

TRABAJO FIN DE GRADO



UCAM

UNIVERSIDAD CATÓLICA
DE MURCIA

FACULTAD DE CIENCIAS DE LA SALUD

GRADO EN MEDICINA

REVISIÓN SISTEMÁTICA DEL APRENDIZAJE AUTOMÁTICO ENTRE 2018-2023 EN PEDIATRÍA. INTELIGENCIA ARTIFICIAL.

Autora: Cristina Guerrero Merino

Director: Gonzalo Ros Cervera

Murcia, mayo de 2023

TRABAJO FIN DE GRADO



UCAM

UNIVERSIDAD CATÓLICA
DE MURCIA

FACULTAD DE CIENCIAS DE LA SALUD

GRADO EN MEDICINA

REVISIÓN SISTEMÁTICA DEL APRENDIZAJE AUTOMÁTICO ENTRE 2018-2023 EN PEDIATRÍA. INTELIGENCIA ARTIFICIAL.

Autora: Cristina Guerrero Merino

Director: Gonzalo Ros Cervera

Murcia, mayo de 2023

TRABAJO FIN DE GRADO



UCAM
UNIVERSIDAD CATÓLICA
SAN ANTONIO

DEFENSA TRABAJO FIN DE GRADO

DATOS DEL ALUMNO	
Apellidos: Guerrero Merino	Nombre: Cristina
DNI: 45120050-F	Grado en Medicina
Facultad de Ciencias de la Salud	
Título del trabajo: Revisión sistemática del aprendizaje automático entre 2018-2023 en pediatría. Inteligencia Artificial.	

El Dr. Gonzalo Ros Cervera, tutor del trabajo reseñado arriba, acredito su idoneidad y otorgo el V. ° B. ° a su contenido para ir a Tribunal de Trabajo fin de Grado.

En Murcia, a 19 de mayo de 2023

Fdo.:

**GONZALO
HUGO ROS
CERVERA -
NIF:448517
95R**

Firmado digitalmente por GONZALO HUGO ROS CERVERA - NIF:44851795R
DN: CN=GONZALO HUGO ROS CERVERA - NIF:44851795R, SERIALNUMBER=44851795R, G=GONZALO HUGO, SN=ROS CERVERA, OU=CIUDADANOS, O=ACCV, C=ES
Razón: Estoy aprobando este documento con mi firma legalmente
Fecha: 2023.05.19 11:23:51+0200
Foxit PDF Editor Versión: 12.0.1

AGRADECIMIENTOS

En primer lugar, a mi tutor, el Dr. Gonzalo Ros Cervera, por su dedicación y enseñanza a lo largo del desarrollo del trabajo. Gracias por abrirme las puertas de la Inteligencia Artificial.

A la universidad y a los profesores, por el aprendizaje a lo largo de estos seis años.

A mi abuelo, Salvador Guerrero Ruiz, por haber hecho posible que haya cumplido el sueño de ser médico. A mi madre, Eva Merino, y mi hermano, Jesús Guerrero, por ser mi mayor apoyo y el motor de mi vida. Al resto de mi familia, gracias por confiar en mí siempre.

A Alejandra y Andrea, por haber estado ahí estos seis años. Gracias por no dudar de mí y estar ahí en todos los momentos. A Rebeca, por este último año a mi lado, gracias por tu apoyo.

Por último, al resto de mis amigos y a todas las personas que me apoyaron y confiaron en mí a lo largo de este camino, gracias.

ÍNDICE

ÍNDICE	11
RESUMEN	13
ABSTRACT	15
ABREVIATURAS	17
1. INTRODUCCIÓN	19
1.1. OBJETIVOS	22
2. MATERIAL Y MÉTODOS	23
3. RESULTADOS	25
4. DISCUSIÓN	29
5. CONCLUSIONES	35
6. BIBLIOGRAFÍA	37
7. TABLAS Y FIGURAS	41
FIGURA 1. Flujograma de búsqueda de artículos.	41
FIGURA 2. Número de publicaciones por año	42
FIGURA 3. Publicaciones por ubicación geográfica.	42
FIGURA 4. Porcentaje de publicaciones por ámbito pediátrico.	43
FIGURA 5. Proporción de estudios según el método algorítmico, función desempeñada y tipo de algoritmo empleado.	44
TABLA 1. Número de publicaciones por localización geográfica.	45
TABLA 2. Clasificación de las publicaciones según el método algorítmico, función desempeñada y tipo de algoritmo empleado.	45
8. ANEXOS	47
ANEXO 1	47
ANEXO 2	57

