



UNIVERSIDAD PERUANA  
**CAYETANO HEREDIA**

Facultad de  
**MEDICINA**

USO DE LA INTELIGENCIA ARTIFICIAL EN EL TRAUMA  
CRANEOENCEFÁLICO EN NIÑOS

USE OF ARTIFICIAL INTELLIGENCE IN TRAUMATIC  
BRAIN INJURY IN CHILDREN

TESIS PARA OPTAR POR EL TÍTULO PROFESIONAL DE MÉDICO  
CIRUJANO

AUTORES

ROGELIO CRISTOPHER SALDAÑA RIMARACHIN

ERIC SALVADOR SEGURA SURCO

ASESOR

ROSENDO DANIEL GUILLEN PINTO

CO-ASESOR

CARLOS ANTONIO SALAZAR ORDOÑEZ

LIMA-PERÚ

2025



## **JURADO**

Presidente: Dra. Yolanda Prevost Ruiz

Vocal: Dra. Maria del Pilar Medina Alva

Secretario: Dra. Guiliana Mas Ubilus

Fecha de Sustentación: 28 de enero del 2025

Calificación: Aprobado

## **ASESORES DE TESIS**

### **ASESOR**

Dr. Rosendo Daniel Guillen Pinto

Departamento Académico de Clínicas Médicas

ORCID: 0000-0003-0412-3350

### **CO-ASESOR**

Dr. Carlos Antonio Salazar Ordoñez

Departamento Académico de Clínicas Médicas

ORCID: 0000-0001-9959-8097

## **DEDICATORIA**

Este proyecto está dedicado a nuestros padres, cuya entrega y sacrificio nos inspiraron a seguir adelante con perseverancia. A nuestros hermanos, compañeros de vida, cuyo apoyo incondicional fue indispensable en los momentos difíciles. A nuestros abuelos, cuya luz sigue iluminando nuestro sendero. A nuestros amigos, que con su compañía hicieron nuestros desafíos más llevaderos.

## **AGRADECIMIENTO**

A los doctores Daniel Guillen y Carlos Salazar, cuyos conocimientos, paciencia y guía incondicional fueron fuente de inspiración para continuar este camino.

Gracias por cada consejo en los momentos de incertidumbre. Su enseñanza ha trascendido lo académico y marcará la forma en que enfrentaremos cada desafío en el futuro.

A nuestras confidentes, cuyo amor y sonrisa nos recordó por qué seguir adelante.

## **FUENTES DE FINANCIAMIENTO**

El presente proyecto fue autofinanciado.

## **DECLARACIÓN DE CONFLICTO DE INTERÉS**

Los autores declaran no tener conflictos de interés.

# RESULTADO DEL INFORME DE SIMILITUD



UNIVERSIDAD PERUANA  
CAYETANO HEREDIA

Facultad de  
MEDICINA

USO DE LA INTELIGENCIA ARTIFICIAL EN EL TRAUMA  
CRANEOENCEFÁLICO EN NIÑOS

USE OF ARTIFICIAL INTELLIGENCE IN TRAUMATIC  
BRAIN INJURY IN CHILDREN

TESIS PARA OPTAR POR EL TÍTULO PROFESIONAL DE MÉDICO  
CIRUJANO

#### AUTORES

ROGELIO CRISTOPHER SALDAÑA RIMARACHIN  
ERIC SALVADOR SEGURA SURCO

#### ASESOR

ROSENDO DANIEL GUILLEN PINTO

#### CO-ASESOR

CARLOS ANTONIO SALAZAR ORDOÑEZ

LIMA-PERÚ  
2025



## 8% Similitud estándar

Filtros

### Fuentes

Mostrar las fuentes solapadas

1 Internet



[www.coursehero.com](http://www.coursehero.com)

<1%

5 bloques de texto 50 palabra que coinciden

2 Internet



[www.cochrane.org](http://www.cochrane.org)

<1%

3 bloques de texto 33 palabra que coinciden

3 Internet



[www.jove.com](http://www.jove.com)

<1%

2 bloques de texto 27 palabra que coinciden

## TABLA DE CONTENIDOS

RESUMEN

ABSTRACT

I.	INTRODUCCIÓN	1
II.	MARCO TEÓRICO	3
III.	OBJETIVOS	6
IV.	MATERIALES Y MÉTODOS	6
V.	RESULTADOS	11
VI.	DISCUSIÓN	19
VII.	CONCLUSIONES	28
VIII.	RECOMENDACIONES	29
IX.	REFERENCIAS BIBLIOGRÁFICAS	30
X.	TABLAS Y FIGURAS	44
XI.	ANEXOS	

## RESUMEN

**Introducción:** La Inteligencia Artificial (IA) constituye una herramienta muy valiosa en la práctica clínica. El trauma encefalocraneano (TEC) en niños, representa una de las principales causas de morbilidad infantil. Se espera que el uso de la IA mejore los resultados clínicos en esta población. **Objetivo:** Explorar y analizar la literatura existente sobre el uso de IA en el manejo del trauma encefalocraneano en la población pediátrica. **Método:** Se realizó una búsqueda en las bases de datos PubMed, PMC, Cochrane, Embase, Web of Science, IEEE Xplore, Scopus, Scielo y Lilacs. Se incluyó estudios que aplicaron modelos de Machine Learning (ML) para predecir el diagnóstico, tratamiento y pronóstico, publicados entre enero de 2015 y primer semestre 2024. **Resultados:** Fueron identificados 1727 artículos, de los cuales se seleccionaron 31. La mayoría publicados entre 2021 y 2024, procedentes de Estados Unidos (51.6%) y países asiáticos (29%). Los modelos de aprendizaje supervisado, Random Forest y Support Vector Machine (SVM) fueron los más utilizados (51.6%), seguidos de aprendizaje profundo (32.2%), destacando las redes neuronales artificiales (ANN). Los modelos de ML se aplicaron en el diagnóstico (64.5%) y pronóstico (38.7%). En términos de desempeño, los modelos diagnósticos reportaron un AUC entre 0.78-0.99 y destacó ANN (exactitud 99%, precisión 100%); en pronóstico, reportaron un AUC de 0.71-0.99 y destacó SVM (exactitud 94%, precisión 99%). **Conclusiones:** Existe un interés creciente del uso de la IA en el diagnóstico y pronóstico del TEC pediátrico, destacando los modelos de aprendizaje profundo, que superarían en rendimiento a las herramientas clínicas tradicionalmente usadas.

**Palabras clave:** Machine learning, inteligencia artificial, TEC, niños, revisión de alcance.

## ABSTRACT

**Introduction:** 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. **Methods:** We searched PubMed, 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. **Results:** 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%). **Conclusions:** There is a growing 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, TBI, children, scoping review.

## **I. INTRODUCCIÓN**

El traumatismo encefalocraneano (TEC) o trauma craneoencefálico se define como una disrupción en la función cerebral u otras evidencias de patología cerebral, causada por una fuerza externa (1).

A nivel global, el TEC se posiciona como una de las principales causas de discapacidad y mortalidad. Según la *Lancet Neurology Commission*, se estima que entre 50 y 60 millones de personas sufren de TEC anualmente y que, para el año 2030, seguirá siendo una de las tres primeras causas de muerte y discapacidad (2).

En los niños, una revisión de estudios realizados en cinco continentes, publicados entre 1995 y 2015, reportó que la incidencia mundial del TEC se encuentra en un rango entre 47 y 280 casos por cada 100 000 (1). Este impacto trasciende las estadísticas, ya que afecta profundamente a la salud infantil tanto a corto como a largo plazo. Dependiendo de la severidad del TEC, los niños pueden presentar síntomas persistentes que se extienden más allá de los tres meses; déficits cognitivos o emocionales, alteraciones del comportamiento, dificultad en el desarrollo de funciones ejecutivas y un mayor riesgo de desórdenes psiquiátricos (3,4,5,6).

En nuestro país, Agramonte (2002) reportó que el compromiso de la región encefalocraneana fue la primera causa de muerte en niños accidentados entre 1 y 14 años (7). En un estudio realizado en un hospital nacional de Lima, entre los años 2004 y 2011, se identificó un rango de 12 a 69 de casos de TEC pediátrico por año, de los cuales 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 con la habilidad de imitar el proceso cognitivo para resolver problemas, ha demostrado ser

una herramienta prometedora en el manejo del TEC (9). La IA es capaz de identificar características clínicas asociadas con un mayor riesgo de enfermedad, clasificar a los pacientes según el grado de severidad (10), analizar imágenes tomográficas e identificar lesiones (11). Asimismo, las aplicaciones de la IA en TEC se extienden al campo quirúrgico, permitiendo determinar a través de modelos el área de fracturas con mayor precisión (12,13).

En el TEC pediátrico, se han desarrollado modelos de IA que ayudan a estimar el pronóstico de la enfermedad, como la mortalidad, y que superan a las herramientas clínicas tradicionales como la Escala de Coma de Glasgow (ECG) o la escala tomográfica de Marshall (9,14,15). Además, pueden identificar a los niños que atravesarán una recuperación prolongada (16). Por otro lado, en aquellos con discapacidad severa, se han elaborado sistemas que recolectan información en tiempo real durante el momento de las terapias físicas. Estos sistemas calculan la funcionalidad del niño, establecen un nivel de entrenamiento con los ejercicios a realizar y son interpretados por un exoesqueleto (17,18).

A pesar de la existencia de guías internacionales para el diagnóstico y manejo del TEC pediátrico, persiste una heterogeneidad entre sus recomendaciones, lo que dificulta la toma de decisiones (3). Factores como la inexperiencia en la interpretación de tomografías, discrepancias entre las opiniones médicas y el temor a repercusiones legales por subestimar la severidad de los pacientes conllevan a hospitalizaciones innecesarias, aumentando la carga en el sistema sanitario (3).

## II. MARCO TEÓRICO

La IA actualmente se define, según la Comisión Europea en 2019, como un sistema con comportamiento inteligente, capaz de analizar su entorno para alcanzar objetivos específicos (19). El ML o aprendizaje automático, una subdivisión de la IA, tiene como función la creación de algoritmos capaces de aprender de datos. Estos modelos imitan las conexiones neuronales del cerebro humano, permitiéndoles realizar tareas complejas sin ser explícitamente programados para cada una de ellas (20). En medicina, estos modelos se utilizan para analizar grandes cantidades de información y tomar decisiones basadas en patrones ocultos en los datos.

El ML se clasifica según su enfoque de aprendizaje: aprendizaje supervisado y no supervisado. El aprendizaje supervisado implica entrenar al modelo con datos etiquetados, lo que significa que cada dato viene con una respuesta correcta conocida, y el no supervisado trabaja con datos sin etiquetar, siendo útil en la búsqueda de nuevos patrones sin referencias previas (21).

Dentro de estas categorías, el aprendizaje profundo se destaca como una subcategoría avanzada de ML, cuya función es emular el procesamiento cerebral mediante redes neuronales. Estas redes analizan datos en capas, cada una compuesta de unidades llamadas neuronas artificiales. fa

Además, existen los modelos híbridos, que combinan los diversos tipos de aprendizaje, maximizando su eficacia. En medicina, estos modelos son particularmente efectivos para resolver problemas complejos a partir de datos heterogéneos, como imágenes, señales fisiológicas y registros clínicos, optimizando el análisis y la predicción (23).

La convergencia entre la tecnología y la atención médica ha permitido la transición de la prestación de servicios sanitarios tradicionales a nuevos sistemas de atención médica mejorados con el ML (24).

El uso potencial de estos sistemas no se limita solo a facilitar procesos administrativos, sino que también abarca la ejecución de tareas clave, tales como el diagnóstico, la decisión terapéutica y el monitoreo de los pacientes (25). En el ámbito de la neurología pediátrica, la IA juega diferentes roles en el diagnóstico temprano, planes de tratamiento personalizados, sistema de apoyo de decisiones, pronóstico y rehabilitación (26,27).

El uso del ML en la predicción de desenlaces clínicos tras un TEC ha impactado de manera significativa en la atención médica (25). Modelos avanzados como el *Random Forest Classifier* han revolucionado el proceso de toma de decisiones, permitiendo prever la probabilidad de TEC en pacientes pediátricos (28). Esta capacidad predictiva es crucial para determinar qué pacientes requieren tomografía computarizada (TC), minimizando así la exposición innecesaria a radiación. Además, el ML aprovecha los datos clínicos e imágenes para pronosticar la morbilidad, mortalidad y resultados a largo plazo en niños afectados por TEC (29). Estas predicciones son esenciales para identificar a aquellos con alto riesgo de recuperación prolongada y complicaciones, facilitando una gestión más eficiente de los recursos, la personalización del tratamiento, la consejería familiar y la definición de expectativas realistas respecto a la recuperación (30).

## **Justificación**

El TEC es una de las principales causas de morbimortalidad en la población pediátrica, representando un desafío significativo para los sistemas de salud debido a su alta demanda en el servicio de emergencia. La complejidad y diversidad de lesiones asociadas al TEC generan variabilidad en el manejo clínico, influenciado por factores como la severidad del trauma, características del paciente (edad y comorbilidades) y recursos disponibles en el centro de atención. La IA y el ML surgen como herramientas prometedoras, no invasivas, capaces de optimizar la toma de decisiones clínicas en el diagnóstico precoz, elección terapéutica y pronóstico. Sin embargo, su implementación efectiva requiere modelos entrenados y evaluaciones rigurosas que validen su eficacia. Actualmente no existe en la literatura una revisión exhaustiva que evalúe la aplicación y rendimiento de modelos de IA en este grupo vulnerable, lo que limita la toma de decisiones clínicas basadas en evidencia. Por lo tanto, es imperativo realizar una revisión de alcance que explore la literatura existente sobre el uso de IA en el TEC pediátrico, examinando su evolución temporal, los tipos de IA empleados y su impacto clínico.

### **Pregunta de investigación:**

¿Cómo ha evolucionado la inteligencia artificial en el manejo de trauma encefalocraneano pediátrico en relación a su implementación en diversos escenarios clínicos y geográficos? La pregunta de investigación fue formulada con base en la estructura propuesta por la formulación de *Joanna Briggs Institute* (JBI) (**ANEXO 1**).

### **III. OBJETIVOS**

#### **Objetivos Principal**

1. Explorar y analizar la literatura existente sobre el uso de la inteligencia artificial en el manejo de trauma encefalocraneano en población pediátrica.

#### **Objetivos Secundarios**

1. Describir la evolución temporal y geográfica de la inteligencia artificial identificando tendencias y enfoques emergentes del trauma encefalocraneano en los niños.
2. Clasificar los estudios según los tipos de *machine learning* utilizados y las métricas de rendimiento reportadas.
3. Determinar las brechas en la literatura existente sobre la aplicación de la inteligencia artificial en el diagnóstico, tratamiento y pronóstico del trauma encefalocraneano en niños.
4. Evaluar los desafíos y limitaciones reportados que afectan el rendimiento de los modelos de *machine learning*.

### **IV. MATERIALES Y MÉTODOS**

#### **Diseño de Estudio**

Se realizó una Revisión de alcance o por sus términos en inglés *Scoping Review* de los estudios disponibles tanto observacionales como ensayos clínicos. Este estudio siguió la metodología propuesta del Manual para Síntesis de Evidencia del JBI (31).

### **Criterios de inclusión**

1. Estudios observacionales prospectivos y/o retrospectivos, ensayos clínicos controlados, revisiones sistemáticas y metaanálisis.
2. Estudios en niños y adolescentes (<18 años).
3. Estudios sobre trauma encefalocraneano que usan modelos de Inteligencia artificial.
4. Estudios que evalúen el desempeño de la inteligencia artificial mediante métricas estadísticas, como sensibilidad, especificidad, área bajo la curva, puntuación F1 o precisión de la predicción.
5. Estudios publicados a partir de enero de 2015 hasta el primer semestre del 2024.
6. Estudios realizados en cualquier región geográfica.
7. Estudios en cualquier idioma.

### **Criterios de exclusión**

1. Estudios no publicados, como artículos de conferencias y proyectos de tesis cargados en línea.
2. Estudios de revisión narrativa, carta a editores y comentarios.

### **Operacionalización de variables**

Las variables consideradas fueron las siguientes: denominación del estudio, autor(es), años de publicación, país, código del estudio, severidad del TEC, diseño del estudio, tamaño de muestra, lugar del estudio, tipos de IA, objetivo del estudio,

área de aplicación, comparador, validación del modelo, desempeño de la IA, impacto significativo, resultado principal, limitaciones reportadas. (**ANEXO 2**)

### **Estrategia de búsqueda**

Las búsquedas se realizaron en las siguientes bases de datos electrónicas: Pubmed/MEDLINE, PubMed Central, Cochrane Library, Embase, Web of Science, Scopus, IEEE Xplore, SciELO y LILACS.

Términos de búsqueda:

#### 1. Búsqueda inicial

- a. Se realizó una estrategia de búsqueda inicial en bases de datos clave como PubMed Medline, PubMed Central y Cochrane Library, para identificar artículos relevantes. Los términos de búsqueda fueron únicamente términos MeSH (*Medical Subject Headings*). Los artículos se buscaron en función de los elementos: Contexto, Condición, Población (CoCoPo) (**ANEXO 1**).

#### 2. Desarrollo de estrategia completa

- a. Se desarrolló una estrategia de búsqueda completa que incluyó los términos MeSH de la búsqueda inicial y palabras clave o *keywords* obtenidos de los artículos relevantes. Estos términos fueron adaptados para cada base de datos. Se utilizaron operadores booleanos para combinar términos de búsqueda (**ANEXO 3**).

#### 3. Búsqueda Manual

- a. La lista de referencias de los estudios incluidos fue revisada para identificar estudios relevantes. Se incluyeron fuentes de literatura, como Clinicaltrial.gov. Además se contactó con los autores de los

estudios clave cuando fue necesario para obtener datos adicionales o aclaraciones.

### **Colección de datos y análisis**

Dos revisores (RS, ES) realizaron de manera independiente el proceso de cribado por título y resumen, identificado en la búsqueda inicial de las bases de datos electrónicas. Se utilizó Rayyan (32) como herramienta para organizar y manejar las referencias. Los estudios que no cumplieron con los criterios de elegibilidad fueron excluidos. Se obtuvieron los textos completos de los estudios potencialmente relevantes y se realizó la revisión de manera independiente por ambos autores (RS, ES) utilizando un formulario de evaluación predefinido que incluía todos los criterios de elegibilidad y un espacio para notas adicionales (**ANEXO 4**). Los estudios que no cumplieron con estos criterios fueron excluidos y se registraron los motivos específicos de la exclusión. La discrepancia entre los revisores se resolvió mediante discusión. No se requirió la intervención de un tercer revisor. En cada estudio incluido en la fase de evaluación de texto completo, se registraron los motivos específicos que avalan su exclusión, garantizando la transparencia del proceso. Se presenta el gráfico PRISMA detallando los resultados de la búsqueda

### **FIGURA 1.**

### **Extracción de Datos**

Los datos fueron extraídos por dos revisores (RS, ES) de manera paralela utilizando una plantilla de extracción de datos desarrollada por ambos autores (RS, ES). La información extraída incluía datos bibliométricos, características del estudio, características del modelo de ML y de los resultados. Además, se incluyeron

campos adicionales para agregar datos como información sobre la población, el diseño del estudio, tamaño de muestra, tipo de ML, objetivo principal, área clínica de aplicación (diagnóstico, tratamiento, pronóstico), comparador, desempeño del modelo de ML (métricas estadísticas), significancia del impacto, validación del modelo de ML y limitaciones reportadas por los autores de cada estudio (**ANEXO 5**). Los datos extraídos se almacenaron utilizando la herramienta de gestión de datos, Excel.

La rigurosidad de la extracción se evaluó previamente mediante el uso de una plantilla piloto con un grupo pequeño de estudios. Las discrepancias entre los revisores fueron resueltas mediante discusión. No se requirió la intervención de un tercer revisor. Además, no hubo modificaciones a la plantilla de extracción de datos.

