral Atış G, Altay T, Atış ŞE. Comparison of CATCH, PECARN, and CHALICE clinical decision rules in pediatric patients with mild head trauma. *Eur J Trauma Emerg Surg* [Internet]. 2022; 48(4): 3123-3130. Disponible en: <https://doi.org/10.1007/s00068-021-01859-x>
60. Easter JS, Bakes K, Dhaliwal J, Miller M, Caruso E, Haukoos JS. Comparison of PECARN, CATCH, and CHALICE rules for children with minor head injury: a prospective cohort study. *Ann Emerg Med* [Internet]. 2014; 64(2): 145-152.e5. Disponible en: <https://doi.org/10.1016/j.annemergmed.2014.01.030>
61. Smolen P, Dash PK, Redell JB. Traumatic brain injury-associated epigenetic changes and the risk for neurodegenerative diseases. *Front Neurosci* [Internet]. 2023; 17: 1259405. Disponible en: <https://doi.org/10.3389/fnins.2023.1259405>
62. Yuan T, Edelmann D, Fan Z, Alwers E, Kather JN, Brenner H, et al. Machine learning in the identification of prognostic DNA methylation biomarkers among patients with cancer: a systematic review of epigenome-wide studies. *Artif Intell Med* [Internet]. 2023; 143: 102589. Disponible en: <https://doi.org/10.1016/j.artmed.2023.102589>