RESUMEN

Introducción: El Sistema de Salud se enfrenta a retos mayores en los últimos años. El desarrollo de la Inteligencia Artificial (IA) aplicada a la medicina ha sido objeto de estudios recientes. El aprendizaje automático o “machine learning” es un tipo de IA que proporciona al ordenador la capacidad de crear algoritmos a partir de la introducción de datos. Por tanto, el progreso de estos modelos puede ser un gran apoyo al sistema sanitario.

Objetivos: Revisar en los estudios publicados las diferentes aplicaciones que ha tenido la IA en el ámbito de la Pediatría entre los años 2018 y 2023.

Material y métodos: Se realiza una búsqueda en PubMed (Medline) introduciendo “*machine learning*”, “*artificial intelligence*”, “*pediatrics*” y “*childhood*” como palabras clave. Se aplican los filtros “*0-18 años*” y “*últimos cinco años*”. Se obtienen 137 artículos a los que se aplican los criterios de inclusión, resultando un total de 62 artículos.

Resultados: El pico de publicaciones se encuentra en el año 2021. Estados Unidos es el país con mayor número de estudios. El terreno de la Radiología se sitúa como el más investigado, seguido de la Neurología y los Cuidados Críticos. La mayoría de los algoritmos son de tipo supervisado y de clasificación. Se hallan dos funciones principales, sistema de apoyo a la decisión clínica y diagnóstico automatizado. El algoritmo más estudiado corresponde a Random Forest (RF) y la métrica habitual de comparación es el área bajo la curva ROC. Por último, se objetivan las principales limitaciones de las publicaciones.

Conclusiones: La IA ofrece numerosas ventajas en el sistema sanitario, sin embargo, la pediatría es un campo con necesidad de mayor investigación actualmente. Además, la recogida de datos de las historias clínicas es limitada y los estudios individuales carecen de validez externa.

DESCRIPTORES: *Aprendizaje automático, Pediatría, Inteligencia Artificial.*

ABSTRACT

Introduction: The Health System faces major challenges in recent years. The development of Artificial Intelligence (AI) applied to medicine has been the subject of recent studies. Automatic learning or “machine learning” is a type of AI that provides the computer with the ability to create algorithms from the input of data. Therefore, the progress of these models can be a great support to the health system.

Objectives: To review in the published studies the different applications that AI has had in the field of Pediatrics between 2018 and 2023.

Material and methods: A search was performed in PubMed (Medline) entering “*machine learning*”, “*artificial intelligence*”, “*pediatrics*” and “*childhood*” as keywords. The filters “*0-18 years*” and “*last five years*” are applied. 137 articles were obtained to which the inclusion criteria were applied, resulting in a total of 62 articles.

Results: The peak of publications is in the year 2021. The United States is the country with the largest number of studies. The field of Radiology ranks as the most researched, followed by Neurology and Critical Care. Most of the algorithms are of the supervised and classification type. There are two main functions, clinical decision support system and automated diagnosis. The most studied algorithm corresponds to Random Forest (RF) and the usual comparison metric is the area under the ROC curve. Finally, the main limitations of the publications are objectified.

Conclusions: AI offers numerous advantages in the healthcare system, however, pediatrics is a field in need of further research today. In addition, data collection from medical records is limited and individual studies lack external validity.