### **Aspectos éticos**

Esta revisión se basa en la recopilación y análisis de datos de estudios previamente publicados, por lo que no implica daño a personas y, por tanto, no requirió la obtención del consentimiento informado, conforme a las pautas éticas de CIOMS (33). No hubo elección de personas por parte de este estudio, pero se garantizó que los estudios incluidos tuvieran una selección de pacientes justa, ética y basada en principios de equidad. Finalmente, se respetaron los derechos y la dignidad de los pacientes cuyos datos fueron utilizados en el presente estudio, manteniendo la confidencialidad y el valor para la investigación científica.

El valor de esta revisión permitirá mejorar la atención de los pacientes pediátricos con TEC, agregando una mayor evidencia a la práctica clínica. La calidad de la información reportada seguirá las recomendaciones brindadas por las guías metodológicas del JBI y PRISMA-ScR (31,34). Existen riesgos como los errores

de predicción, que podrían afectar en la toma de decisiones clínicas y, en consecuencia, la atención del paciente.

## **V. RESULTADOS**

La búsqueda inicial, realizada en septiembre de 2024, dio como resultado 1 727 artículos recopilados a partir de 9 bases de datos, distribuidos de la siguiente manera: Pubmed/MEDLINE [50], Pubmed Central [22], Cochrane Library [201], Embase [710], Web of Science [95], Scopus [534], IEEE Xplore [112], SciELO [0], LILACS [3]. Además, como parte de la búsqueda manual, se realizó una búsqueda en ClinicalTrial.gov, que no identificó estudios relevantes para esta revisión.

Los estudios encontrados fueron importados a la herramienta Rayyan para la gestión de las referencias. Durante esta primera fase, se detectaron y eliminaron 499 estudios duplicados. Además, 78 estudios fueron excluidos automáticamente por Rayyan; esta herramienta identificó palabras clave ('animals', 'conference abstract', 'case report', 'retracted publication', 'protocol', 'CONF') dentro del título o resumen, términos que no se alineaban con los criterios de elegibilidad. Los 1 150 estudios restantes fueron evaluados en base a títulos y resúmenes por ambos revisores de manera independiente, de los cuales 1 044 estudios fueron excluidos por no cumplir con los criterios de inclusión como no incluir población pediátrica, tratarse sobre algoritmos que no emplean IA o que el diseño de estudio sea distinto a los de interés en esta revisión.

Finalmente, 106 estudios fueron evaluados a texto completo, 2 fueron obtenidos por comunicación directa con los autores, 5 de ellos no pudieron ser recuperados, debido a que su acceso estaba restringido por costos asociados y no estaban incluidos dentro de los convenios institucionales de la universidad con las bases de

datos consultadas. Además, 70 fueron descartados por no cumplir los criterios de elegibilidad. Por lo que se incluyeron 31 estudios en la revisión final. Los desacuerdos suscitados por ambos revisores durante el proceso de selección fueron resueltos mediante discusión y consenso. El resumen para la selección de estudios se encuentra bajo el diagrama de flujo del modelo PRISMA 2020, como muestra en la **FIGURA 1**.

### **Características de los estudios incluidos**

De los 31<sup>16,28,29,35-62</sup> estudios incluidos en esta revisión, el estudio más antiguo fue publicado en 2015, mientras que el 60% de ellos se publicaron entre los años 2021 y 2024, como se ilustra en la **FIGURA 2**. En cuanto a la distribución geográfica, la mayoría de estudios se llevaron a cabo en países de América del Norte (58%), Asia (29%) y otras regiones (13%), según se detalla en la **FIGURA 3**. Respecto al diseño de los estudios, el 70.9% (n=22)<sup>16, 28,29,35-39,41,44,45,47,49,51,55,57-62</sup> correspondió a estudios tipo cohortes, 22.5% (n=7)<sup>40,42,46,50,52,53,56</sup> fueron casos y controles, 3.3% (n=1)<sup>48</sup> correlacionales y 3.3% (n=1)<sup>43</sup> simulación cuasi-experimental. Cabe señalar que no se encontraron ensayos clínicos ni revisiones sistemáticas. Asimismo, el 74.1% de los estudios (n=23)<sup>16,35-39,42-44,47,49-53,29,55,28,57-61</sup> fueron retrospectivos, el 19.3% prospectivos (n=6)<sup>40,41,45,54,56,62</sup> y 6.6% transversales (n=2)<sup>46,48</sup>. En relación al tamaño de muestra, los estudios incluyeron entre 24 y 885 100 pacientes o datos relacionados (datos clínicos y laboratoriales, reportes radiológicos de imágenes, imágenes radiológicas y muestras biológicas). Dado el amplio rango observado, se calculó la mediana del tamaño de muestra, que fue 289 pacientes, reflejando una marcada disparidad. En cuanto al grupo etario de los pacientes, el 90% de los

estudios incluyó dentro de su población a participantes en edad preescolar y escolar. Respecto a la severidad del TEC, el 48.4% (n=15)<sup>35,39-41,43-48,16,54,56,57,60</sup> de los estudios evaluó exclusivamente TEC leve, el 9.6% (n=3)<sup>36,51,61</sup> se enfocó en TEC severo y el 13% (n=5)<sup>28,29,49,55,62</sup> abarcó TEC leve, moderado y severo. Sin embargo, el 25.8% (n=7)<sup>37,38,50,52,53,58,59</sup> de los estudios no especificó la severidad del TEC y no se encontraron estudios que evalúen a pacientes solo con TEC moderado. Finalmente, respecto a las áreas de aplicación de la IA en TEC pediátrico, se centraron principalmente en el diagnóstico con el 64.5% (n=20)<sup>28,35,38,39,40,42,43,44,46,47,48,50,52,53,54,56,58,59,60,62</sup> de los estudios y, en menor medida, en el pronóstico con el 38.7% (n=12)<sup>16,29,36,37,41,45,49,51,54,55,57,61</sup> evaluando desenlaces clínicos como mortalidad, discapacidad a largo plazo y duración de hospitalización. Cabe destacar que Huang et al. (2022) abordó ambas áreas de aplicación. Sin embargo, no se encontraron estudios relacionados con el tratamiento. El resumen de las características de los estudios se encuentran en el **ANEXO 6**.

### **Clasificación de los estudios según tipos de ML**

En esta revisión, se identificaron cuatro tipos de aprendizaje: supervisados, no supervisados, profundos e híbridos. Es importante señalar que no se encontraron modelos basados en sistemas difusos.

El ML supervisado fue la categoría más utilizada, representando el 51.6% de los estudios (n=16)<sup>28,29,36,38,39,41,42,45,46,47,48,49-51,60,61</sup>. Entre los modelos más destacados fueron *Random Forest* (RF, n=6)<sup>28,29,36,38,39,41</sup>, *Decision tree* (DT, n=6)<sup>28,46,47,49,51,60</sup>, *Logistic Regression* (RL, n=6)<sup>28,29,39,46,49,61</sup> y *Support Vector Machine* (SVM, n=5)<sup>28,29,41,45,61</sup>. Además, se identificaron otros modelos como *Artificial Neural*

*Network* (ANN, n=3)<sup>28,29,42</sup>, *Naive Bayes* (NB, n=3)<sup>28,29,50</sup>, *K-Nearest Neighbors* (KNN, n=2)<sup>28,29</sup>, *Generalized Boosted Model* (GBM, n=1)<sup>39</sup>, *Optimal Classification Tree* (n=1)<sup>47</sup> y *Partial Least Square* (n=1)<sup>48</sup>, estos fueron utilizados como comparadores o herramientas complementarias. En contraste, el ML no supervisado fue el menos frecuente, apareciendo solo el 3.3% de estudios, con el modelo *Cluster K-Means* (CK-M, n=1)<sup>57</sup>.

El aprendizaje profundo, representó el 32.2% de los estudios (n=10)<sup>35,37,40,43,44,52,53,55,58,62</sup>. Entre los modelos más utilizados se incluyen las ANN (n=10), que incluyeron *Deep Neural Network* (DNN, n=3)<sup>37,43,44</sup>, *Convolutional Neural Network* (CNN, n=3)<sup>52,53,62</sup> y cuatro modelos no tipificados.

Finalmente, los modelos híbridos estuvieron presentes en el 12.9% de los estudios (n=4)<sup>16,54,56,59</sup>. Estos estudios implementaron un total de 10 modelos híbridos, cuyas bases incluyeron SVM (n=2)<sup>54,56</sup>, *Genetic Fuzzy Tree* (GFT, n=1)<sup>16</sup> y DT (n=1)<sup>59</sup> junto a técnicas complementarias para maximizar su desempeño.

### **Clasificación de los estudios según el desempeño de la IA**

Los tipos de ML aplicados en el diagnóstico y pronóstico del TEC pediátrico fueron analizados en términos de frecuencia. Adicionalmente, se evaluó el desempeño específico de los modelos de ML implementados en cada área, considerando métricas como área bajo la curva (AUC) cuyos valores van de cero a uno, sensibilidad, especificidad, exactitud y precisión. Sin embargo, no todos los estudios utilizaron las mismas métricas.

### **Diagnóstico**

En los estudios relacionados con el diagnóstico (n=20), se identificaron diferentes tipos de ML. El aprendizaje supervisado fue el más frecuente; estuvo presente en el 45% (n=9)<sup>28,38,39,42,46,47,48,50,60</sup> de los 20 estudios . El aprendizaje profundo estuvo presente en el 40% (n=8)<sup>35,40,43,44,52,53,58,62</sup> y los modelos híbridos se emplearon en el 15% (n=3)<sup>54,56,59</sup> de los estudios. No hubo estudios de aprendizaje no supervisado en diagnóstico.

Entre los modelos supervisados, el modelo más utilizado fue el DT (4 de 20 estudios o 20%)<sup>28,46,47,60</sup>, seguido de RF (3 de 20 estudios o 15%)<sup>28,38,39</sup>, RL (3 de 20 estudios o 15%)<sup>28,39,46</sup> y NB (2 de 20 estudios o 10%)<sup>28,50</sup>. Los modelos de GBM, SVM, KNN estuvieron presentes en el 5% de estudios (1 estudio de 20 cada uno). Entre los modelos que emplearon aprendizaje profundo, se encontraron a los CNN (3 de 20 estudios o 15%)<sup>52,53,62</sup>, DNN (2 de 20 estudios o 10%)<sup>43,44</sup> y los ANN no especificados (3 de 20 estudios o 10%)<sup>35,40,58</sup>. Los modelos híbridos fueron los menos frecuentes. Entre ellos, los diseños basados en SVM fueron combinados con estrategias de eliminación recursiva de variables (RFE)<sup>54</sup> y análisis de componente principal (PCA)<sup>56</sup>; y aquellos basados en DT se combinaron con procesamiento de lenguaje natural (NLP)<sup>59</sup>.

Al analizar los modelos de ML según su desempeño, se evaluó el valor mínimo y máximo encontrado. El AUC osciló entre 0.78 y 0.99, siendo el valor más bajo el reportado por Zahid et al. (2018)<sup>46</sup> y el más alto por Hale et al. (2018)<sup>58</sup>, con una mediana de 92%. La sensibilidad tuvo un rango mucho más amplio, osciló entre 4.8%<sup>44</sup> y 99.7%<sup>58</sup>, con una mediana de 89.7%, mientras que la especificidad entre 60.4%<sup>35</sup> a 100%<sup>44</sup>, con una mediana de 91.6%. En términos de precisión, los valores fluctuaron entre 1.8%<sup>43</sup> y 100%<sup>35</sup>, con una mediana de 84.6% y la exactitud entre

86.3%<sup>38</sup> y 99.9%<sup>35</sup>, con una mediana de 97.2%. Cabe destacar que Rowe et al. (2020) evaluó a su modelo mediante tasa de falsos negativos y Guberman et al. (2021) no presentó métricas de desempeño. Al comparar a los modelos según su categoría de aprendizaje, el rango de AUC de aprendizaje supervisado fue de 0.78<sup>46</sup> a 0.98<sup>42</sup>. El valor más alto fue descrito por Chong et al. (2015) quién diseñó un modelo de ANN para identificar a pacientes con TEC moderado a severo. Los modelos de aprendizaje profundo tuvieron un rango de AUC de 0.79<sup>44</sup> a 0.99<sup>58</sup>, el valor más alto lo obtuvo el modelo de ANN descrito por Hale et al. (2018), cuyo objetivo principal era identificar pacientes con riesgo de desarrollar TEC clínicamente relevante. Solo 2 de los 3 estudios, reportaron el AUC de sus modelos híbridos. El mayor valor fue de 0.98, reportado por Huang et al. (2022), quién desarrolló un modelo de SVM-RFE capaz de interpretar magnetoencefalografías. Como se muestra en la **TABLA 1**.

### **Pronóstico**

En los estudios relacionados con el pronóstico (n=12)<sup>17,29,36,37,41,45,49,51,54,55,57,61</sup>. El aprendizaje supervisado fue el más frecuente; se identificó en el 58% de los 12 estudios (n=7)<sup>29,36,41,45,49,51,61</sup>. Le siguieron el aprendizaje profundo y los modelos híbridos, cada uno con un 17% (n=2)<sup>16,54</sup>, mientras que el aprendizaje no supervisado apareció en el 8% (n=1)<sup>57</sup>.

Entre los modelos supervisados, el modelo más utilizado fue SVM (4 de 12 estudios o 33.3%)<sup>29,41,45,61</sup>, seguidos por RF (3 de 12 estudios o 25%)<sup>29,36,41</sup>, RL (3 de 12 estudios o 25%)<sup>29,49,61</sup> y DT (2 de 12 estudios o 16.67%)<sup>49,51</sup>. Los modelos ANN,

NB y KNN se implementaron en el 8.33% de los estudios (1 de 12 cada uno)<sup>29</sup>. Entre los modelos que emplearon aprendizaje profundo solo se encontraron a los ANN (2 de 12 estudios o 16.6%)<sup>37,55</sup>. Los modelos híbridos representaron el 16.67% (2 de 12 estudios o 16.6%)<sup>16,54</sup> e incluyeron diseños como GFT y SVM-RFE, cada uno en el 8.33% de los estudios (1 de 12 cada uno). Finalmente, el aprendizaje no supervisado estuvo presente en el 8.33%<sup>57</sup> de los estudios (1 de 12) con el modelo CK-M.

Al analizar los modelos de ML según su desempeño, se evaluó el valor mínimo y máximo encontrado. El AUC osciló entre 0.71 y 0.99, siendo el valor más bajo alcanzado por el modelo de Kim et al. (2021)<sup>49</sup> y el más alto por Hale et al. (2018)<sup>58</sup>, con una mediana de 0.87. La sensibilidad de los algoritmos varió desde un mínimo de 59.4%<sup>16</sup> hasta un máximo del 100%<sup>37</sup>, con una mediana de 87.3%, mientras que la especificidad fluctuó entre 60%<sup>29</sup> y 99%<sup>61</sup>, con una mediana de 78.71%. En términos de precisión, los valores fluctuaron entre 35.2%<sup>49</sup> y 99%<sup>29</sup>, con una mediana de 64.6%, y la exactitud entre 0.27%<sup>55</sup> y 94%<sup>29</sup>, con una mediana de 87%. Al comparar los modelos según su categoría de aprendizaje, los modelos basados en aprendizaje profundo mostraron un rango de exactitud entre 0.27%<sup>55</sup> y 91.9%<sup>37</sup>, siendo el modelo ANN de Shahi et al (2021) el que obtuvo el valor máximo en esta categoría. Por otro lado, los modelos supervisados mostraron un rango de precisión de 35.2%<sup>49</sup> a 99%<sup>29</sup>. Dentro de esta categoría, el modelo SVM de Tunthanathip et al. (2021) fue el que alcanzó el mayor valor. Finalmente, en los estudios de modelos híbridos, se reportó una exactitud de 62.3%<sup>16</sup> en un modelo diseñado para predecir la recuperación de post-conmoción en adolescentes mediante imágenes de tensor

de difusión (DTI) obtenidas por resonancia magnética (16). Como se ilustra en la **TABLA 2.**

### **Datos de entrenamiento**

De los 31 estudios incluidos, 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 e imágenes o datos clínicos y marcadores).

Los datos clínicos fueron los más utilizados, presentes en el 58% de los estudios (n=18)<sup>28,29,35-39,42-44,47,51,55,57-61</sup>. Los estudios que utilizaron imágenes como única fuente de datos fueron el 16% (n=5)<sup>45,50,52,53,56</sup>, solo un estudio utilizó como biomarcador el *edge density imaging* (56). Mientras tanto, los videos se utilizaron en 6.5% (n=2)<sup>46,62</sup>. Además, un 19.5% (n=6)<sup>16,40,41,48,49,54</sup> emplearon datos combinados. Aquellos que combinaron datos clínicos con biomarcadores utilizaron datos epigenéticos, como cambios en la metilación del ADN (40) y ARN no codificante (41).

### **Validación**

La validación es esencial para el desarrollo de cualquier modelo de IA, ya que asegura que las herramientas sean exactas, fiables, generalizables y de utilidad clínica. En esta revisión se identificaron tres tipos de validación: interna, externa y cruzada. La validación interna evalúa el rendimiento del modelo utilizando la

misma muestra de datos que se usó para su desarrollo (63). La validación cruzada también utiliza los mismos datos del desarrollo; sin embargo, estos mismos datos se dividen en múltiples subconjuntos. El modelo se entrena con todos los subconjuntos menos uno y se valida con el subconjunto restante, este proceso se repite varias veces. A diferencia de la validación interna, la validación externa evalúa el rendimiento a partir de datos independientes de aquellos utilizados para el desarrollo del modelo; esto permite determinar si el modelo mantiene su capacidad predictiva incluso en otros contextos (63). De los 31 estudios encontrados, se identificó que el 25.8% (n=8)<sup>16,38,47,53,58,59,60,62</sup> utilizaron validación interna para sus modelos, el 54.8% (n=17)<sup>28,29,35,36,37,39,40,41,44,45,46,49,54,55,56,57,61</sup> validación cruzada, el 9.6% (n=3)<sup>43,51,52</sup> validación externa y el 9.6% (n=3)<sup>42,48,50</sup> no mencionaron el tipo de validación de su modelo.

## VI. DISCUSIÓN

Para ilustrar la aplicación de la IA en el TEC pediátrico, se presentan dos casos clínicos que ejemplifican la integración de la IA en escenarios reales.

### **CASO CLÍNICO: Uso de la Inteligencia Artificial en el Manejo de TEC leve.**

Una niña de 10 años llegó a urgencias luego de un accidente mientras manejaba su bicicleta sin casco. Los padres refirieron que la niña perdió el control de la bicicleta al intentar esquivar un obstáculo, lo que provocó que su cabeza impactara directamente contra la vereda. Inmediatamente después, presentó dolor de cabeza y náuseas, lo que motivó la consulta médica. Durante la evaluación inicial, la niña se encontraba consciente y alerta. Al examinarla, presentó una puntuación de 14

(M6,V5,O3) en el ECG, no tuvo signos de déficit neurológico focal, ni signos de fractura. Además, no tenía antecedentes relevantes.

Con base en los criterios del *Pediatric Emergency Care Applied Research Network* (PECARN), la paciente no justificaba una tomografía computarizada inmediata, ya que no presentaba criterios tales como pérdida de conciencia prolongada, vómitos repetidos, signos neurológicos focales o fractura de cráneo evidente, mecanismo de lesión severo o caída desde una gran altura. Por ello, la recomendación inicial fue la observación clínica.

En este contexto, se utilizó una herramienta de IA llamada DEEPTICH, diseñada para calcular riesgos de hemorragia intracraneal traumática (HICT) en pacientes con trauma leve. Este sistema entrenado con más de 1,8 millones de casos, analiza datos como el sexo, edad, mecanismo de lesión, puntuación ECG y persistencia de síntomas. Después de ingresar los datos clínicos de la paciente, la herramienta estimó un riesgo moderado de hemorragia intracraneal traumática (HICT), por lo que sugirió solicitar una TC. Este análisis detectó patrones asociados a lesiones sin manifestaciones clínicas evidentes, pero con factores de riesgo específicos, como alteración leve del estado mental.

A partir de la predicción proporcionada por DEEPTICH, el equipo médico, en consenso con los padres de la niña, decidió realizar una TC debido al riesgo detectado por la herramienta DEEPTICH, a pesar de que los criterios PECARN no lo indicaban. Los resultados de la TC mostraron ausencia de hemorragia intracraneal u otras lesiones significativas. La niña fue dada de alta con recomendaciones para observación domiciliaria y seguimiento de 24-48 horas.

Este caso subraya la importancia de integrar herramientas de IA en el manejo clínico de TEC pediátrico. Aunque los criterios PECARN están respaldados por una sólida evidencia clínica, la IA proporcionó un análisis adicional que ayudó a identificar un riesgo moderado y justificó la realización de una TC.

### **CASO CLÍNICO: Uso de la Inteligencia Artificial en el Manejo de TEC severo.**

Un niño de 7 años ingresó al servicio de emergencias tras sufrir un accidente automovilístico de alta energía. Durante la evaluación inicial, presentaba un puntaje de 6 en la ECG, anisocoria derecha, bradicardia (38 lpm) y presión arterial elevada (160/95 mmHg), hallazgos consistentes con hipertensión intracraneal severa. Estos signos clínicos, junto con el mecanismo de lesión, indicaban un TEC severo con compromiso vital inminente.

La TC inicial reveló una hemorragia subdural masiva con un volumen aproximado de 50 ml, edema cerebral difuso, desviación de la línea media de 10 mm e indicaciones de herniación uncal. Los análisis de laboratorio mostraron leucocitosis moderada (15 000/ $\mu$ L) y un estado de hipercoagulabilidad leve (D-dímero: 750 ng/mL), lo que subraya la severidad del cuadro.

En el manejo inicial, el paciente fue intubado para proteger la vía aérea y recibió tratamiento con manitol al 20% y solución salina hipertónica al 3% para controlar la presión intracraneal. Además, se implementó un monitoreo continuo de la presión intracraneal (PIC) para evaluar la respuesta al tratamiento.

En este contexto, se utilizó un modelo de aprendizaje profundo basado en redes neuronales artificiales (ANN), diseñado para integrar datos clínicos e imágenes y realizar predicciones en tiempo real. Este modelo determinó una probabilidad de

mortalidad del 35%, un riesgo del 40% de necesitar transfusión masiva y una probabilidad del 60% de éxito del manejo no quirúrgico (NOM). Con base en esas predicciones, el equipo interdisciplinario optó por un manejo conservador inicial, complementado con un monitoreo intensivo.

La IA desempeñó un papel clave en el pronóstico, evaluando la viabilidad del manejo conservador y reduciendo así los riesgos asociados con intervenciones quirúrgicas innecesarias.

### **Evolución temporal y geográfica**

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, como se ilustra en la **FIGURA 2**. Esta tendencia marcada hacia el aumento del número de publicaciones podría estar relacionada con la mayor accesibilidad a hardware avanzado y el incremento de datos disponibles para entrenar a la IA (24). Además, la pandemia de COVID-19 parece haber actuado como un catalizador para la adopción de tecnologías digitales, incluida la IA, para automatizar procesos en entornos de alta presión (64).

La distribución geográfica de los estudios revela una concentración predominante en Estados Unidos (51.6%), mientras que en regiones como América Latina y África los estudios están prácticamente ausentes. Este desequilibrio refleja disparidades globales en el desarrollo y aplicación de estas tecnologías, influenciadas por recursos económicos y políticos. Por otro lado, se observa una tendencia creciente en países asiáticos, como Corea del Sur, China y Japón, a partir del 2021, impulsada por políticas estratégicas de innovación (65). En contraste,

otros países como Reino Unido, Australia y Turquía presentan una participación limitada, a pesar de su capacidad tecnológica y recursos. Cabe resaltar que las colaboraciones internacionales podrían impulsar la equidad en la implementación de tecnologías avanzadas en salud global. Finalmente, otras revisiones han encontrado una distribución temporal y geográfica similar a la descrita en nuestros hallazgos (66,67,68), como se muestra en la **FIGURA 4**.

Debido a la heterogeneidad de las recomendaciones presentes en las guías clínicas del TEC pediátrico, se han desarrollado herramientas que brinden mayor seguridad para la toma de decisiones. En el ámbito médico, los modelos de aprendizaje supervisado del ML son los más utilizados en estudios de diagnóstico y pronóstico (69), hecho que se refleja en nuestros hallazgos. Sin embargo, las ventajas que ofrecen los modelos de aprendizaje profundo han llevado a que las publicaciones más recientes los consideren como objeto de interés (70), como se ilustra en la **FIGURA 5**. En nuestro estudio, los modelos de aprendizaje profundo fueron los segundos en frecuencia; sin embargo, en su mayoría, demostraron un mayor desempeño frente al resto de modelos. Esta superioridad en el desempeño ha provocado una tendencia creciente a la investigación de estos modelos (54). Como respuesta a esta diferencia y con el fin de obtener mejores resultados, han surgido modelos híbridos que combinan el aprendizaje supervisado con técnicas como PCA y RFE (56). No obstante, este tipo de diseños implica costos computacionales más altos (71).

## **Diagnóstico**

Cada año en Estados Unidos, 644 679 niños se someten a una TC, de los cuales solo el 9% presenta hallazgos positivos de TEC, lo que implica que el 91% está expuesto a radiación de manera innecesaria, desperdiciando recursos que podrían ser mejor aprovechados (35). Existen numerosas herramientas clínicas para identificar qué pacientes requieren una TC; sin embargo, muchas de ellas tienen una especificidad y valor predictivo positivo deficientes (72). Por este motivo, se han desarrollado herramientas que muestran mejor desempeño.

En este estudio se identificaron modelos que presentaron una exactitud y precisión muy cercana al 100%. Ellethy et al. (2021) desarrolló un modelo de ANN que obtuvo 99.9% y 100%, respectivamente. Hale et al. (2018), por su parte, desarrolló un modelo de ANN con una exactitud de 97.9% y una precisión de 98.1%. Asimismo, se reportó que este mismo tipo de modelos y de DNN, alcanzaron niveles de sensibilidad superiores al 95% (35,43,58), superando a escalas clínicas tradicionales como el PECARN (83.8%) o CHALICE (90%) (72). Además, Chong et al. (2015) y Hale et al. (2018) registraron valores de AUC de 0.98 y 0.99, respectivamente, superando a los obtenidos por el PECARN (0.81), CHALICE (0.84) y CATCH (0.67) (73).

Por otro lado, algunos de los estudios se enfocaron en el desarrollo de herramientas cuyo objetivo fue exclusivamente identificar a pacientes con TEC mediante marcadores específicos. Raji et al. (2020) y Huang et al. (2023) utilizaron resonancias magnéticas potenciadas en difusión y magnetoencefalografías, respectivamente. Ambos respaldaron el uso de imágenes avanzadas, interpretadas por modelos híbridos de ML, con el fin de identificar alteraciones en el tejido cerebral que normalmente no pueden ser captadas por una TC (54,56). El

desempeño de ambas herramientas tuvo un AUC considerable, siendo el mayor el de Huang (0.98). Existen revisiones que resaltan la capacidad del ML en la interpretación de magnetoencefalografías y que sugieren que incluso podrían ser utilizadas para la evaluación de respuesta al tratamiento (74). Bahado Singh et al. (2020), por su parte, demostraron la capacidad de seis modelos de ML para identificar pacientes con TEC mediante cambios en la metilación del ADN de leucocitos en sangre. La capacidad del ML para interpretar cambios epigenéticos e identificar distintas enfermedades y generar predicciones, ha sido descrita ampliamente (75,76).

### **Pronóstico**

El TEC pediátrico es una de las principales causas de morbimortalidad y discapacidad, con graves secuelas cognitivas y físicas a largo plazo (2,5,6). Los desenlaces en el TEC varían según su severidad. El TEC leve puede generar síntomas persistentes durante más de 3 meses prolongando el tiempo de recuperación (4). En casos de TEC moderado a severo, surgen déficits cognitivos, emocionales y conductuales que impactan el desarrollo social (5,6). El TEC severo presenta una alta tasa de mortalidad (56.6% al año) y discapacidad severa en el 71.6% de los casos (77).

Los modelos pronósticos tradicionales, basados en análisis estadísticos convencionales, no logran adaptarse a los cambios dinámicos en pacientes con TEC, destacando la necesidad de sistemas más avanzados. Identificar subgrupos con posibilidades de recuperación es esencial para personalizar tratamientos. Sin embargo, los algoritmos actuales se enfocan en predicciones de mortalidad a corto

plazo, dejando de lado desenlaces funcionales a largo plazo (17,78). En contraste, modelos de ML han demostrado un mejor desempeño en estudios recientes. Modelos basados en aprendizaje profundo como el ANN, alcanzaron una exactitud y precisión mayor al 90% en la predicción de mortalidad, transfusión masiva y éxito de manejo no quirúrgico, en comparación con métodos tradicionales (37). Modelos basados en aprendizaje supervisado, como el SVM, alcanzaron una precisión del 99% y exactitud del 94% en la predicción de resultados desfavorables, superando a otros modelos supervisados como ANN, RF, RL, NB, KNN, en pacientes con TEC leve, moderado y severo (29). Modelos híbridos como GFT, fueron capaces de predecir la recuperación post conmoción en adolescentes a partir de imágenes de MRI, superando a modelos supervisados como NB, RF, SVM, DT en la misma tarea (16). El modelo no supervisado, CK-M, evaluó el uso de recursos posteriores al alta, generó fenotipos e identificó a los pacientes con una alta carga de morbilidad. Este reportó un AUC de 0.85; sin embargo, el estudio no determinó el desempeño de métodos estadísticos como el Análisis de Clases Latentes para poder comparar el desempeño entre ellos (57).

### **Brechas y Limitaciones de los estudios**

Los estudios sobre la aplicación de ML, aunque prometedores, presentaron varias brechas y limitaciones que afectan su implementación clínica. Entre las principales brechas se destacan la falta de ensayos clínicos y estudios prospectivos, mientras que las limitaciones incluyen el uso de datos retrospectivos, muestras pequeñas y la falta de validación de los modelos, lo que limita su aplicabilidad.

Además, se encontraron vacíos importantes en ciertas poblaciones y áreas geográficas. Por ejemplo, no se encontraron estudios en América Latina y África, regiones que enfrentan barreras como la falta de infraestructura tecnológica y deficiencias en la gestión de datos. Asimismo, la evaluación de pacientes con TEC moderado es casi inexistente, a pesar de que representan un grupo clínicamente heterogéneo. El aprendizaje no supervisado, una técnica capaz de identificar patrones en datos, fue la menos utilizada (20). Por otro lado, la integración de datos clínicos con biomarcadores y videos fue limitada, a pesar de haber demostrado mejoras significativas en el desempeño de los modelos. Estas brechas resaltan posibles áreas de investigación ya que son estrategias poco exploradas.

### **Aportes y Limitaciones de la presente revisión**

De acuerdo con nuestro conocimiento, esta es la primera revisión de alcance que evalúa el uso de la IA en TEC pediátrico. Nuestra búsqueda abarcó una amplia base de datos, incluyendo fuentes especializadas en tecnología y electrónica, reflejando la naturaleza multidimensional de la IA. No solo sintetizamos la información existente, sino que identificamos brechas clave en la literatura actual. Nuestra revisión aporta una perspectiva única al clasificar y evaluar los modelos en términos de su desempeño, destacando su potencial para superar herramientas clínicas tradicionales. Finalmente, ofrecemos un análisis detallado y visualmente claro para los profesionales de la salud, facilitando la comprensión del uso de la IA en la práctica clínica.

El presente estudio posee varias limitaciones. Primero, si bien se mencionó que se incluirían estudios en cualquier idioma, solo se encontraron estudios en inglés, por

lo que es posible que se hayan excluido estudios relevantes escritos en otros idiomas. Segundo, los estudios encontrados son muy heterogéneos entre sí, lo que impide realizar un análisis cuantitativo tipo metaanálisis que resuma mejor los resultados obtenidos. Finalmente, debido a la propia naturaleza de nuestro estudio, las conclusiones generadas en una revisión de alcance suelen ser muy generales, lo que limita su aplicación como guía para la toma de decisiones clínicas.

## **VII. CONCLUSIONES**

La presente revisión de alcance resalta el creciente interés en la integración de la inteligencia artificial (IA) en el manejo del TEC pediátrico. Se identificaron cuatro categorías de aprendizaje, de las cuales las más utilizadas fueron el supervisado y el profundo. Dentro de esas categorías, los modelos de redes neuronales artificiales (ANN, por sus siglas en inglés) y máquinas de soporte vectorial (SVM), han demostrado tener un desempeño superior, superando incluso a las herramientas tradicionales como escalas clínicas o algoritmos clásicos. Sin embargo, también se evidenció la ausencia de estudios que evalúen su aplicación en la práctica clínica real, como los ensayos clínicos aleatorizados. Además, hubo un enfoque predominante sobre TEC leve o severo, dejando un vacío en la evaluación del TEC moderado.

## **VIII. RECOMENDACIONES**

Dado el ritmo acelerado en el desarrollo de la IA, es fundamental mantener un enfoque dinámico que no solo nos permita actualizar constantemente la información, sino que también sean comprensibles y transparentes para los profesionales de la salud. En este sentido, recomendamos fomentar la implementación de Inteligencia Artificial Explicable (XAI), ya que permite garantizar que cada decisión tomada durante el proceso del aprendizaje automático pueda rastrearse y explicarse. Además, es necesario la realización de estudios prospectivos y ensayos clínicos que validen externamente los modelos de IA, garantizando así su aplicación en contextos clínicos reales. Asimismo, se recomienda el uso de datos heterogéneos, incluyendo biomarcadores moleculares, imágenes y videos, para mejorar la precisión de la predicción.

## IX. REFERENCIAS BIBLIOGRÁFICAS

1. Dewan MC, Mummareddy N, Wellons JC, Bonfield CM. Epidemiology of Global Pediatric Traumatic Brain Injury: Qualitative Review. *World Neurosurg.* 2016;91:497–509.e1. doi: 10.1016/j.wneu.2016.03.045.
2. Maas AI, Menon DK, Manley GT, Abrams M, Åkerlund C, Andelic N, Aries M, Bashford T, Bell MJ, Bodien YG, Brett BL, Büki A, Chesnut RM, Citerio G, Clark D, Clasby B, Cooper DJ, Czeiter E, Czosnyka M, Dams-O'Connor K, De Keyser V, Diaz-Arrastia R, Ercole A, A Van Esse T, Falvey E, Ferguson A, Figaji A, Fitzgerald M, Foreman B, Gantner D, Gao G, Giacino J, Gravesteijn J, Guiza F, Gupta D, Gurnell M, Haagsma J, Hammond F, Hawryluk G, Hutchinson P, Van der Jagt P, Jain S, Jain S, Jiang J, Kent H, Kolias A, Kompanje E, Lecky E, Lingsma H, Maegele M, Majdan M, Markowitz A, McCrea M, Meyfroidt G, Mikolić A, Mondello S, Mukherjee P, Nelson D, Nelson L, Newcombe V, Okonkwo D, Orešič M, Peul W, Piscià D, Polinder S, Ponsford J, Puybasset L, Raj R, Robba C, Røe C, Rosand J, Schueler P, Sharp D, Smielewski P, Stein M, von Steinbüchel N, Stewart W, Steyerberg E, Stocchetti N, Temkin N, Tenovuo O, Theadom A, Thomas I, Torres A, Turgeon A, Unterberg A, Van Praag D, van Veen E, Verheyden J, Vande Vyvere T, Wang K, Wiegers E, Huw Williams W, Wilson L, Wisniewski S, Younsi A, Yue J, Yuh E, Zeiler F, Zeldovich M, Zemek R. Traumatic brain injury: progress and challenges in prevention, clinical care, and research. *Lancet Neurol.* 2022; 21(11):1004–1060. doi: 10.1016/s1474-4422(22)00309-x.
3. Moore L, Abdeljelil AB, Tardif PA, Zemek R, Reed N, Yeates KO, Emery CA, Gagnon IJ, Yanchar N, Bérubé M, Dawson J, Berthelot S, Stang A, Beno S,

- Beaulieu E, Turgeon A, Labrosse A, Lauzier F, Pike I, Macpherson A, Freire G. Clinical practice guideline recommendations in pediatric mild traumatic brain injury: A systematic review. *Ann Emerg Med.* 2024;83(4):327–39. doi: 10.1016/j.annemergmed.2023.11.012.
4. Lumba-Brown A, Yeates KO, Sarmiento K, Breiding MJ, Haegerich TM, Gioia GA, Turner M, Benzel EC, Suskauer SJ, Giza CC, Joseph M, Broomand C, Weissman B, Gordon W, Wright DW, Moser RS, McAvoy K, Ewing-Cobbs L, Duhaime AC, Putukian M, Holshouser B, Paulk D, Wade SL, Herring SA, Halstead M, Keenan HT, Choe M, Christian CW, Guskiewicz K, Raksin PB, Gregory A, Mucha A, Taylor HG, Callahan JM, DeWitt J, Collins MW, Kirkwood MW, Ragheb J, Ellenbogen RG, Spinks TJ, Ganiats TG, Sabelhaus LJ, Altenhofen K, Hoffman R, Getchius T, Gronseth G, Donnell Z, O'Connor RE, Timmons SD. Centers for Disease Control and Prevention Guideline on the Diagnosis and Management of Mild Traumatic Brain Injury Among Children. *JAMA Pediatr.* 2018;172(11):e182853. doi: 10.1001/jamapediatrics.2018.2853.
  5. Goh MSL, Looi DSH, Goh JL, Sultana R, Goh SSM, Lee JH, Chong SL. The Impact of Traumatic Brain Injury on Neurocognitive Outcomes in Children: a Systematic Review and Meta-Analysis. *J Neurol Neurosurg Psychiatry.* 2021;92(8):847-53. doi: 10.1136/jnnp-2020-325066.
  6. Blackwell LS, Grell R. Pediatric Traumatic Brain Injury: Impact on the Developing Brain. *Pediatr Neurol.* 2023;148:215-22. doi: 10.1016/j.pediatrneurol.2023.06.019.

7. Agramonte JS. Aspectos epidemiológicos en pacientes que sufrieron Trauma Pediátrico. [Tesis de maestría]. Perú: UNMSM; 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, Bravo-Padilla E, Espinoza IO, Medina-Alva M. Traumatismo encefalocraneano en niños atendidos en un hospital nacional de Lima, Perú 2004-2011. *Rev Peru Med Exp Salud Pública*. 2013;30(4):630-4.
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 Minireview. *World Neurosurg*. 2024;18:83–92. doi: 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*. 2020;37(12):1431-44. doi: 10.1089/neu.2019.6705.
11. Hibi A, Jaberipour M, Cusimano MD, Bilbily A, Krishnan RG, Aviv RI, Tyrrell PN. Automated identification and quantification of traumatic brain injury from CT scans: Are we there yet? *Medicine*. 2022;101(47):e31848. doi: 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*. 2023;34(6):1834-6. doi: 10.1097/SCS.00000000000009486.