KEYWORDS: *Machine learning, Pediatrics, Artificial Intelligence.*

ABREVIATURAS

- ANN: Red neuronal artificial (del inglés, Artificial neural network)
- AUC: Área bajo la curva (del inglés, Area under curve)
- CDSS: Sistema de Apoyo a la Decisión Clínica (del inglés, Clinical Decision Support System)
- HyM: Modelo híbrido (del inglés, Hybrid Model)
- IA: Inteligencia Artificial
- ML: Aprendizaje automático (del inglés, Machine learning)
- NLP: Procesamiento del lenguaje natural (del inglés, Natural language processing)
- RF: Bosque aleatorio (del inglés, Random forest)
- ROC: Característica operativa del receptor (del inglés, Receiver operating characteristic)
- SVM: Máquinas de vector soporte (del inglés, Support vector machine)
- TC: Tomografía computerizada
- UCIP: Unidad de Cuidados Intensivos Pediátricos
- XGboost: Refuerzo de árboles de gradiente (del inglés, Gradient tree boosting)

1. INTRODUCCIÓN

En las últimas décadas, el Sistema de Salud se enfrenta a retos cada vez mayores dada la gran demanda y los costes, que no pueden ser compensados únicamente con un incremento en recursos humanos o en el capital invertido. Estos sistemas acaban trabajando de un modo inefectivo y con posibilidad de errores, consiguiendo resultados por debajo de los estándares deseados, a pesar de que los profesionales hagan lo mejor para proporcionar el cuidado adecuado (1).

La Inteligencia Artificial (IA) en salud es la intersección entre matemáticas, informática y medicina. Por lo tanto, el gran desarrollo potencial de la IA enfrenta a grandes retos asociados a la formación de expertos, equipos de altas prestaciones y grandes bases de datos. La IA puede entonces ser definida como la simulación del comportamiento inteligente por agentes, de manera que los consideraríamos similares a los humanos. No supone una alternativa a la metodología científica actual, sino que probablemente se constituye en la progresión del actual modo de trabajar. Entre muchas de las oportunidades que el análisis avanzado de datos ofrece al Sistema de Salud, se encuentran el potencial en la prevención de complicaciones al mejorar el pronóstico de modo preventivo, dar soporte a la toma de decisiones en el tratamiento individualizado del paciente, la automatización de tareas clínicas y la gestión de recursos para mejorar la eficiencia y la seguridad (1). Sin embargo, la mayoría de estos sistemas se han centrado en poblaciones adultas, con menos enfoque en pacientes pediátricos (2).

El aprendizaje automático o “machine learning” (ML) es un tipo de IA que proporciona a las computadoras la capacidad de aprender mediante el uso de datos, sin ser programadas de un modo explícito. Es decir, el ordenador aprende por sí mismo a expensas de los datos proporcionados. En el modelo tradicional, al ordenador se le introduce un modelo matemático al que se le proporcionan datos y se obtiene un resultado, sin embargo, en el ML al ordenador le proporcionamos datos y resultados, y después se obtiene un modelo matemático denominado algoritmo (1). Los métodos basados en IA han surgido como

poderosas herramientas para transformar la atención médica, y aunque han demostrado un fuerte desempeño, siguen siendo un desafío (3).

Podemos definir un algoritmo como un modelo matemático que reúne un conjunto de instrucciones dadas a una computadora, para que a partir de unos datos de entrada genere unos datos de salida. Distinguimos dos tipos de algoritmos: por tarea y según su aplicación. Entre los algoritmos por tarea podemos distinguir: el aprendizaje supervisado, el aprendizaje no supervisado y el aprendizaje por refuerzo. En el aprendizaje **supervisado**, los algoritmos se alimentan de variables y diagnósticos etiquetados con un resultado, con el objetivo de aprender a hacer predicciones de eventos futuros. Para ello, a través de un proceso de entrenamiento en el que el propio modelo hace predicciones, se va corrigiendo cuando estas son incorrectas. En el aprendizaje **no supervisado**, el algoritmo no recibe etiquetas para los datos, por lo que se deja que encuentre por sí solo la estructura a partir de la interpretación de los datos introducidos. En el aprendizaje **por refuerzo**, permite decidir la mejor acción en función de comportamientos a través de prueba-error y retroalimentación (1).