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.* 2023;12(4):7. doi: 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.* 2023;23(1):142. doi: 10.1186/s12911-023-02247-8.
15. Raita Y, Goto T, Faridi MK, Brown DFM, Camargo CA Jr, Hasegawa K. Emergency department triage prediction of clinical outcomes using machine learning models. *Crit Care.* 2019;23(1):64. doi: 10.1186/s13054-019-2351-7.
16. Fleck DE, Ernest N, Asch R, Adler CM, Cohen K, Yuan W, Kunkel B, Krikorian R, Wade SL, Babcock L. Predicting Post-Concussion Symptom Recovery in Adolescents Using a Novel Artificial Intelligence. *J Neurotrauma.* 2021;38(7):830-6. doi: 10.1089/neu.2020.7018.
17. Courville E, Kazim SF, Vellek J, Tarawneh O, Stack J, Roster K, Roy J, Schmidt M, Bowers C. Machine learning algorithms for predicting outcomes of traumatic brain injury: A systematic review and meta-analysis. *Surg Neurol Int.* 2023;14:262. doi: 10.25259/SNI\_312\_2023.
18. Choo YJ, Chang MC. Use of Machine Learning in Stroke Rehabilitation: A Narrative Review. *Brain Neurorehabil.* 2022;15(3):e2. doi: 10.12786/bn.2022.15.e26.
19. European Commission: Directorate-General for Communications Networks, Content and Technology, Ethics guidelines for trustworthy AI. Publications Office; 2019. doi: 10.2759/346720

20. Sidey-Gibbons JAM, Sidey-Gibbons CJ. Machine learning in medicine: a practical introduction. *BMC Med Res Methodol*. 2019;19(1):64. doi: 10.1186/s12874-019-0681-4.
21. Habehh H, Gohel S. Machine Learning in Healthcare. *Curr Genomics*. 2021;22(4):291-300. doi: 10.2174/1389202922666210705124359.
22. LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature*. 2015;521(7553):436-44. doi: 10.1038/nature14539.
23. Manikandan A, Anandan R. A Hybrid Deep Learning Models for Hetrogeneous Medical Big Data Integration. In: *Advances in intelligent systems and computing*. Springer. 2022.p:201–12. doi: 10.1007/978-981-19-0182-9\_21
24. Bajwa J, Munir U, Nori A, Williams B. Artificial intelligence in healthcare: transforming the practice of medicine. *Future Healthc J*. 2021;8(2):e188-94. doi: 10.7861/fhj.2021-0095.
25. Rajkomar A, Dean J, Kohane I. Machine Learning in Medicine. *N Engl J Med*. 2019;380(14):1347-58. doi: 10.1056/NEJMr1814259.
26. Korff C. Artificial Intelligence and Pediatric Neurology. *Sinapse*. 2023;23(3):137-40. doi.org/10.46531/sinapse/ED/230064/2023.
27. Gombolay GY, Gopalan N, Bernasconi A, Nabbout R, Megerian JT, Siegel B, Hallman-Cooper J, Bhalla S, Gombolay MC. Review of Machine Learning and Artificial Intelligence (ML/AI) for the Pediatric Neurologist. *Pediatr Neurol*. 2023;141:42-51. doi: 10.1016/j.pediatrneurol.2023.01.004.
28. Tunthanathip T, Duangsuwan J, Wattanakitrunroj N, Tongman S, Phuenpathom N. Comparison of intracranial injury predictability between

- machine learning algorithms and the nomogram in pediatric traumatic brain injury. *Neurosurg Focus*. 2021;51(5):E7. doi: 10.3171/2021.8.FOCUS2155.
29. Tunthanathip T, Oearsakul T. Application of machine learning to predict the outcome of pediatric traumatic brain injury. *Chin J Traumatol*. 2021;24(6):350-355. doi: 10.1016/j.cjtee.2021.06.003.
30. Matsuo K, Aihara H, Nakai T, Morishita A, Tohma Y, Kohmura E. Machine Learning to Predict In-Hospital Morbidity and Mortality after Traumatic Brain Injury. *J Neurotrauma*. 2020;37(1):202-10. doi: 10.1089/neu.2018.6276
31. Peters MDJ, Godfrey C, McInerney P, Munn Z, Tricco AC, Khalil, H. Scoping Reviews (2020). Aromataris E, Lockwood C, Porritt K, Pilla B, Jordan Z, editors. *JBIM Manual for Evidence Synthesis*. JBI; 2024. doi: 10.46658/JBIMES-24-09.
32. Ouzzani M, Hammady, H, Fedorowicz Z, Elmagarmid A. Rayyan—a web and mobile app for systematic reviews. *Syst Rev* 5, 210 (2016). doi: 10.1186/s13643-016-0384-4.
33. Council for International Organizations of Medical Sciences (CIOMS). *International Ethical Guidelines for Health-Related Research Involving Humans*. Geneva: CIOMS; 2016. doi: 10.56759/rgx17405.
34. Tricco, AC, Lillie, E, Zarin, W, O'Brien, KK, Colquhoun, H, Levac, D, Moher, D, Peters, MD, Horsley, T, Weeks, L, Hempel, S et al. PRISMA extension for scoping reviews (PRISMA-ScR): checklist and explanation. *Ann Intern Med*. 2018,169(7):467-473. doi: 10.7326/M18-0850.

35. Ellethy H, Chandra SS, Nasrallah FA. The detection of mild traumatic brain injury in paediatrics using artificial neural networks. *Comput Biol Med.* 2021;135:104614. doi: 10.1016/j.combiomed.2021.104614.
36. Daley M, Cameron S, Ganesan SL, Patel MA, Stewart TC, Miller MR, Alharfi I, Fraser DD. Pediatric severe traumatic brain injury mortality prediction determined with machine learning-based modeling. *Injury.* 2022;53(3):992-998. doi: 10.1016/j.injury.2022.01.008.
37. 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.* 2022;56(2):379-384. doi: 10.1016/j.jpedsurg.2020.10.021.
38. Farzaneh CA, Schomberg J, Sullivan BG, Guner YS, Nance ML, Gibbs D, Yu PT. Development and validation of machine learning models for the prediction of blunt cerebrovascular injury in children. *J Pediatr Surg.* 2022;57(4):732-738. doi: 10.1016/j.jpedsurg.2021.11.008.
39. 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.* 2020;3:100026. doi:10.1016/j.ympdx.2020.100026.
40. Bahado-Singh RO, Vishweswaraiah S, Er A, Aydas B, Turkoglu O, Taskin BD, Duman M, Yilmaz D, Radhakrishna U. Artificial Intelligence and the detection of pediatric concussion using epigenomic analysis. *Brain Res.* 2020;1726:146510. doi: 10.1016/j.brainres.2019.146510.

41. Fedorchak G, Rangnekar A, Onks C, Loeffert AC, Loeffert J, Olympia RP, DeVita S, Leddy J, Haider MN, Roberts A, Rieger J, Uhlig T, Monteith C, Middleton F, Zuckerman SL, Lee T, Yeates KO, Mannix R, Hicks S. Saliva RNA biomarkers predict concussion duration and detect symptom recovery: a comparison with balance and cognitive testing. *J Neurol*. 2021;268(11):4349-4361. doi: 10.1007/s00415-021-10566-x.
42. Chong SL, Liu N, Barbier S, Ong ME. Predictive modeling in pediatric traumatic brain injury using machine learning. *BMC Med Res Methodol*. 2015;15:22. doi: 10.1186/s12874-015-0015-0.
43. Heo S, Ha J, Jung W, Yoo S, Song Y, Kim T, Cha WC. Decision effect of a deep-learning model to assist a head computed tomography order for pediatric traumatic brain injury. *Sci Rep*. 2022;12(1):12454. doi: 10.1038/s41598-022-16313-0.
44. 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*. 2023;23(1):58. doi: 10.1186/s12911-023-02155-x.
45. Iyer KK, Zalesky A, Barlow KM, Cocchi L. Default mode network anatomy and function is linked to pediatric concussion recovery. *Ann Clin Transl Neurol*. 2019;6(12):2544-2554. doi: 10.1002/acn3.50951.
46. Zahid A, Hubbard ME, Lockyer J, Podolak O, Dammavalam VM, Grady M, Nance M, Scheiman M, Samadani U, Master CL. Eye Tracking as a Biomarker for Concussion in Children. *Clin J Sport Med*. 2020;30(5):433-443. doi: 10.1097/JSM.0000000000000639.

47. 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.* 2019;173(7):648-656. doi: 10.1001/jamapediatrics.2019.1068.
48. Guberman GI, Stojanovski S, Nishat E, Ptito A, Bzdok D, Wheeler AL, Descoteaux M. Multi-tract multi-symptom relationships in pediatric concussion. *Elife.* 2022;11:e70450. doi: 10.7554/eLife.70450.
49. Kim YT, Kim H, Lee CH, Yoon BC, Kim JB, Choi YH, Cho WS, Oh BM, Kim DJ. 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.* 2021;9:750272. doi: 10.3389/fped.2021.750272.
50. 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.* 2024;45(10):e26763. doi: 10.1002/hbm.26763.
51. Greenan K, Taylor SL, Fulkerson D, Shahlaie K, Gerndt C, Krueger EM, Zwienenberg M. Selection of children with ultra-severe traumatic brain injury for neurosurgical intervention. *J Neurosurg Pediatr.* 2019;23(6):670-679. doi: 10.3171/2019.1.
52. Choi JW, Cho YJ, Ha JY, Lee YY, Koh SY, Seo JY, Choi YH, Cheon JE, Phi JH, Kim I, Yang J, Kim WS. Deep Learning-Assisted Diagnosis of Pediatric Skull Fractures on Plain Radiographs. *Korean J Radiol.* 2022;23(3):343-354. doi: 10.3348/kjr.2021.0449.

53. 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.* 2023;66(1):53-62. doi: 10.3340/jkns.2022.0062.
54. Huang MX, Angeles-Quinto A, Robb-Swan A, De-la-Garza BG, Huang CW, Cheng CK, Hesselink JR, Bigler ED, Wilde EA, Vaida F, Troyer EA, Max JE. Assessing Pediatric Mild Traumatic Brain Injury and Its Recovery Using Resting-State Magnetoencephalography Source Magnitude Imaging and Machine Learning. *J Neurotrauma.* 2023;40(11-12):1112-1129. doi: 10.1089/neu.2022.0220.
55. Hale AT, Stonko DP, Brown A, Lim J, Voce DJ, Gannon SR, Le TM, Shannon CN. 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.* 2018;45(5):E2. doi: 10.3171/2018.8.FOCUS17773.
56. Raji CA, Wang MB, Nguyen N, Owen JP, Palacios EM, Yuh EL, Mukherjee P. Connectome mapping with edge density imaging differentiates pediatric mild traumatic brain injury from typically developing controls: proof of concept. *Pediatr Radiol.* 2020;50(11):1594-1601. doi: 10.1007/s00247-020-04743-9.
57. 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.* 2021;36(4):242-252. doi: 10.1097/HTR.0000000000000646.

58. Hale AT, Stonko DP, Lim J, Guillaumondegui OD, Shannon CN, Patel MB. Using an artificial neural network to predict traumatic brain injury. *J Neurosurg Pediatr.* 2019;23(2):219-226. doi: 10.3171/2018.8.PEDS18370.
59. Yadav K, Sarioglu E, Choi HA, Cartwright WB 4th, Hinds PS, Chamberlain JM. Automated Outcome Classification of Computed Tomography Imaging Reports for Pediatric Traumatic Brain Injury. *Acad Emerg Med.* 2016;23(2):171-8. doi: 10.1111/acem.12859.
60. 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.* 2023;18(1):e0278562. doi: 10.1371/journal.pone.0278562.
61. Kayhanian S, Young AMH, Mangla C, Jalloh I, Fernandes HM, Garnett MR, Hutchinson PJ, Agrawal S. Modelling outcomes after paediatric brain injury with admission laboratory values: a machine-learning approach. *Pediatr Res.* 2019;86(5):641-645. doi: 10.1038/s41390-019-0510-9.
62. Yang Z, Tsui B, Wu Z. Assessment System for Child Head Injury from Falls Based on Neural Network Learning. *Sensors (Basel).* 2023;23(18):7896. doi: 10.3390/s23187896.
63. Steyerberg EW, Harrell FE Jr. Prediction models need appropriate internal, internal-external, and external validation. *J Clin Epidemiol.* 2016;69:245-7. doi: 10.1016/j.jclinepi.2015.04.005.
64. Clipper B. The Influence of the COVID-19 Pandemic on Technology: Adoption in Health Care. *Nurse Lead.* 2020;18(5):500-503. doi: 10.1016/j.mnl.2020.06.008.

65. Pasricha M, Thakur V, Ghosh D. The Future of Work, Artificial Intelligence, and Digital Government: Policy Perspectives for Asia. ADBI. 2024. doi: 10.56506/tryi4372.
66. Han R, Acosta J, Shakeri Z, Ionannidis J, Topol E, Rajpurkar P. Randomised controlled trials evaluating artificial intelligence in clinical practice: a scoping review. *Lancet Digit Health*. 2024; 6(5):e367–73. doi: 10.1016/S2589-7500(24)00047-5.
67. 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. *Intelligence-Based Medicine*. 2024;100179. doi: 10.1016/j.ibmed.2024.100179.
68. Serra-Burriel M, Locher L, Vokinger KN. Development Pipeline and Geographic Representation of Trials for Artificial Intelligence/Machine Learning-Enabled Medical Devices (2010 to 2023). *NEJM AI*. 2023;1(1). doi: 10.1056/aipc2300038.
69. Ono S, Goto T. Introduction to supervised machine learning in clinical epidemiology. *Ann Clin Epidemiol*. 2022;4(3):63-71. doi: 10.37737/ace.22009.
70. 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*. 2022;221:106874. doi: 10.1016/j.cmpb.2022.106874.
71. Mazlan AU, Sahabudin NA, Remli MA, Ismail NSN, Mohamad MS, Nies HW, Abd Warif NB. A Review on Recent Progress in Machine Learning and Deep

- Learning Methods for Cancer Classification on Gene Expression Data. *Processes*. 2021; 9(8):1466. doi: 10.3390/pr9081466.
72. Meral Atiş G, Altay T, Atiş ŞE. Comparison of CATCH, PECARN, and CHALICE clinical decision rules in pediatric patients with mild head trauma. *Eur J Trauma Emerg Surg*. 2022;48(4):3123-3130. doi: 10.1007/s00068-021-01859-x.
73. 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*. 2014;64(2):145-52, 152.e1-5. doi: 10.1016/j.annemergmed.2014.01.030.
74. Peitz GW, Wilde EA, Grandhi R. Magnetoencephalography in the Detection and Characterization of Brain Abnormalities Associated with Traumatic Brain Injury: A Comprehensive Review. *Med Sci (Basel)*. 2021;9(1):7. doi: 10.3390/medsci9010007.
75. Smolen P, Dash PK, Redell JB. Traumatic brain injury-associated epigenetic changes and the risk for neurodegenerative diseases. *Front Neurosci*. 2023;17:1259405. doi: 10.3389/fnins.2023.1259405.
76. 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* . 2023;143:102589. doi: 10.1016/j.artmed.2023.102589.
77. Fulkerson DH, White IK, Rees JM, Baumanis MM, Smith JL, Ackerman LL, Boaz JC, Luerssen TG. 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.* 2015;16(4):410-9. doi: 10.3171/2015.3.PEDS14679.

78. Goyal P, Malviya R. Challenges and opportunities of big data analytics in healthcare. *Health Care Sci.* 2023;2(5):328-338. doi: 10.1002/hcs2.66.

## X. TABLAS Y FIGURAS

**TABLA 1**

Denominación del estudio	Tipo de Aprendizaje	Objetivo Diagnóstico	Modelos de IA	Precisión (%)	Exactitud (%)	AUC	Sensibilidad (%)	Especificidad (%)
Ellethy et al. (2021) [35]	Profundo	Necesidad de TC	ANN	100	99.9	-	97.7	100
Farzaneh et al. (2022) [38]	Supervisado	Necesidad de TC	RF	3.9	86.3	0.92	84	86
Rowe et al. (2020) [39]	Supervisado	Necesidad de TC	RF	-	-	-	-	-
Bahado Singh et al. (2020) [40]	Profundo	Identificación de TEC por marcador	ANN	-	-	0.98	97	95
Chong et al. (2015) [42]	Supervisado	Necesidad de TC	ANN	90.2	-	0.98	94.9	97.4
Heo et al. (2022) [43]	Profundo	Necesidad de TC	DNN	1.8	-	0.92	95	67.2
Zou et al. (2023) [44]	Profundo	Necesidad de TC	DNN	-	91.5	0.79	4.8	100
Zahid et al. (2020) [46]	Supervisado	Identificación de TEC por marcador	RL	78.1	-	0.78	75	64.7
Bertsimas et al. (2019) [47]	Supervisado	Necesidad de TC	DT	2.7	-	-	94.5	65.6
Choi et al. (2022) [52]	Profundo	Identificación de fractura	CNN	-	-	0.87	78.9	91.3
Jeon et al. (2023) [53]	Profundo	Identificación de fractura	CNN	-	-	-	37.5	62.5
Huang et al. (2023) [54]	Hibrido	Identificación de TEC por marcador	SVM-RFE	-	-	0.98	95.5	90.2
Tunthanathip et al. (2021) [28]	Supervisado	Necesidad de TC	RF	79	-	0.80	34	95
Rajiet al. (2020) [56]	Hibrido	Identificación de TEC por marcador	SVM-PCA	-	-	0.94	79	100

Continuación en siguiente página ...

Continuación de la tabla 1

Hale et al. (2019) [58]	Profundo	Necesidad de TC	ANN	98.19	97.9	0.99	99.7	60.4
Yadav et al. (2016) [59]	Híbrido	Necesidad de TC	DT-NLP	-	-	-	89.7	91.9
Miyagawa et al. (2023) [60]	Supervisado	Necesidad de TC	DT	95	-	0.85	-	-
Yang et al. (2023) [62]	Profundo	Identificación de TEC por video	CNN	99	96.6	-	96.1	97.7

**Tabla 1. Desempeño de los modelos de inteligencia artificial (IA) utilizados para el diagnóstico en traumatismo encefalocraneano pediátrico.**

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: TC, tomografía computarizada; ANN, *Artificial Neural Network*; RF, *Random Forest*; DNN, *Deep Neural Network*; RL, Regresión Logística; SVM, *Support Vector Machine*; RFE, *Recursive Feature Elimination*; PCA, *Principal Component Analysis*; DT, *Decision Tree*; NB, *Naive Bayes*; CNN, *Convolutional Neural Network*; NLP, *Natural Language Processing*. Las métricas de desempeño se presentan en términos de precisión, exactitud (*accuracy*), área bajo la curva (AUC), sensibilidad y especificidad. Los valores resaltados en   indican un desempeño superior, mientras que los destacados en   reflejan un rendimiento limitado.

**TABLA 2**

Denominación del estudio	Tipo de Aprendizaje	Modelos de IA	Desenlace evaluado	Precisión (%)	Exactitud (%)	AUC	Sensibilidad (%)	Especificidad (%)
Daley et al. 2022 [36]	Supervisado	RF	Mortalidad	-	82	0.91	-	-
Shahi et al. 2021 [37]	Profundo	ANN	Mortalidad	-	91.9	0.96	100	91.8
	Profundo	ANN	Falla de NOM	-	83.8	0.88	91.7	83.5
	Profundo	ANN	MT	-	90.5	0.90	88.9	90.5
	Profundo	ANN	Éxito NOM sin intervención	-	90.3	0.89	90.4	88.2
Fedorchak et al. 2021 [41]	Supervisado	RF	Recuperación	-	-	0.86	-	-
Iyer et al. 2019. [45]	Supervisado	SVM	Recuperación	-	79	0.86	82	75

Continuación en la siguiente página

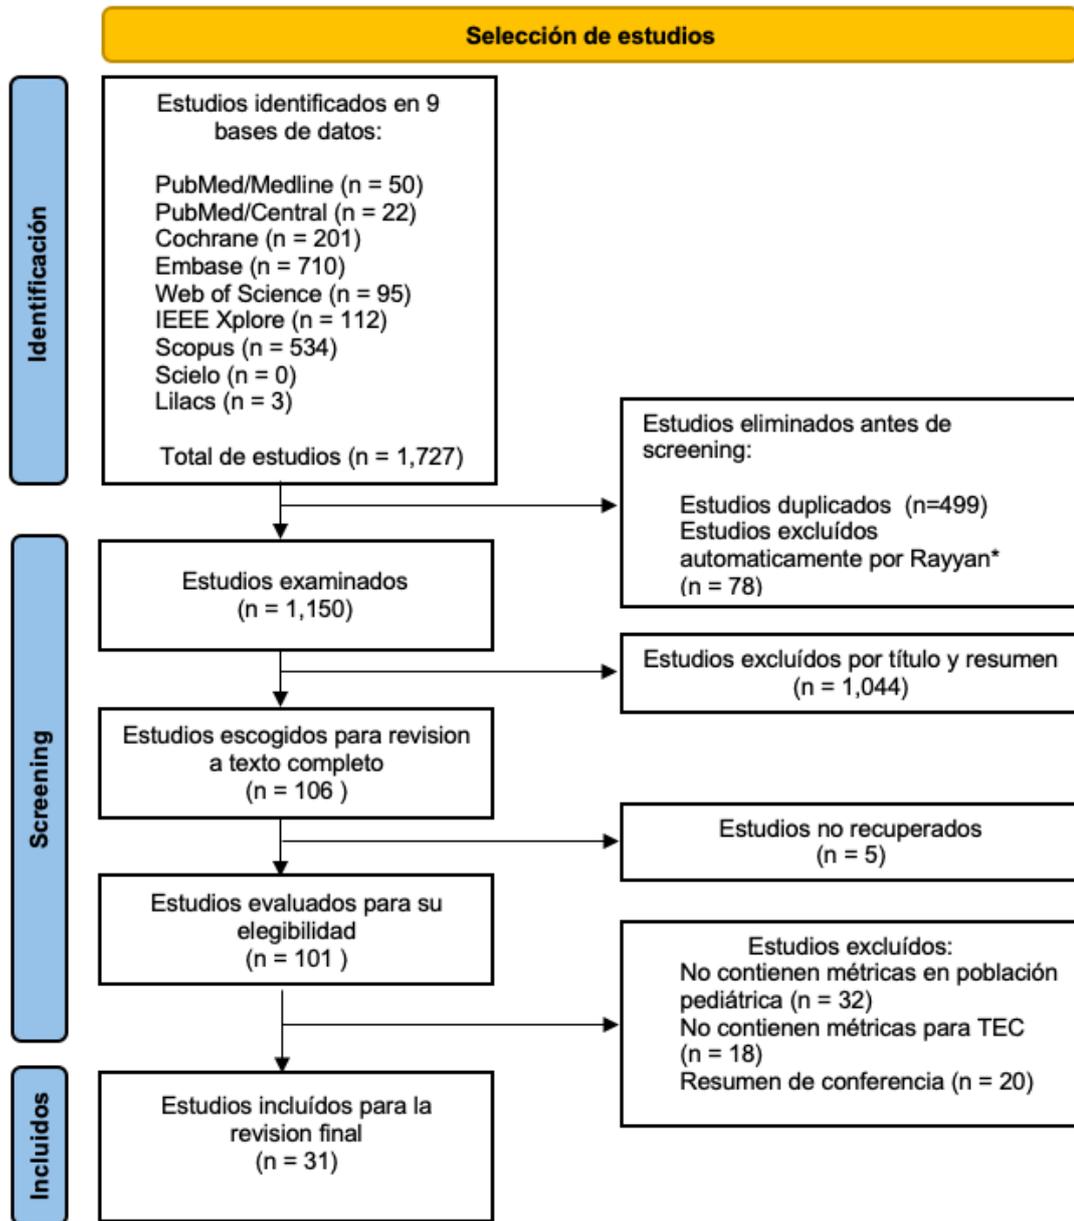
Continuación de la TABLA 2

Fleck et al. 2021 [16]	Híbrido	GFT	Recuperación	-	62.3	-	59.4	65.1
Kim et al. 2021 [49]	Supervisado	DT	Favorabilidad	50	-	0.83	83.33	78.26
	Supervisado	DT	Necesidad de Cirugía	42.86	-	0.71	85.71	63.64
	Supervisado	DT	Mortalidad	35.29	-	0.91	100	78.85
	Supervisado	DT	Recuperación	79.31	-	0.83	76.6	78.57
Greenan et al. 2019 [51]	Supervisado	DT	Favorabilidad	-	90.2	-	68.4	93.6
Tunthanathip et al. 2021 [29]	Supervisado	SVM	Favorabilidad	99	94	0.78	95	60
Hale et al. 2018 [55]	Profundo	ANN	Favorabilidad	98.19	0.27	0.99	99	60.4
Maddux et al. 2021 [57]	No supervisado	CK-M	Morbilidad	-	-	0.85	-	-
Kayhanian et al. 2019 [61]	Supervisado	SVM	Favorabilidad	-	-	-	80	99

**Tabla 2. Desempeño de los modelos de inteligencia artificial (IA) utilizados para el pronóstico en traumatismo encefalocraneano pediátrico.**

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: RF, *Random Forest*; ANN, *Artificial Neural Network*; SVM, *Support Vector Machine*; DT, *Decision Tree*; GFT, *Generalized Feature Transformation* y CK-M, *Cluster K-Means*. Los desenlaces clínicos evaluados incluyen mortalidad, morbilidad, recuperación, favorabilidad, necesidad de cirugía y fracaso del manejo no operatorio (NOM, por sus siglas en inglés *Non-Operative Management*). Las métricas de desempeño se presentan en términos de precisión, exactitud (*accuracy*), área bajo la curva (AUC), sensibilidad y especificidad. Los valores resaltados en   indican un desempeño superior, mientras que los destacados en   reflejan un rendimiento limitado.

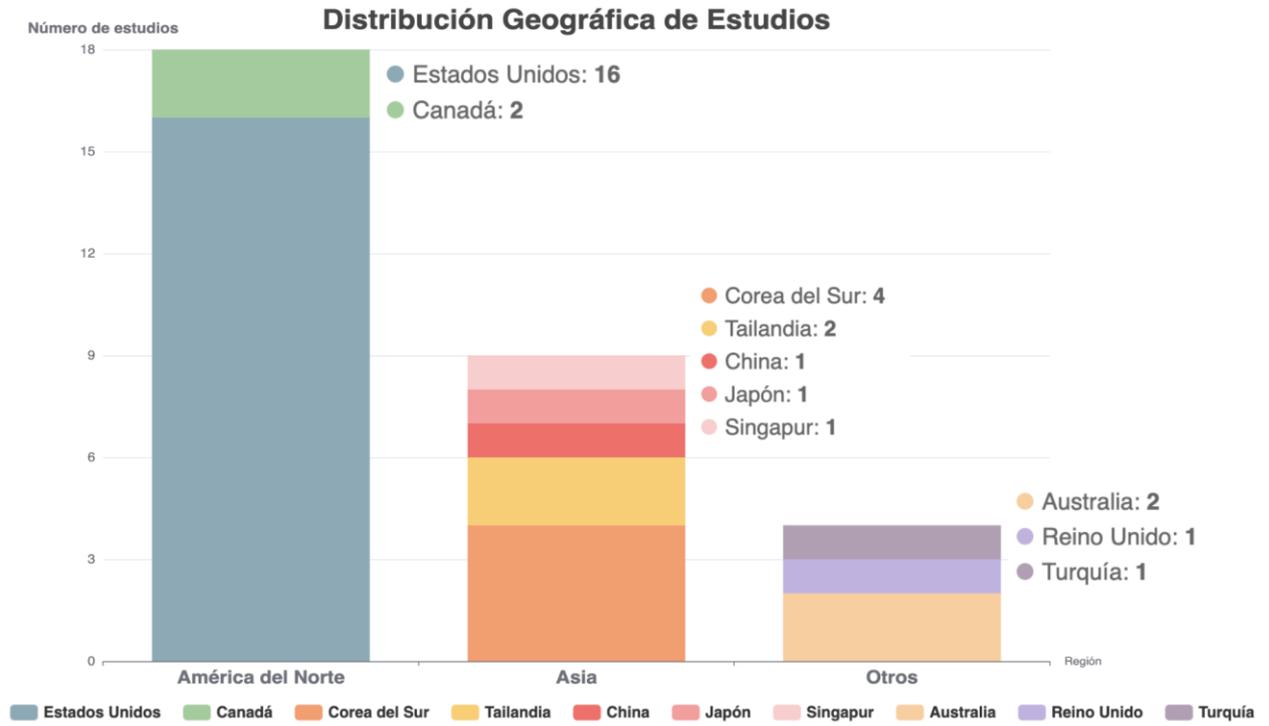
FIGURA 1



**FIGURA 2**



**FIGURA 3**

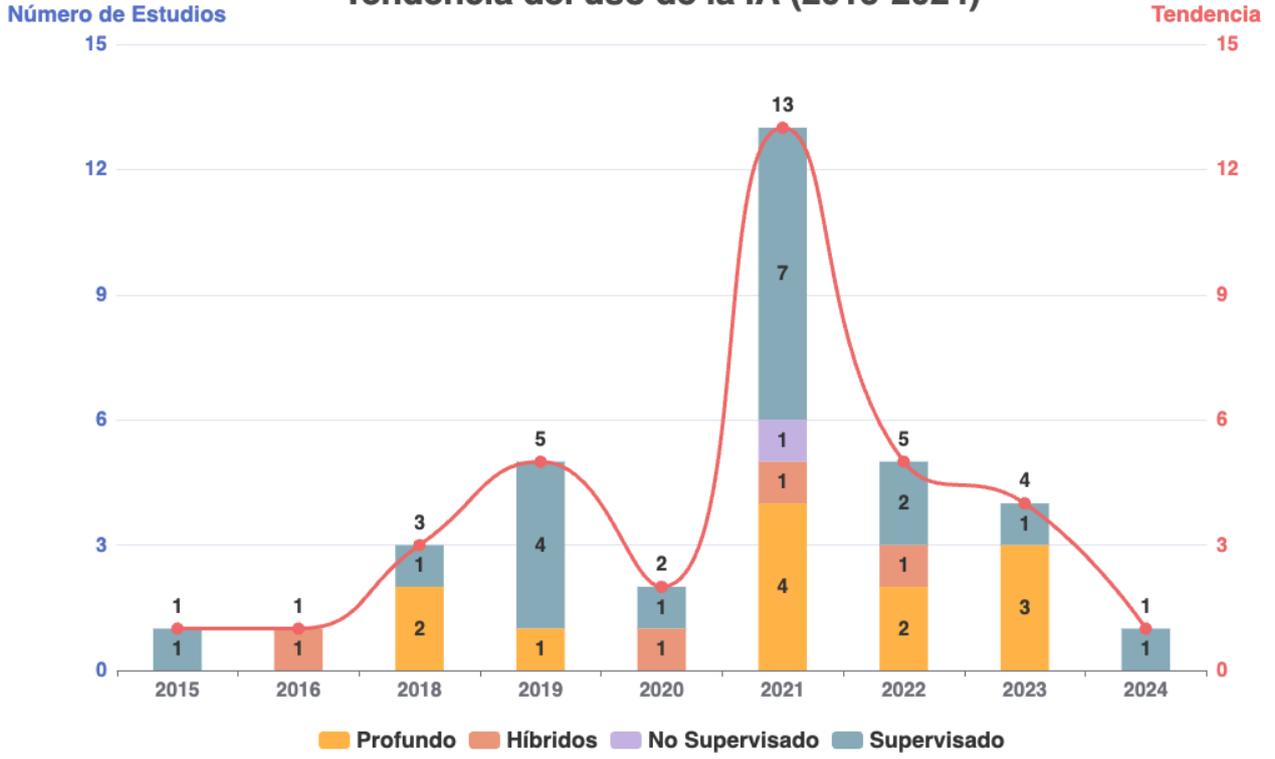


**FIGURA 4**



**FIGURA**

**Tendencia del uso de la IA (2015-2024)**



## XI. ANEXOS

### ANEXO 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 a 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 machine learning durante el diagnóstico, tratamiento o pronóstico.	Población Pediátrica con TEC.  Los datos utilizados en la IA deben incluir datos humanos reales.

### ANEXO 2

VARIABLE	DEFINICIÓN OPERACIONAL	NATURALEZA DE LA VARIABLE	ESCALA	FUENTE DE EXTRACCIÓN	EXPRESIÓN FINAL DE LA VARIABLE
Identificación del estudio					
Denominación del Estudio	Apellido del primer autor, año de publicación	Cualitativa	Nominal	Registro de publicación	Ejm: Rodriguez, 2022
Autor(es)	Nombres de los autores principales	Cualitativa	Nominal	Registro de publicación	Ejm: Rodriguez CA, Vásquez DA, Dueñas F
Año de publicación	Año en que fue publicado el estudio	Cuantitativa	Intervalo	Registro de publicación	2015 2016 2017 2018 2019 2020 2021 2022 2023 2024
País	País en el que se realizó el estudio	Cualitativa	Nominal	Artículo	Ejm: Perú
Código del estudio	Código único asignado de	Cualitativa	Nominal	Registro de publicación	Ejm:DOI 10.24875/CIRU.22000

	publicaciones digitales				446
Características del estudio					
Población	Características específicas de la población	Cualitativa	Dicotómico	Artículo	0= No específica 1= Específica (deportistas, estudiantes, etc)
Grupo etario	Grupo etario evaluado en el estudio	Cualitativo	Nominal	Artículo	0= Neonatos (<1 año) 1= Pre escolares (1-5 años) 2= Escolares (5-12 años) 3= Adolescentes (12-17 años)
Severidad de TEC	Grado de severidad del TEC según criterios médicos	Cualitativa	Nominal	Artículo	0=Niños con TEC leve 1=Niños con TEC moderado 2=Niños con TEC severo 3=No específica
Diseño del estudio	Tipo de estudio realizado	Cualitativa	Nominal	Artículo	0=Estudio observacional 1=Estudio experimental 2=Revisión Sistemática
Tamaño de muestra	Número total de pacientes pediátricos con TEC, imágenes y eventos registrados.	Cuantitativa	Razón	Artículo	Ejm: 150 pacientes, 320 incidentes registrados, 830 imágenes de 150 pacientes recolectadas, etc.
Lugar del estudio	Contexto donde se realizó el estudio	Cualitativa	Nominal	Artículo	0=Ambulatorio 1=Emergencia 2=Unidades de cuidados intensivos(UCI) 3=Otros
Intervención					
Tipo de IA	Nombre del modelo de IA utilizado	Cualitativa	Nominal	Artículo	0= Aprendizaje profundo 1= Aprendizaje automático supervisado 2= Aprendizaje automático no supervisado 3= Modelo híbrido 4= Sistemas difusos 5= Otros(Modelos que no se ajustan claramente a las categorías anteriores o son menos comunes)

Objetivo del estudio	Objetivo descrito por los autores	Cualitativa	Nominal	Artículo	Ejm: Identificar lesiones en TAC cerebral, estimación de tiempo de recuperación, etc.
Área de Aplicación	Área clínica de aplicación de la IA	Cualitativa	Nominal	Artículo	0=Diagnóstico 1=Tratamiento 2=Pronóstico
Comparador	Método que se utiliza para comparar el desempeño de la IA	Cualitativa	Nominal	Artículo	Ejm: Opinión de expertos
Resultados					
Desempeño de la IA	Métrica estadística que evalúa el desempeño de la IA	Cuantitativa	Intervalo	Artículo	Sensibilidad, Especificidad, odds ratio, F1, AUC, significancia u otras medidas que evalúan el desempeño de la IA.
Impacto/Significativo	Nivel de significancia del impacto	Cualitativa	Nominal	Artículo	0=No 1=Si 2=Neutral
Resultados principales	Resultados del uso de IA	Cualitativa	Nominal	Artículo	Ejm: Mejora la precisión diagnóstica
Validación					
Validación del modelo	Tipo de validación utilizada en el Modelo de IA	Cualitativa	Nominal	Artículo	0= Interna 1= Externa 2= Cruzada 3= Otros (Validación pragmática, Revalidación independiente, Benchmarking)
Limitaciones reportadas	Descripción de las limitaciones identificadas por los autores del estudio	Cualitativa	Nominal	Artículo	Ejm: Tamaño de muestra pequeño

## ANEXO 3

### Búsqueda inicial limitada

#### Pubmed/Medline

Número de búsqueda	Estrategia de búsqueda	Número de artículos
#1	Craniocerebral trauma[MeSH Terms]	184,909
#2	"Intracranial injur*"[Title/Abstract] OR "traumatic brain injur*"[Title/Abstract] OR "traumatic cerebral lesion*"[Title/Abstract] OR "mild traumatic brain injur*"[Title/Abstract] OR "Brain Trauma*"[Title/Abstract] OR "Brain injur*"[Title/Abstract] OR "Brain Contusion*"[Title/Abstract] OR "Cerebellar Contusion*"[Title/Abstract] OR "Cerebral Concussion*"[Title/Abstract] OR "Cerebral Contusion*"[Title/Abstract] OR "cerebral trauma"[Title/Abstract] OR "cerebrovascular trauma"[Title/Abstract] OR "Comotio Cerebri"[Title/Abstract] OR "Contusio Cerebri"[Title/Abstract] OR "Cortical Contusion*"[Title/Abstract] OR "Mild Concussion*"[Title/Abstract] OR "posttraumatic encephalopath*"[Title/Abstract] OR "Severe Concussion*"[Title/Abstract] OR "Traumatic Encephalopath*"[Title/Abstract] OR "Minor traumatic brain injur*"[Title/Abstract] OR "cerebrovascular trauma"[Title/Abstract] OR "Cranial CT"[Title/Abstract] OR "Neurosurgery"[Title/Abstract] OR "Glasgow Coma Scale "[Title/Abstract] OR "extracranial injur*"[Title/Abstract] OR "Head Impact* "[Title/Abstract]	142,563
#3	Craniocerebral trauma[MeSH Terms] OR #2	267,375
#4	Artificial Intelligence[MeSH Terms]	206,120
#5	"Algorithm*"[Title/Abstract] OR "Machine Learning"[Title/Abstract] OR "Deep Learning"[Title/Abstract] OR "Natural Language Processing"[Title/Abstract] OR "Computer Vision"[Title/Abstract] OR "Bayes' Theorem"[Title/Abstract] OR "Quantitative Analysis"[Title/Abstract] OR "Mathematical Framework"[Title/Abstract] OR "Clinical Decision Support"[Title/Abstract] OR "Regularized Optical Flow Computation"[Title/Abstract] OR "Spectral Feature Extraction"[Title/Abstract] OR "Prediction tool"[Title/Abstract] OR "Random forest classifier"[Title/Abstract] OR "Prediction Model*"[Title/Abstract] OR "Nomogram"[Title/Abstract] OR "Generalized low-rank models"[Title/Abstract] OR "Partitioning around medoids"[Title/Abstract] OR "Data-driven approaches"[Title/Abstract] OR "Wrapper framework"[Title/Abstract] OR "Random forest"[Title/Abstract] OR "Gradient boosting"[Title/Abstract] OR "Decision tree*"[Title/Abstract] OR "Gaussian naïve Bayes"[Title/Abstract] OR "Artificial Intelligence"[Title/Abstract] OR "Transfer Learning"[Title/Abstract] OR "Ensemble Learning"[Title/Abstract] OR "Neural network*"[Title/Abstract] OR "CNN"[Title/Abstract] OR "Gradient Boosting Machine"[Title/Abstract] OR "GBM"[Title/Abstract] OR "XGBoost"[Title/Abstract] OR "Adaboost"[Title/Abstract] OR "ResNet-50"[Title/Abstract] OR "ResNet"[Title/Abstract] OR "Radiomic*"[Title/Abstract] OR "Fine-Gray"[Title/Abstract] OR "Competitive Risk Model"[Title/Abstract] OR "Naive Bayesian"[Title/Abstract] OR "Risk Prediction"[Title/Abstract] OR "Risk-Prediction"[Title/Abstract]	791,796
#6	Artificial Intelligence[MeSH Terms] OR #5	859,252
#7	#3 AND #6	5,900
#8	"Neonate*"[Title/Abstract] OR "newborn*"[Title/Abstract] OR "infant*"[Title/Abstract] OR "baby"[Title/Abstract] OR "babies"[Title/Abstract] OR "toddler*"[Title/Abstract] OR "Child*"[Title/Abstract] OR "children"[Title/Abstract] OR "Adolescen*"[Title/Abstract] OR "Adolescents"[Title/Abstract] OR "Adolescence"[Title/Abstract] OR "Teen*"[Title/Abstract]	2,750,345