En cuanto a los algoritmos según su aplicación podemos distinguir: clasificación, regresión y clustering (segmentación). En los algoritmos de **clasificación**, como su propio nombre indica, se clasifican los datos en grupos en función de sus características. En los casos de **regresión**, el objetivo es determinar un valor o conjunto de valores dentro de un rango. Por último, el **clustering** nos permite organizar información en subgrupos sin tener ningún conocimiento previo de su pertenencia a ningún grupo (1).

El término Big Data (o macrodatos) hace referencia al conjunto o combinaciones de datos de elevado volumen y complejidad, que son fuente para la aplicación de métodos analíticos avanzados y generación de resultados utilizando algoritmos de aprendizaje automático (1). Los análisis de aprendizaje automático permiten considerar numerosas variables para llevar a cabo relaciones complejas que no serían evidentes en la estadística tradicional (4). Dichos datos se categorizan en volumen, variedad, velocidad, veracidad y valor:

- Volumen hace referencia a la cantidad de datos generados y almacenados.

- Variedad se refiere al tipo y naturaleza de los datos, los cuales pueden estar en diferente formato (texto, imágenes, audio, vídeo o combinación de varios tipos de datos). Pueden proceder a su vez de diferentes entornos (pacientes, especialidades, enfermedades, procedimientos, etc.).
- Velocidad es aquella a la cual se generan, almacenan, procesan, analizan y visualizan los datos.
- Veracidad hace referencia a la calidad, confiabilidad y autenticidad de los datos.
- Valor se refiere a la utilidad que generan los datos que se extraen. En salud, se evalúa mediante análisis cualitativo y cuantitativo a través de una variedad de factores, principalmente el impacto clínico en los resultados del paciente, el impacto en los procesos y flujos de trabajo o en la gestión de los recursos económicos.

Finalmente, aunque el avance de las tecnologías de computación y las herramientas analíticas han conseguido mejorar el análisis de datos y la predicción de eventos, es el elemento humano en el que reside el fundamento del proceso. Es la intuición humana y las habilidades las que permiten la extracción de importantes inferencias de la información procesada, permitiendo generar razonamientos en el sector de la salud (1). La implementación de estos sistemas de IA aún se enfrenta al desafío de la confiabilidad y la interpretabilidad, sin embargo, puede aliviar significativamente los problemas derivados de la subjetividad, costo económico, tiempo y recursos humanos entre otros (5). Por tanto, es de crucial importancia la formación de profesionales de la salud para crear equipos multidisciplinares que puedan interpretar las herramientas analíticas.

1.1. OBJETIVOS

El objetivo principal de esta revisión es conocer a través de estudios publicados, las diferentes aplicaciones que ha tenido la Inteligencia Artificial en el ámbito de la Pediatría durante los últimos cinco años.

Los objetivos secundarios que podemos destacar son el conocimiento de los campos donde más se ha llevado a cabo dicha investigación y las distintas subespecialidades pediátricas tratadas. Además, trataremos las limitaciones a las que se somete el tema en la actualidad.

2. MATERIAL Y MÉTODOS

Esta investigación trata de una revisión sistemática de los estudios publicados entre el 1 de enero de 2018 y el 3 de febrero de 2023 sobre la aplicación de la Inteligencia Artificial en el ámbito de la Pediatría.

Para ello se ha llevado a cabo una búsqueda en la base de datos PubMed (Medline) en la que se han introducido las siguientes palabras claves: *machine learning (aprendizaje automático)*, *artificial intelligence (inteligencia artificial)*, *pediatrics (pediatría)*, *childhood (infancia)*.

A dichos resultados se aplicaron dos filtros de búsqueda: “*birth-18 years (0-18 años)*” y “*in the last 5 years (últimos cinco años)*”.

Se obtuvieron un total de 137 artículos, de los cuales se seleccionaron aquellos que cumplieran una serie de criterios de inclusión propuestos. Estos criterios se basan en que dichos resultados se traten de artículos originales, descartando así diez de ellos correspondientes a revisiones sistemáticas. Además, debían tener un algoritmo de aprendizaje automático aplicado a un área de la pediatría para poder valorar los resultados obtenidos, así como pertenecer a publicaciones realizadas entre 2018-2023. Encontramos el flujograma de dicha búsqueda en la **Figura 1**.