Número de búsqueda	Estrategia de búsqueda	Número de artículos
	OR "Teenagers"[Title/Abstract] OR "Teenager"[Title/Abstract] OR "Youth*"[Title/Abstract] OR "Youths"[Title/Abstract] OR "Paediatric*"[Title/Abstract] OR "paediatric*"[Title/Abstract]	
#9	#7 AND #8	674
#10	#9 Filters: from 2015 - 2024	521
#11	#10 Filters: Clinical Trial	11
#12	#10 Filters: Systematic review	24
#13	#10 Filters: Observational study	15
Total de estudios encontrados en esta base de datos:		50

\*D/T/P: diagnóstico, tratamiento y pronóstico

## PMC

Número de búsqueda	Estrategia de búsqueda	Número de artículos
#1	Craniocerebral Trauma[MeSH Terms]	20,833
#2	"Intracranial injur*"[Title/Abstract] OR "traumatic brain injur*"[Title/Abstract] OR "traumatic cerebral lesion*"[Title/Abstract] OR "mild traumatic brain injur*"[Title/Abstract] OR "Brain Trauma*"[Title/Abstract] OR "Brain injur*"[Title/Abstract] OR "Brain Contusion*"[Title/Abstract] OR "Cerebellar Contusion*"[Title/Abstract] OR "Cerebral Concussion*"[Title/Abstract] OR "Cerebral Contusion*"[Title/Abstract] OR "cerebral trauma"[Title/Abstract] OR "cerebrovascular trauma"[Title/Abstract] OR "Commotio Cerebri"[Title/Abstract] OR "Contusio Cerebri"[Title/Abstract] OR "Cortical Contusion*"[Title/Abstract] OR "Mild Concussion*"[Title/Abstract] OR "posttraumatic encephalopath*"[Title/Abstract] OR "Severe Concussion*"[Title/Abstract] OR "Traumatic Encephalopath*"[Title/Abstract] OR "Minor traumatic brain injur*"[Title/Abstract] OR "cerebrovascular trauma"[Title/Abstract] OR "Cranial CT"[Title/Abstract] OR "Neurosurgery"[Title/Abstract] OR "Glasgow Coma Scale "[Title/Abstract] OR "extracranial injur*"[Title/Abstract] OR "Head Impact* "[Title/Abstract]	2,401
#3	Craniocerebral Trauma[MeSH Terms] OR #2	22,979
#4	Artificial Intelligence[MeSH Terms]	57,906
#5	"Algorithm*"[Title/Abstract] OR "Machine Learning"[Title/Abstract] OR "Deep Learning"[Title/Abstract] OR "Natural Language Processing"[Title/Abstract] OR "Computer Vision"[Title/Abstract] OR "Bayes' Theorem"[Title/Abstract] OR "Quantitative Analysis"[Title/Abstract] OR "Mathematical Framework"[Title/Abstract] OR "Clinical Decision Support"[Title/Abstract] OR "Regularized Optical Flow Computation"[Title/Abstract] OR "Spectral Feature Extraction"[Title/Abstract] OR "Prediction tool"[Title/Abstract] OR "Random forest classifier"[Title/Abstract] OR "Prediction Model*"[Title/Abstract] OR "Nomogram"[Title/Abstract] OR "Generalized low-rank models"[Title/Abstract] OR "Partitioning around medoids"[Title/Abstract] OR "Data-driven approaches"[Title/Abstract] OR "Wrapper framework"[Title/Abstract] OR "Random forest"[Title/Abstract] OR "Gradient boosting"[Title/Abstract] OR "Decision tree*"[Title/Abstract] OR "Gaussian naïve Bayes"[Title/Abstract] OR "Artificial	104,649

	Intelligence"[Title/Abstract] OR "Transfer Learning"[Title/Abstract] OR "Ensemble Learning"[Title/Abstract] OR "Neural network*"[Title/Abstract] OR "CNN"[Title/Abstract] OR "Gradient Boosting Machine"[Title/Abstract] OR "GBM"[Title/Abstract] OR "XGBoost"[Title/Abstract] OR "Adaboost"[Title/Abstract] OR "ResNet-50"[Title/Abstract] OR "ResNet"[Title/Abstract] OR "Radiomic*"[Title/Abstract] OR "Fine-Gray"[Title/Abstract] OR "Competitive Risk Model"[Title/Abstract] OR "Naive Bayesian"[Title/Abstract] OR "Risk Prediction"[Title/Abstract] OR "Risk-Prediction"[Title/Abstract]	
#6	Artificial Intelligence[MeSH Terms] OR #5	139,357
#7	#3 AND #6	256
#8	("Neonate*"[Title/Abstract] OR "newborn*"[Title/Abstract] OR "infant*"[Title/Abstract] OR "baby"[Title/Abstract] OR "babies"[Title/Abstract] OR "toddler*"[Title/Abstract] OR "Child*"[Title/Abstract] OR "children"[Title/Abstract] OR "Adolescen*"[Title/Abstract] OR "Adolescents"[Title/Abstract] OR "Adolescence"[Title/Abstract] OR "Teen*"[Title/Abstract] OR "Teenagers"[Title/Abstract] OR "Teenager"[Title/Abstract] OR "Youth*"[Title/Abstract] OR "Youths"[Title/Abstract] OR "Pediatric*"[Title/Abstract] OR "paediatric*"[Title/Abstract])	328,714
#9	#7 AND #8	25
#10	Filters: Publication date from 2015/01/01	23
#11	#10 Filters: Clinical Trial	2
#12	#10 Filters: Systematic review	0
#13	#10 Filters: Observational study	20
Total de estudios encontrados en esta base de datos:		22

\*D/T/P: diagnóstico, tratamiento y pronóstico

## Cochrane Library

Número de búsqueda	Estrategia de búsqueda	Número de artículos
#1	MeSH descriptor: [Craniocerebral trauma] explode all trees	5,571
#2	('Intracranial injur*' OR 'traumatic brain injur*' OR 'traumatic cerebral lesion*' OR 'mild traumatic brain injur*' OR 'Brain Trauma*' OR 'Brain injur*' OR 'Brain Contusion*' OR 'Cerebellar Contusion*' OR 'Cerebral Concussion*' OR 'Cerebral Contusion*' OR 'cerebral trauma' OR 'cerebrovascular trauma' OR 'Comotio Cerebri' OR 'Contusio Cerebri' OR 'Cortical Contusion*' OR 'Mild Concussion*' OR 'posttraumatic encephalopath*' OR 'Severe Concussion*' OR 'Traumatic Encephalopath*' OR 'Minor traumatic brain injur*' OR 'cerebrovascular trauma' OR 'Cranial CT' OR 'Neurosurgery' OR 'Glasgow Coma Scale' OR 'extracranial injur*' OR 'Head Impact*'):ti,ab,kw	20,797
#3	#1 OR #2	22,308
#4	MeSH descriptor: [Artificial Intelligence] explode all trees	3,279
#5	('Algorithm*' OR 'Machine Learning' OR 'Deep Learning' OR 'Natural Language Processing' OR 'Computer Vision' OR 'Bayes' Theorem' OR 'Quantitative Analysis' OR 'Mathematical Framework' OR 'Clinical Decision Support' OR 'Regularized Optical Flow Computation' OR 'Spectral Feature Extraction' OR 'Prediction tool' OR 'Random forest	66,844

	classifier' OR 'Prediction Model*' OR 'Nomogram' OR 'Generalized low-rank models' OR 'Partitioning around medoids' OR 'Data-driven approaches' OR 'Wrapper framework' OR 'Random forest' OR 'Gradient boosting' OR 'Decision tree*' OR 'Gaussian naïve Bayes' OR 'Artificial Intelligence' OR 'Transfer Learning' OR 'Ensemble Learning' OR 'Neural network*' OR 'CNN' OR 'Gradient Boosting Machine' OR 'GBM' OR 'XGBoost' OR 'Adaboost' OR 'ResNet-50' OR 'ResNet' OR 'Radiomic*' OR 'Fine-Gray' OR 'Competitive Risk Model' OR 'Naive Bayesian' OR 'Risk Prediction' OR 'Risk-Prediction');ti,ab,kw	
#6	#4 OR #5	68,089
#7	MeSH descriptor: [Child] explode all trees	82,724
#8	('Neonate*' OR 'newborn*' OR 'infant*' OR 'baby' OR 'babies' OR 'toddler*' OR 'child*' OR 'children' OR 'adolescenc*' OR 'adolescents' OR 'adolescence' OR 'teen*' OR 'teenagers' OR 'teenager' OR 'youth*' OR 'youths');ti,ab,kw	371,115
#9	#7 OR #8	371,115
#10	#3 AND #6 AND #9	302
#11	#10 Filters: from 2015 - 2024	201
#12	#10 Filter: Cochrane Reviews	9
#13	#10 Filter: Trials	192
Total de estudios encontrados en esta base de datos:		201

\*D/T/P: diagnóstico, tratamiento y pronóstico

## Búsqueda completa

### Embase

Número de búsqueda	Estrategia de búsqueda	Número de artículos
#1	Traumatic brain injury/	71,189
#2	("Intracranial injur*" or "traumatic brain injur*" or "traumatic cerebral lesion*" or "mild traumatic brain injur*" or "Brain Trauma*" or "Brain injur*" or "Brain Contusion*" or "Cerebellar Contusion*" or "Cerebral Concussion*" or "Cerebral Contusion*" or "cerebral trauma" or "cerebrovascular trauma" or "Commotio Cerebri" or "Contusio Cerebri" or "Cortical Contusion*" or "Mild Concussion*" or "posttraumatic encephalopath*" or "Severe Concussion*" or "Traumatic Encephalopath*" or "Minor traumatic brain injur*" or "cerebrovascular trauma" or "Cranial CT" or "Neurosurgery" or "Glasgow Coma Scale" or "extracranial injur*" or "Head Impact*").mp. [mp=title, abstract, heading word, drug trade name, original title, device manufacturer, drug manufacturer, device trade name, keyword heading word, floating subheading word, candidate term word]	334,599
#3	#1 OR #2	334,599
#4	machine learning/	131,594
#5	("Algorithm*" or "Machine Learning" or "Deep Learning" or "Natural Language Processing" or "Computer Vision" or "Bayes' Theorem" or "Quantitative Analysis" or "Mathematical Framework" or "Clinical Decision Support" or "Regularized Optical Flow Computation" or "Spectral Feature Extraction" or "Prediction tool" or "Random forest classifier" or "Prediction	1,596,061

	Model* or "Nomogram" or "Generalized low-rank models" or "Partitioning around medoids" or "Data-driven approaches" or "Wrapper framework" or "Random forest" or "Gradient boosting" or "Decision tree*" or "Gaussian naïve Bayes" or "Artificial Intelligence" or "Transfer Learning" or "Ensemble Learning" or "Neural network*" or "CNN" or "Gradient Boosting Machine" or "GBM" or "XGBoost" or "Adaboost" or "ResNet-50" or "ResNet" or "Radiomic*" or "Fine-Gray" or "Competitive Risk Model" or "Naive Bayesian" or "Risk Prediction" or "Risk-Prediction").mp. [mp=title, abstract, heading word, drug trade name, original title, device manufacturer, drug manufacturer, device trade name, keyword heading word, floating subheading word, candidate term word]	
#6	#4 OR #5	1,594,814
#7	#3 AND #6	13,440
#8	(Neonate* or newborn* or infant* or baby or babies or toddler* or Child* or children or Adolescen* or Adolescents or Adolescence or Teen* or Teenagers or Teenager or Youth* or Youths or Pediatric* or paediatric*).mp. [mp=title, abstract, heading word, drug trade name, original title, device manufacturer, drug manufacturer, device trade name, keyword heading word, floating subheading word, candidate term word]	5,193,016
#9	#7 AND #8	2,434
#10	#9 Filters: from 2015 - 2024	1,624
#11	#10 Filters: Clinical Trial	16
#12	#10 Filters: Systematic review	72
#13	#10 AND ("observational study" or "cohort study" or "case-control study" or "cross-sectional study" or "prospective study" or "retrospective study" or "longitudinal study" or "epidemiological study" or "observational research").mp. [mp=title, abstract, heading word, drug trade name, original title, device manufacturer, drug manufacturer, device trade name, keyword heading word, floating subheading word, candidate term word]	622
Total de estudios encontrados en esta base de datos:		710

\*D/T/P: diagnóstico, tratamiento y pronóstico

## Web of science

Número de búsqueda	Estrategia de búsqueda	Número de artículos
#1	AB=(“Traumatic brain injuries” OR “traumatic brain injur*” OR "Intracranial injur*" OR "traumatic cerebral lesion*" OR "mild traumatic brain injur*" OR "Brain Trauma*" OR "Brain injur*" OR "Brain Contusion*" OR "Cerebellar Contusion*" OR "Cerebral Concussion*" OR "Cerebral Contusion*" OR "cerebral trauma" OR "cerebrovascular trauma" OR "Commotio Cerebri" OR "Contusio Cerebri" OR "Cortical Contusion*" OR "Mild Concussion*" OR "post-traumatic encephalopath*" OR "Severe Concussion*" OR "Traumatic encephalopath*" OR "Minor traumatic brain injur*" OR "cerebrovascular trauma" OR "Cranial CT" OR "extracranial injur*" OR "Head Impact**”) OR TI=(“Traumatic brain injuries” OR “traumatic brain injur*” OR "Intracranial injur*" OR "traumatic cerebral lesion*" OR "mild traumatic brain injur*" OR "Brain Trauma*" OR "Brain injur*" OR "Brain Contusion*" OR "Cerebellar Contusion*" OR "Cerebral Concussion*" OR "Cerebral Contusion*" OR "cerebral trauma" OR "cerebrovascular trauma" OR "Commotio Cerebri" OR "Contusio Cerebri" OR "Cortical Contusion*" OR "Mild Concussion*" OR "post-traumatic encephalopath*" OR "Severe Concussion*" OR "Traumatic encephalopath*" OR	78,573

	"Minor traumatic brain injur*" OR "cerebrovascular trauma" OR "Cranial CT" OR "extracranial injur*" OR "Head Impact*")	
#2	TI=("Artificial intelligence" OR "machine learning" OR Algorithm* OR "Deep Learning" OR "Natural Language Processing" OR "Computer Vision" OR "Bayes' Theorem" OR "Quantitative Analysis" OR "Mathematical Framework" OR "Clinical Decision Support System" OR "Regularized Optical Flow Computation" OR "Spectral Feature Extraction" OR "Prediction tool" OR "Random forest classifier" OR "Prediction Model*" OR Nomogram OR "Generalized low-rank models" OR "Partitioning around medoids" OR "Data-driven approaches" OR "Wrapper framework" OR "Random forest" OR "Gradient boosting" OR "Decision tree*" OR "Gaussian naïve Bayes" OR "Artificial Intelligence" OR "Transfer Learning" OR "Ensemble Learning" OR "Neural network*" OR CNN OR "Gradient Boosting Machine" OR GBM OR XGBoost OR Adaboost OR "ResNet-50" OR "ResNet" OR Radiomic* OR "Fine-Gray" OR "Competitive Risk Model" OR "Naive Bayesian" OR "Risk Prediction" OR "Risk-Prediction") OR AB=("Artificial intelligence" OR "machine learning" OR Algorithm* OR "Deep Learning" OR "Natural Language Processing" OR "Computer Vision" OR "Bayes' Theorem" OR "Quantitative Analysis" OR "Mathematical Framework" OR "Clinical Decision Support System" OR "Regularized Optical Flow Computation" OR "Spectral Feature Extraction" OR "Prediction tool" OR "Random forest classifier" OR "Prediction Model*" OR Nomogram OR "Generalized low-rank models" OR "Partitioning around medoids" OR "Data-driven approaches" OR "Wrapper framework" OR "Random forest" OR "Gradient boosting" OR "Decision tree*" OR "Gaussian naïve Bayes" OR "Artificial Intelligence" OR "Transfer Learning" OR "Ensemble Learning" OR "Neural network*" OR CNN OR "Gradient Boosting Machine" OR GBM OR XGBoost OR Adaboost OR "ResNet-50" OR "ResNet" OR Radiomic* OR "Fine-Gray" OR "Competitive Risk Model" OR "Naive Bayesian" OR "Risk Prediction" OR "Risk-Prediction")	1,830,910
#3	TS=(Child* OR Neonate* OR newborn* OR infant* OR baby OR babies OR toddler* OR child* OR children OR adolescen* OR adolescents OR adolescence OR teen* OR teenagers OR teenager OR youth* OR youths)	1,973,301
#4	#1 AND #2 AND #3	293
#5	#4 Refined by Publication years: 2015 - 2024	246
#6	#5 AND TS=("clinical trial" OR "randomized trial" OR "single blind*" OR "single mask*" OR "double blind*" OR "double mask*" OR "triple blind*" OR "triple mask*" OR placebo*)	7
#7	#5 AND TS=("observational stud*" OR "cohort study" OR "case-control study" OR "cross-sectional study" OR "longitudinal study")	38
#9	#5 AND TS=("systematic review" OR review)	50
Total de estudios encontrados en esta base de datos:		95

\*D/T/P: diagnóstico, tratamiento y pronóstico

## IEEX

Número de búsqueda	Estrategia de búsqueda	Número de artículos
#1	"Mesh_Terms": "Brain Injuries, Traumatic"	54
#2	Intracranial injury OR traumatic brain injury OR traumatic cerebral lesion OR mild traumatic brain injury OR Brain Trauma OR Brain injury OR Brain Contusion OR Cerebellar Contusion OR Cerebral Concussion OR Cerebral Contusion OR cerebral trauma OR cerebrovascular	14,460

	trauma OR Commotio Cerebri OR Contusio Cerebri OR Cortical Contusion OR Mild Concussion OR posttraumatic encephalopathy OR Severe Concussion OR Traumatic Encephalopathy OR Minor traumatic brain injury OR Cranial CT OR Neurosurgery OR Glasgow Coma Scale OR extracranial injury OR Head Impact	
#3	#1 OR #2	14,460
#4	"Mesh_Terms": "Machine Learning"	2,648
#5	Algorithm OR Machine Learning OR Deep Learning OR Natural Language Processing OR Computer Vision OR Bayes' Theorem OR Quantitative Analysis OR Mathematical Framework OR Clinical Decision Support OR Regularized Optical Flow Computation OR Spectral Feature Extraction OR Prediction tool OR Random forest classifier OR Prediction Model OR Nomogram OR Generalized low-rank models OR Partitioning around medoids OR Data-driven approaches OR Wrapper framework OR Random forest OR Gradient boosting OR Decision tree OR Gaussian naïve Bayes OR Artificial Intelligence OR Transfer Learning OR Ensemble Learning OR Neural network OR CNN OR Gradient Boosting Machine OR GBM OR XGBoost OR Adaboost OR ResNet-50 OR ResNet OR Radiomics OR Fine-Gray OR Competitive Risk Model OR Naive Bayesian OR Risk Prediction OR Risk-Prediction	1,886,771
#6	#4 OR #5	1,886,771
#7	#3 AND #6	6,549
#8	Neonate OR newborn OR infant OR baby OR babies OR toddler OR Child OR children OR Adolescent OR Adolescents OR Adolescence OR Teen OR Teenagers OR Teenager OR Youth OR Youths OR Pediatric OR paediatric	52,101
#9	#7 AND #8	343
#10	#9 Filters: from 2015 - 2024	254
#11	#10 Filter: Journals	110
#12	#10 Filter: Early Access Articles	2
Total de estudios encontrados en esta base de datos:		112

\*D/T/P: diagnóstico, tratamiento y pronóstico

## Scopus

Número de búsqueda	Estrategia de búsqueda	Número de artículos
#1	TITLE-ABS-KEY(("Craniocerebral trauma" OR "traumatic brain injuries" OR "traumatic brain injur*" OR "Intracranial injur*" OR "traumatic cerebral lesion*" OR "mild traumatic brain injur*" OR "Brain Trauma*" OR "Brain injur*" OR "Brain Contusion*" OR "Cerebellar Contusion*" OR "Cerebral Concussion*" OR "Cerebral Contusion*" OR "cerebral trauma" OR "cerebrovascular trauma" OR "Commotio Cerebri" OR "Contusio Cerebri" OR "Cortical Contusion*" OR "Mild Concussion*" OR "post-traumatic encephalopath*" OR "Severe Concussion*" OR "Traumatic encephalopath*" OR "Minor traumatic brain injur*" OR "cerebrovascular trauma" OR "Cranial CT" OR "extracranial injur*" OR "Head Impact*"))	217,641
#2	TITLE-ABS-KEY(("Artificial intelligence" OR "machine learning" OR Algorithm* OR "Deep Learning" OR "Natural Language Processing" OR "Computer Vision" OR "Bayes' Theorem" OR "Quantitative Analysis" OR "Mathematical Framework" OR "Clinical Decision Support System" OR "Regularized Optical Flow Computation" OR "Spectral Feature Extraction" OR "Prediction tool" OR "Random forest classifier" OR "Prediction	6,630,163

	Model* OR Nomogram OR "Generalized low-rank models" OR "Partitioning around medoids" OR "Data-driven approaches" OR "Wrapper framework" OR "Random forest" OR "Gradient boosting" OR "Decision tree*" OR "Gaussian naïve Bayes" OR "Artificial Intelligence" OR "Transfer Learning" OR "Ensemble Learning" OR "Neural network*" OR CNN OR "Gradient Boosting Machine" OR GBM OR XGBoost OR Adaboost OR "ResNet-50" OR "ResNet" OR Radiomic* OR "Fine-Gray" OR "Competitive Risk Model" OR "Naive Bayesian" OR "Risk Prediction" OR "Risk-Prediction")	
#3	TITLE-ABS-KEY(Child* OR Neonate* OR newborn* OR infant* OR baby OR babies OR toddler* OR child* OR children OR adolescen* OR adolescents OR adolescence OR teen* OR teenagers OR teenager OR youth* OR youths)	6,373,132
#4	#1 AND #2 AND #3	1,814
#6	#4 AND TITLE-ABS-KEY("clinical trial" OR "randomized trial" OR "single blind*" OR "single mask*" OR "double blind*" OR "double mask*" OR "triple blind*" OR "triple mask*" OR placebo*) AND PUBYEAR > 2014 AND PUBYEAR < 2025	104
#7	#4 AND TITLE-ABS-KEY ("systematic review" OR review) AND PUBYEAR > 2014 AND PUBYEAR < 2025	186
#8	#4 AND TITLE-ABS-KEY ("observational stud*" OR "cohort study" OR "case-control study" OR "cross-sectional study" OR "longitudinal study") AND PUBYEAR > 2014 AND PUBYEAR < 2025	244
Total de estudios encontrados en esta base de datos:		534

D/T/P: diagnóstico, tratamiento y pronóstico

## Scielo

Número de búsqueda	Estrategia de búsqueda	Número de artículos
#1	"trauma craneoencefálico" OR "traumatismo craneoencefálico" OR "lesiones cerebrales traumáticas" OR "lesiones cerebrales" OR "lesión cerebral traumática leve" OR "trauma craneal" OR "contusión cerebral" OR "conmoción cerebral" OR "lesión intracraneal" OR "contusión del cerebelo" OR "trauma cerebral" OR "trauma cerebrovascular" OR "Comotio Cerebri" OR "Contusio Cerebri" OR "contusión cortical" OR "conmoción leve" OR "encefalopatía postraumática" OR "conmoción severa" OR "encefalopatía traumática" OR "lesión cerebral leve" OR "trauma craneal leve" OR "TC craneal" OR "neurocirugía" OR "Escala de Coma de Glasgow" OR "lesión extracraneal" OR "impacto en la cabeza"	1,349
#2	"inteligencia artificial" OR "aprendizaje automático" OR "algoritmos" OR "aprendizaje profundo" OR "procesamiento de lenguaje natural" OR "visión por computadora" OR "teorema de Bayes" OR "análisis cuantitativo" OR "marco matemático" OR "soporte a la toma de decisiones clínicas" OR "computación de flujo óptico regularizado" OR "extracción de características espectrales" OR "herramienta de predicción" OR "clasificador de bosques aleatorios" OR "modelo de predicción" OR normograma OR "modelos de rango bajo generalizados" OR "agrupamiento alrededor de medoides" OR "enfoques impulsados por datos" OR "framework de envoltura" OR "bosques aleatorios" OR "impulso de gradiente" OR "árbol de decisiones" OR "Bayes ingenuo" OR "inteligencia artificial" OR "aprendizaje por transferencia" OR "aprendizaje en conjunto" OR "redes neuronales" OR "redes neuronales convolucionales" OR "máquina de impulso de gradiente" OR XGBoost OR Adaboost OR "ResNet-50" OR ResNet OR radiómica OR "modelo de riesgos competitivos" OR "naive bayesian" OR "predicción de riesgos"	5,541
#3	#1 AND #2	11

#4	niño OR neonato OR "recién nacido" OR infante OR bebé OR bebés OR "niño pequeño" OR niños OR adolescente OR adolescentes OR adolescencia OR joven OR jóvenes	65,341
#5	#3 AND #4	1
#6	#5 Filtro 2015-2024	0
#7	#6 Filtro Tipo de Literatura: Artículo de Revisión	0
#8	#6 AND "ensayo clínico" OR "ensayo aleatorizado" OR "simple ciego*" OR "máscara única" OR "doble ciego*" OR "doble máscara" OR "triple ciego" OR "triple máscara" OR placebo	0
#9	#6 AND "estudio observacional*" OR "estudio de cohorte" OR "estudio de casos y controles" OR "estudio transversal" OR "estudio longitudinal"	0
Total de estudios encontrados en esta base de datos:		0

\*D/T/P: diagnóstico, tratamiento y pronóstico

## Lilacs

Número de búsqueda	Estrategia de búsqueda	Número de artículos
#1	"trauma craneoencefálico" OR "lesiones cerebrales traumáticas" OR "lesiones cerebrales" OR "lesión cerebral traumática leve" OR "trauma craneal" OR "contusión cerebral" OR "conmoción cerebral" OR "lesión intracraneal" OR "contusión del cerebelo" OR "trauma cerebral" OR "trauma cerebrovascular" OR "Comotio Cerebri" OR "Contusio Cerebri" OR "contusión cortical" OR "conmoción leve" OR "encefalopatía postraumática" OR "conmoción severa" OR "encefalopatía traumática" OR "lesión cerebral leve" OR "trauma craneal leve" OR "TC craneal" OR "neurocirugía" OR "Escala de Coma de Glasgow" OR "lesión extracraneal" OR "impacto en la cabeza"	2,614
#2	"inteligencia artificial" OR "aprendizaje automático" OR "algoritmos" OR "aprendizaje profundo" OR "procesamiento de lenguaje natural" OR "visión por computadora" OR "teorema de Bayes" OR "análisis cuantitativo" OR "marco matemático" OR "soporte a la toma de decisiones clínicas" OR "computación de flujo óptico regularizado" OR "extracción de características espectrales" OR "herramienta de predicción" OR "clasificador de bosques aleatorios" OR "modelo de predicción" OR "nomograma" OR "modelos de rango bajo generalizados" OR "agrupamiento alrededor de medoides" OR "enfoques impulsados por datos" OR "framework de envoltura" OR "bosques aleatorios" OR "impulso de gradiente" OR "árbol de decisiones" OR "Bayes ingenuo" OR "inteligencia artificial" OR "aprendizaje por transferencia" OR "aprendizaje en conjunto" OR "redes neuronales" OR "redes neuronales convolucionales" OR "máquina de impulso de gradiente" OR "XGBoost" OR "Adaboost" OR "ResNet-50" OR "ResNet" OR "radiómica" OR "modelo de riesgos competitivos" OR "naive bayesian" OR "predicción de riesgos"	5,592
#3	#1 AND #2	31
#4	"niño" OR "neonato" OR "recién nacido" OR "infante" OR "bebé" OR "bebés" OR "niño pequeño" OR "niños" OR "adolescente" OR "adolescentes" OR "adolescencia" OR "joven" OR "jóvenes"	226,155
#5	#3 AND #4	13
#6	#5 Filters: from 2015 - 2024	3

#7	#6 Filtro: Ensayo clínico	1
#8	#6 Filtro: Revisión sistemática	0
#9	#6 Filtro: Estudio Observacional	2
Total de estudios encontrados en esta base de datos:		3

\*D/T/P: diagnóstico, tratamiento y pronóstico

## ANEXO 4

# Criterios de elegibilidad

**Revisor:** \_\_\_\_\_  
**Denominación del estudio:** \_\_\_\_\_  
**Código del estudio:** \_\_\_\_\_  
**Fecha de realización:** \_\_\_\_\_

### Criterios de inclusión

- Tipo de estudio:** Estudios observacionales prospectivos y/o retrospectivos, ensayos clínicos controlados, revisiones sistemáticas y metanálisis.
- Población:** Estudios en niños y adolescentes (<18 años).
- Temática:** Estudios sobre trauma encefalocraneano que usan modelos de Inteligencia artificial.
- Métrica de Evaluación:** Estudios que evalúen el desempeño de la Inteligencia Artificial mediante métricas estadísticas como sensibilidad, especificidad, área bajo la curva, puntuación F1 o precisión de la predicción.
- Año de publicación:** Estudios publicados a partir de enero del 2015 hasta el primer semestre del 2024.
- Geografía:** Estudios realizados en cualquier región geográfica.
- Idioma:** No se restringe la búsqueda respecto al idioma

### Criterios de exclusión

- Estudio descriptivo sin métricas reportadas.
- Estudios no publicados, como artículos de conferencias y proyectos de tesis cargados en línea.
- Estudios de revisión, carta a editores, comentarios.

### Notas

-----  
-----  
-----  
-----  
-----  
-----  
-----  
-----

ANEXO 5

Tabla de extracción de datos

Revisor:

Denominación del estudio: \_\_\_\_\_

Código del estudio: \_\_\_\_\_

Fecha de realización: \_\_\_\_\_

Bibliometría	Componente (definición)	Detalles (expresión final)
Identificación del estudio		
Denominación del Estudio	Apellido del primer autor, año de publicación.	Ejm: Rodriguez, 2022
Autor(Es)	Nombre(s) del autor(es)	Ejm: Rodriguez CA, Vásquez DA, Dueñas F
Año de publicación	Año que fue publicado	Ejm: 2022
País	País en el que se realizó el estudio	Ejm: Perú
Código del Estudio	Código único asignado de publicaciones digitales	DOI (Digital Object Identifier) de cada estudio. Ejm: DOI 10.24875/CIRU.22000446
Características del estudio		
Población	Características específicas de la población	0= No especifica 1= Específica (Deportistas,estudiantes,etc)
Grupo etario	Grupo etario evaluado en el estudio	0= Neonatos (<1 año) 1= Pre escolares (1-5 años) 2= Escolares (5-12 años) 3= Adolescentes (12-17 años)
Severidad de TEC	Grado de severidad del TEC según criterios médicos	0= Niños con TEC leve 1= Niños con TEC moderado 2= Niños con TEC severo 3= No especifica

Diseño de estudio	Tipo de estudio realizado	0= Estudio observacional 1= Estudio experimental 2= Revisión Sistemática
Tamaño de muestra	Número total de pacientes pediátricos con TEC o de datos utilizados (imágenes, videos, fotografías)	Ejm: 150 pacientes, 320 incidentes registrados, 830 imágenes de 150 pacientes recolectadas, etc.
Lugar del estudio	Contexto donde se realizó el estudio	0= Ambulatorio 1= Emergencia 2= Unidades de cuidados intensivos (UCI) 3= Otros
Intervención		
Tipo de IA	Modelo de IA utilizado	0= Aprendizaje profundo 1= Aprendizaje automático supervisado 2= Aprendizaje automático no supervisado 3= Modelo híbrido 4= Sistemas difusos 5= Otros (Modelos que no se ajustan claramente a las categorías anteriores o son menos comunes)
Objetivo del estudio	Objetivo descrito por los autores	Ejm: Identificar lesiones en TAC cerebral, estimación de tiempo de recuperación, etc.
Área de aplicación	Área clínica de aplicación de la IA	0= Diagnóstico 1= Tratamiento 2= Pronóstico
Comparador	Método clínico que se usan para comparar el desempeño de la IA	Ejm: Opinión de expertos
Resultados		
Desempeño de la IA	Métrica estadística que evalúa el rendimiento de la IA	Sensibilidad, Especificidad, odds ratio, F1, AUC, significancia u otras medidas que evalúan el desempeño de la IA.
Impacto/Significativo	Nivel de significancia del impacto	0= No 1= Si 2= Neutral
Resultados principales		

Diagnóstico	Como la IA mejora en el diagnóstico o identificación de lesiones posterior a un TEC	Reporte sobre la capacidad de la IA para mejorar el diagnóstico en comparación con métodos habituales
Tratamiento	Cómo la IA mejora el tratamiento y manejo del TEC	Reportes de ensayos clínicos que lo comparan con un manejo habitual
Pronóstico	Como la IA mejora en la predicción de tiempo de recuperación o mortalidad posterior a sufrir un TEC	Reportes que muestren si la IA mejoró las predicción de desenlaces clínicos (Tiempo de hospitalización, recuperación, etc)
Validación		
Validación del modelo	Tipo de validación utilizada en el Modelo de IA	0= Interna 1= Externa 2= Cruzada 3= Otros (Validación pragmática, Revalidación independiente, Benchmarking)
Limitaciones Reportadas	Descripción de las limitaciones identificadas por los autores del estudio	Tamaño de muestra pequeño

## ANEXO 6

Número de serie	DOI	Denominación del estudio	País	Grupo etario (edad media)	Tamaño de muestra	Severidad	Diseño de estudio	Lugar del estudio	Tipo de aprendizaje/Modelo	Datos de entrada	Área de aplicación	Objetivo	Comparador	Desempeño de la IA	Impacto/Significativo	Resultados principales	Validación del modelo	Limitaciones reportadas
1	10.1016/j.compbio.med.2021.104614	Ellethy et al. (2021) [35]	Australia	Preescolares, escolares, adolescentes	15,271 pacientes (80% entrenamiento, 20% prueba)	Leve	Observacional Cohorte Retrospectivo	Emergencia	Profundo: ANN	Datos clínicos	Diagnóstico	Necesidad de TC	Híbrido: RF-ANN	P 100% Ex 99.9% S 97.7% E 100%	Si	ANN profundo tiene buen desempeño y supero al modelo híbrido RF-ANN.	Cruzada	La precisión mejoraría si fueran datos directamente de la historia clínica e imágenes originales
2	10.1016/j.injury.2022.01.008	Daley et al. (2022) [36]	Canadá	Preescolares, escolares, adolescentes (edad media 13 años)	196 pacientes (70% entrenamiento, 30% prueba)	Severo	Observacional Cohorte Retrospectivo	UCI	Supervisado: RF	Datos clínicos	Pronóstico	Mortalidad	Método estadístico: RL	Ex 82% AUC 0.91	Si	RF resulta ser modelo pragmático y de alto rendimiento con excelente capacidad de discriminación.	Cruzada	Validación necesaria en otros centros para evitar sobreajuste.
3	10.1016/j.jpedsur.2020.10.021	Shahi et al. (2021) [37]	USA	Preescolares, escolares, adolescentes (edad media 11 años)	477 pacientes	No específica	Observacional Cohorte Retrospectivo	Emergencia	Profundo: DNN	Datos clínicos	Pronóstico	Mortalidad Manejo: Masive Transfusion (MT), failure of non operative management (fNOM), succesfull of non operative management (sNOM)	ABC score MT: Ex 90.5%, AUC 0.90, S 88.9%, E 90.5% Mortalidad: Ex 91.9%, AUC 0.96, S 100%, E 91.8% fNOM: Ex 83.8%, AUC 0.88, S 91.7%, E 83.5% sNOM: Ex 90.3%, AUC 0.89, S 90.4%, E 88.2%	Si	Los modelos desarrollados predijeron transfusiones masivas, falla del NOM y mortalidad con gran exactitud.	Cruzada	Modelo limitado por solo 477 pacientes, afectando precisión.	
4	10.1016/j.jpedsur.2021.11.008	Farzaneh et al. (2022) [38]	USA	Preescolares, escolares, adolescentes (edad media 13.3 años)	885,100 pacientes (50% entrenamiento, 50% prueba)	No específica	Observacional Cohorte Retrospectivo	Emergencia	Supervisado: RF	Datos clínicos	Diagnóstico	Necesidad de TC: diagnóstico de daño cerebrovascular no cortante	Criterios: Denver y Memphis	P 3.9% Ex 86.3% AUC 0.92 S 84% E 86% VPN 99.8%	Neutral	RF presenta mejor desempeño en comparación a los criterios de Denver y Memphis.	Interna	Amplia data con daños de codificación, selección, sesgo de información.
5	10.1016/j.ympdx.2020.100026	Rowe et al. (2020) [39]	USA	Preescolares, escolares, adolescentes	43,399 pacientes (relación 2:1 entre set de entrenamiento prueba)	Leve	Observacional Cohorte Retrospectivo	Emergencia	Supervisado: RF	Datos clínicos	Diagnóstico	Necesidad de TC	Supervisado: RL GBM RPART*	Tasa de falsos negativos: (valor de p=1)	No	Los modelos no fueron herramientas más precisas para el diagnóstico en ausencia de fractura de cráneo.	Cruzada	Resultados limitados en situaciones clínicas diversas y entornos reales
6	10.1016/j.braintres.2019.146510	Bahado-Singh et al. (2019) [40]	Turquía	Neonatos, preescolares, escolares, adolescentes (edad media 12.8 años)	35 pacientes (80% entrenamiento, 20% prueba)	Leve	Observacional Casos y controles Prospectivo	Emergencia	Profundo: ANN	Data combinada: datos clínicos y marcador	Diagnóstico	Identificación de TEC por marcador epigenético	Supervisado: RF SVM LDA PAM GLM	AUC 0.98 S 97% E 95%	Si	El uso de marcadores epigenéticos alcanzó altos niveles de sensibilidad y especificidad.	Cruzada	Imposible evaluar tejido cerebral en TEC pediátrico leve por razones éticas.

*Continúa*

7	10.1007/s00415-021-10566-x	Fedorchak et al. (2021) [41]	USA	Escolares, adolescentes (edad media 16 años)	112 pacientes (505 muestras: 58% entrenamiento, 23% evaluación, 19% prueba)	Leve	Observacional Cohorte Prospectivo	Emergencia	Supervisado: RF	Data combinada: datos clínicos y marcador (RNA no codificante)	Pronóstico	Recuperación	Supervisado: SVM PPSC herramienta clínica	RF combinado AUC 0.86	Si	El RNA no codificante permite predicción de persistencia de síntomas y facilita el seguimiento de los pacientes.	Cruzada	Mayor diversidad poblacional requerida para resultados más generalizables
8	10.1186/s12874-015-0015-0	Chong et al. (2015) [42]	Singapur	Escolares, adolescentes (edad media 8.1 años)	195 pacientes	Moderado Severo	Observacional Casos y controles Retrospectivo	Emergencia	Supervisado: ANN	Datos clínicos	Diagnóstico	Necesidad de TC	Método estadístico: RL	P 90.2% AUC 0.98 S 94.9% E 97.4% VPN 98.7%	No	Existe superioridad del ML sobre la RL con valores de sensibilidad y precisión	Ninguna	Se requieren estudios prospectivos para validar los resultados
9	10.1038/s41598-022-16313-0	Heo et al. (2022) [43]	Corea del Sur	Neonatos, preescolares, escolares, adolescentes	102,002 pacientes (80,508 validación interna, 21,494 validación externa)	Leve	Simulación Cuasi-experimental Retrospectivo	Emergencia	Profundo: DNN/DEEPTICH*	Datos clínicos	Diagnóstico Apoyo toma de decisiones	Necesidad de TC	PECARN	P 1.8% AUC 0.92 S 95% E 67.2% VPN 99%	Si	El modelo DEEPTICH presentaba un AUC más elevado que las guías clínicas usuales para solicitar TC craneal	Externa	El estudio evaluó la eficacia de DEEPTICH según decisiones médicas, sin medir su exactitud ni superioridad. Su aceptación en entornos clínicos podría variar.
10	10.1186/s12911-023-02155-x	Zou et al. (2023) [44]	USA	Neonatos, preescolares <2años	1,429 pacientes (90% entrenamiento 10% prueba)	Leve	Observacional Cohorte Retrospectivo	Emergencia	Profundo: DNN	Datos clínicos	Diagnóstico Apoyo toma de decisiones	Necesidad de TC	Supervisado: RF SVM XGB	Ex 91.5% AUC 0.79 S 4.8% E 100% PR-AUC 0.97	Si	El modelo DNN identifica sólidamente características clínicas y mejora la precisión de la predicción en comparación con otros modelos de aprendizaje automático.	Cruzada	PermFIT-DNN mostró alta precisión, pero su AUC fue relativamente bajo.
11	10.1002/acn3.50951	Iyer et al. (2019) [45]	Australia	Escolares, adolescentes	99 pacientes (85 entrenamiento, 14 prueba)	Leve	Observacional - Cohorte Prospectivo	Emergencia	Supervisado: SVM	Imágenes RM	Pronóstico	Recuperación	PPSC herramienta clínica	Ex 79% AUC 0.86 S 82% E 75%	Neutral	EL modelo SVM fue capaz de discriminar con precisión a los niños que se recuperaron de TEC leve de los que permanecieron clínicamente sintomáticos.	Cruzada	Se requieren validación en conjuntos de datos independientes.
12	10.1097/JSM.000000000000639	Zahid et al. (2018) [46]	USA	Escolares, adolescentes (edad media 15.4 años)	139 pacientes (64 entrenamiento, 75 prueba)	Leve	Observacional Casos y controles transversal	Emergencia	Supervisado: RL DT	Videos (marcador/movimiento ocular)	Diagnóstico	Identificación de TEC por marcador movimiento ocular	Cuestionario ACE y prueba de convergencia	P 78.1 AUC 0.78 S 75% E 64.7%	Neutral	El seguimiento ocular tiene utilidad de ayuda rápida, objetiva y no invasiva en el diagnóstico.	Cruzada	Diferencias etarias causaron más falsos positivos y menor sensibilidad en validación cruzada.

Continúa

13	10.1001/jama.pediatrics.2019.1068	Bertsimas et al. (2019) [47]	USA	Neonatos, preescolares, escolares, adolescentes (edad media 4.9 años)	42,412 pacientes (33,785 entrenamiento, 8627 prueba)	Leve	Observacional Cohorte Retrospectivo	Emergencia	Supervisado: OCT	Datos clínicos	Diagnóstico	Necesidad de TC	PECARN	P 2.7% S 94.5% E 65.6% VPN 99.9%	Neutral	El modelo OCT parece tener una mejor precisión predictiva que el PECARN, sensibilidad similar pero especificidad mejorada.	Interna	El estudio se limita por falta de validación externa, datos retrospectivos y complejidad del modelo
14	10.1001/jama.pediatrics.2021.1068	Guberman et al. (2021) [48]	Canadá	Escolares	306 pacientes (70% descubrimiento 30% replicación)	Leve	Observacional Correlacional Transversal	No específica	Supervisado: PLSc	Data combinada: datos clínicos e imágenes RM	Diagnóstico	Correlación de la relación multi-tracto y multi-sintoma	Análisis univariado	Covarianza 26% r = 0.9997 P<0.001	Neutral	El modelo PLSc identificó relaciones clínicamente significativas, multitracto y multisintoma.	Ninguna	Falta de datos basales y tiempo del TEC limita análisis y generalización.
15	10.1089/neuro.2020.7018	Fleck et al. (2021) [16]	USA	Escolares, adolescentes (edad media 12.9 años)	43 pacientes (48 imágenes volumétricas de MRI y 192 datos de DTI por participante), (80% entrenamiento 20% Validación)	Leve	Observacional Cohorte Retrospectivo	Emergencia	Híbrido: GFT	Data combinada: datos clínicos e imágenes RM	Pronóstico	Recuperación	Supervisado: NB RF SVM DT DFA ETC	Ex 62.3% S 59.4% E 65.1%	Neutral	El modelo GFT fue capaz de clasificar correctamente a los participantes como recuperados o no recuperados a la semana posterior a la lesión.	Interna	Muestra pequeña, falta de validación externa y combinación de datos afectaron resultados.
16	10.3389/fped.2021.750272	Kim et al. (2021) [49]	Corea del Sur	Escolares (edad media 6 años)	58 pacientes (57 entrenamiento 1 Prueba)	Leve Moderado Severo	Observacional Cohorte Retrospectivo	Emergencia	Supervisado: DT/Catboost*	Data combinada: datos clínicos e imágenes TC	Pronóstico	Favorabilidad Manejo (necesidad de cirugía) Mortalidad Recuperación	Entre modelos CRASH-CT* CRASH-RL* D/CRASH*  PECARN	Favorabilidad (GOS 1–3 vs. 4–5) al alta: VPP 50%, AUC 0.83, S 83.3%, E 78.2%, VPN 94.7%  Necesidad de cirugía: P 42.8%, AUC 0.71, S 85.7%, E 63.6%, VPN 93.3%  Mortalidad: P 35.2%, AUC 0.91, S 100%, E 78.8%, VPN 100%.  Recuperación >1 semana: P 79.3%, AUC 0.83; S 76.6%, E 78.5%, VPN 75.8%	Si	Los parámetros densitométricos eran efectivos para predecir resultados desfavorables.	Cruzada	Estudio limitado por único centro, datos retrospectivos y dependencia de densitometría de TC.
17	10.1002/hbm.2024.26763	Ren et al. (2024) [50]	USA	Adolescentes (edad media 12.5 años)	120 pacientes 90 regiones de interés (ROIs) de FMRI	No específica	Observacional Casos y controles Retrospectivo	Emergencia	Supervisado: NB/VEVAR*	Imágenes (RM)	Diagnóstico	Identificar alteraciones de conectividad cerebral y efectos de covariables	Entre modelos GC-LASSO* GC-PLSMSE LECT* VEVAR-S1-SS*  Metodos tradicionales	Ex 99% F1 0.93 S 0.87 MCC 0.93	No	Se observó una alteración en la conectividad cerebral en relación con la edad, especialmente en los lóbulos frontales y temporales, con diferencias significativas en la conectividad según el sexo.	Ninguna	Alta complejidad, sensibilidad a hiperparámetros y correlaciones complican interpretación.
18	10.3171/2019.1.PEDS18293	Greenan et al. (2019) [51]	USA	Escolares (edad media: 5.9 años)	112 pacientes	Severo	Observacional Cohortes Retrospectivo Multicéntrico	Emergencia UCI	Supervisado: DT	Datos clínicos	Pronóstico	Favorabilidad	Supervisado: DT/Fulkerston	Ex 90.2% S 68.4 E 93.6%	Si	El modelo DT fue externamente validado con éxito modesto.	Externa	Decisiones sobre retiro de cuidados y diferencias institucionales sobre datos del manejo del paciente complican análisis

19	10.3348/kjr.2021.0449	Choi et al. (2022) [52]	Corea del Sur	Preescolares, escolares, adolescentes (edad media 7.5 años)	508 pacientes (70% entrenamiento interna, validacion externa 20%)	No especifica	Observacional Retrospectivo Multicentrico	Emergencia	Profundo: CNN	Imágenes Rx	Diagnóstico	Identificación de fracturas	Opinión de expertos	AUC 0.87 S 78.9% E 91.3%	Si	El modelo CNN en la identificación precisa de fracturas craneales, mejorando la sensibilidad y especificidad.	Externa	Menor sensibilidad en niños mayores por alteraciones anatómicas y sobreajuste limitan generalización del modelo.
20	10.3340/jkns.2022.0062	Jeong et al. (2023) [53]	Corea del Sur	Escolares, adolescentes (menor de 10 años)	88 pacientes 88 imágenes (70% entrenamiento 30% Prueba)	No especifica	Observacional Retrospectivo	Emergencia	Profundo: CNN	Imágenes Rx	Diagnóstico	Identificación de fracturas	Entre modelos Resnet*	S 37.5% E 62.5%	No	El modelo CNN tuvo dificultades para identificar fracturas de cráneo.	Interna	Entrenamiento insuficiente por diferencias craneales entre niños y adultos.
21	10.1016/j.cjce.2021.06.003	Tunthanathip et al. (2021) [29]	Tailandia	Preescolares (edad media 72 meses)	828 pacientes (70% entrenamiento 30% prueba)	Leve Moderado Severo	Observacional Cohorte Retrospectivo	Emergencia	Supervisado: SVM	Datos clinicos	Pronóstico	Favorabilidad	Supervisado: ANN, RF, RL, NB KNN	Favorabilidad P 99% Ex 94% AUC 0.78 S 95% E 60% VPN 21%	Si	El modelo permitió una predicción más precisa de la recuperación funcional a seis meses.	Cruzada	El uso de una cantidad limitada de datos, especialmente para casos moderados y severos, y la falta de validación externa
22	10.3171/2018.8.FOCUS17773	Huang et al. (2022) [54]	USA	Escolares (edad media 12 años)	98 pacientes (90% entrenamiento, 10% prueba)	Leve	Observacional Cohorte Prospectivo	Emergencia	Hibrido: SVM-RFE	Data combinada: datos clínicos y marcador	Diagnóstico Pronóstico	Identificación de TEC por marcador (bandas delta-gamma)	Metodos estadísticos: ANOVA, ANCOVA	Firmas neuronales AUC 98.5 S 95.5 E 90.2 Recuperación: varianza 84.5%	Si	El modelo demostró una utilidad en la identificación y evaluación de la recuperación	Cruzada	Muestra pequeña, evaluación rs-MEG limitada y síntomas reportados solo por padres, sin autoevaluaciones ni entrevistas.
23	10.3171/2018.8.FOCUS17773	Hale et al. (2018) [55]	USA	Escolares (edad media 6.8 años)	565 pacientes (70% entrenamiento, 15% validación, 15% prueba )	Leve Moderado Severo	Observacional Cohorte Retrospectivo	Emergencia	Profundo: ANN	Datos clinicos	Pronóstico	Favorabilidad	Escalas tomográficas de Marshall, Rotterdam y Helsinki	AUC 0.97	Si	El modelo ANN demostró ser una herramienta robusta para predecir el resultado a largo plazo.	Cruzada	Estudio retrospectivo en un único centro, limitando generalización; se requiere validación externa y ensayos prospectivos.
24	10.1007/s00247-020-04743-9	Tunthanathip et al. (2021) [28]	Tailandia	Escolares (edad media 75.5 meses)	964 pacientes (75% entrenamiento, 25% prueba)	Leve Moderado Severo	Observacional Cohorte Retrospectivo	Emergencia	Supervisado: RF	Datos clinicos	Diagnóstico	Necesidad de TC	Nomograma/ RL	P 73% Ex 79% AUC 0.8 S 34% E 95% VPN 80%	Si	El modelos RFC ofrece alta especificidad y precisión en la predicción de lesiones intracraneales.	Cruzada	Muestra reducida, diseño retrospectivo con sesgos y sin validación externa; se requiere validación multicéntrica.

Continúa

25	10.1007/s00247-020-04743-9	Raji et al. 2020 [56]	USA	Adolescentes (edad media 14.2 años)	24 pacientes (14 con TCE y 10 controles)	Leve	Observacional Casos y controles Prospectivo	Ambulatorio	Hibrido: SVM-PCA	Imagen RM (marcador/EDI^)	Diagnostico	Identificación de TEC por marcador (EDI^)	Pruebas neurocognitivas	S 79% E 100% AUC 94%	Si	EDI fue efectiva para diferenciar niños con TBI leve de controles sanos.	Cruzada	Generalización limitada por muestra pequeña y falta de validación; técnica no aplicable a TCE graves ni adultos.
26	10.1097/HTR.00000000000646	Maddux et al. (2021) [57]	USA	Escolares (edad media 5 años)	289 pacientes	Leve Moderado Severo	Observacional Cohorte Retrospectivo	UCI	No Supervisado: CK-M	Datos clínicos	Pronóstico	Morbilidad (uso de recursos)	Metodos estadísticos LCA	Fenotipo 3: AUC de 0.85 Fenotipo 1: AUC de 0.70 Fenotipo 2: AUC de 0.63	Si	El modelo demostró gran capacidad discriminativa para el fenotipo 3.	Cruzada de 10 pliegues	Falta de datos externos, hallazgos de imágenes y antecedentes médicos limita generalización y captura de condiciones preexistentes.
27	10.3171/2018.8.PEDS18370	Hale et al. (2018) [58]	USA	Escolares (edad media 7.9 años)	12,902 pacientes (70% entrenamiento, 15% validación, 15% prueba)	No especifica	Observacional Cohorte Retrospectivo	Emergencia	Profundo: ANN	Datos clínicos	Diagnostico	Necesidad de TC	PECARN	P 98.1% Ex 97.9% AUC 0.99 S 99.7% E 60.4% F1 0.97	Si	El modelo ANN muestra alta precisión en la identificación de TEC.	Interna	Datos retrospectivos, variabilidad en pautas de tomografías y ausencia de exámenes físicos limitan aplicabilidad clínica.
28	10.1111/acem.12859	Yadav et al. (2016) [59]	USA	Preescolares, escolares, adolescentes	5,987 pacientes 2121 informes de TC (50% entrenamiento 50% prueba)	No especifica	Observacional Cohorte Retrospectivo	Emergencia	Hibrido: DT-NLP	Datos clínicos	Diagnóstico	Necesidad de TC	Opinión de expertos	P 43.6% S 89.7% E 91.9% VPN 99.2	Neutral	El modelo mostró un buen rendimiento en la identificación de informes negativos de TEC.	Interna	Alta tasa de falsos positivos, la IA necesita revisión manual de los reportes clasificados positivamente.
29	10.1371/journal.pone.0278562	Miyagawa et al. (2023) [60]	Japón	Preescolares (<2años)	1,100 pacientes (80% entrenamiento, 20% prueba)	Leve	Observacional Cohorte Retrospectivo	Emergencia	Supervisado: DT	Datos clínicos	Diagnóstico	Necesidad de TC	PECARN	P 95% AUC 0.85 F1 0.95	Si	El modelo DT demostró alta precisión en la identificación de niños que requieren TC.	Interna	Sesgo de selección limita generalización por edad; modelos no comparados con técnicas avanzadas como Random Forest.
30	10.1038/s41390-019-0510-9	Kayhanian et al. (2019) [61]	Reino Unido	Escolares (edad media 7.3 años)	94 pacientes (datos: 14 variables séricas)	Severo	Observacional Cohorte Retrospectivo	UCI	Supervisado: SVM	Datos clínicos	Pronostico	Favorabilidad	Supervisado RL	Favorable: S 80% E 99% J-statistic 0.63	Si	El modelo SVM mejoró la predicción de desenlace favorable o desfavorable a 6 meses.	Cruzada	Tamaño de muestra pequeño y modelo limitado a un solo centro.
31	10.3390/s23187896	Yang et al. (2023) [62]	China	Preescolares (edad media 21.5 meses)	100 pacientes 500 clips de 200 videos de caídas de niños (80% entrenamiento 20% prueba)	Leve Moderado Severo	Observacional Cohorte Prospectivo	Monitoreo en casa	Profundo: CNN	Videos	Diagnóstico	Identificación de TEC por video	Supervisado RF y SVM	P 99% Ex 96.6% S 96.1% E 97.7% F-score 97.5%	Si	El modelo permitió la detección de caídas y posibles lesiones en tiempo real, basándose en el cálculo de la aceleración y el criterio HIC.	Interna	No se evaluó la dureza del suelo en relación con la gravedad de la lesión.

**ANEXO 6.** Se muestra un resumen de los estudios sobre el uso de los modelos de Machine Learning (ML) de inteligencia artificial (IA) en el manejo de Trauma encefalocraneano (TEC). Se incluye información como el DOI para consulta directa, la denominación del estudio, los países donde se realizaron los estudios, el grupo etario y el tamaño de muestra, especificando la división de datos utilizados en el entrenamiento y prueba del modelo. También se detalla la severidad del trauma, el diseño de estudio y el lugar donde se realizó como servicios de emergencias o unidades de cuidados intensivos (UCI). Los estudios emplearon modelos de IA, abreviados por sus siglas en inglés: ANN, Artificial Neural Network; RF, Random Forest; DNN, Deep Neural Network;

SVM, Support Vector Machine; RL, Regresión logística; DT, Decision Tree; OCT, Optimal Classification Tree; PLSc, Partial Least Squares correlation; GFT, Generalized Feature Transformation; NB, Naive Bayes; CNN, Convolutional Neural Network; RFE, Recursive Feature Elimination; PCA, Principal Component Analysis; CK-M, Cluster K-Means; NLP, Natural Language Processing; LDA, Linear Discriminant; PAM, Prediction Analysis for Microarrays, GLM, Generalized Linear Model; XGB, X Gradient Boosting; DFA, Discriminant Function Analysis; ETC, Extra Trees Classifier; KNN, K-Nearest Neighbors; LCA, Latent Class Analysis.

Además, se listan comparadores y las métricas de desempeño que incluyeron Precisión (P), Exactitud (Ex), Sensibilidad (S), Especificidad (E), Área bajo la curva (AUC), Coeficiente de correlación de Mathews (MCC, por sus siglas en inglés), VPN (valor predictivo negativo). Se indicó si los hallazgos tuvieron un impacto clínico significativo y se resumen los principales resultados obtenidos, además del tipo de validación realizada. Finalmente, se detallan las limitaciones reportadas en los estudios, como muestra pequeñas, diseño retrospectivo, falta de validación externa, sesgos de selección y alta tasa de falsos positivos.

(\*) Nombres propios de algunos modelos.

(+) Métodos utilizados como comparadores estadísticos: síntomas post contusivos persistentes, PPSC por sus siglas en inglés; red de investigación aplicada de atención de emergencia pediátrica, PECARN por sus siglas en inglés; evaluación aguda de contusión, ACE por sus siglas en inglés; análisis de varianza, ANOVA por sus siglas en inglés; análisis de covarianza, ANCOVA por sus siglas en inglés.

(^) Imágenes de difusión de borde, EDI por sus siglas en inglés.