Tras establecer estos criterios, se consiguieron un total de 62 artículos.

Posteriormente, se analizaron una serie de variables en cada uno de los artículos seleccionados:

- Año de publicación.
- Localización: lugar donde se encuentra el mayor centro de investigación.
- Ámbito pediátrico: subespecialidad pediátrica tratada en el estudio.
- Método de algoritmo: dividimos los artículos por tarea según sean supervisados, no supervisados o por refuerzo.
- Función: clasificamos dos tipos, sistema de apoyo a la decisión clínica (CDSS (Clinical Decision Support System)) el cual hace referencia a un tipo de software para ayudar a un médico en la toma de decisiones;

y diagnóstico automatizado, que mediante el análisis de datos nos refleja la patología hallada.

- Tipo de algoritmo: divide según su aplicación en clasificación, regresión y clusterización.
- Algoritmos utilizados: muestra los distintos modelos de algoritmos utilizados en el estudio.
- Muestra de estudio: hace referencia al número de sujetos, imágenes o elementos a estudiar.
- Número de variables: datos introducidos para el desarrollo del algoritmo.
- Comparación: analizamos el objeto a contrastar con el algoritmo estudiado.
- Métrica: se refiere a la medida con la que se ha realizado dicha comparación.
- Resultados: buscamos el fruto final del estudio.
- Limitaciones: principales inconvenientes encontrados en los estudios.

Tras ello, se utilizó el programa “Statistical Package for the Social Sciences (SPSS)”, donde se evaluaron los resultados obtenidos a nivel gráfico y descriptivo.

3. RESULTADOS

Respecto al **año de publicación**, el mayor número de publicaciones se concentra en el año 2021, en el que se objetivan un total de 27 artículos, correspondiente al 43,55% de las publicaciones. Los años con menor publicación se sitúan en 2018 con un total de 5 artículos, y en 2019 con 4 artículos. Además, destacamos que en el actual año 2023 sólo ha sido objetivada una publicación hasta la fecha. Por último, en el año 2020 encontramos un total de 13 artículos, y en el año 2022 objetivamos 12 artículos. Estos resultados los encontramos en la **Figura 2**.

Con respecto a la **localización**, encontramos que Estados Unidos se sitúa al alza con 27 artículos publicados. A dicho país, le sigue China con 12 artículos. Otras localizaciones son Canadá con 7 artículos, Corea y Alemania, ambas con 5 artículos. Reino Unido, Suiza y Francia cuentan con 3 artículos publicados. En países como Brasil y España visualizamos 2 artículos en cada uno de ellos, destacando que los publicados en nuestro país pertenecen a las provincias de Valladolid y Barcelona. Finalmente, en Singapur, Países Bajos, Italia, Israel, Austria y Australia únicamente se ha realizado una publicación. Podemos encontrar los resultados correspondientes en la **Figura 3**.

En cuanto al **ámbito pediátrico**, situamos el que más ha investigado la aplicación de la Inteligencia Artificial al campo de la Radiología, con un resultado de 13 artículos equivalente al 20,97% de las publicaciones. Le siguen las especialidades de Neurología con 9 artículos y la Unidad de Cuidados Intensivos con 8 artículos, lo que corresponde al 14,52% y al 12,9% respectivamente. En el resto de las subespecialidades pediátricas, encontramos en el campo de la Neumo-alergología un total de 7 artículos. En Cardiología, Atención Primaria, Gastroenterología, Servicios de Urgencias y Nefro-urología observamos 3 publicaciones por ámbito. En el campo de la Farmacología, la Hematología, la Gestión Clínica y la Endocrinología objetivamos 2 artículos por cada una de ellas. Para finalizar, en las subespecialidades de Reumatología e Infecciosas se ha hallado una única publicación por cada uno de los ámbitos. Los porcentajes de dichos resultados se encuentran en la **Figura 4**. La clasificación por áreas se encuentra en el **Anexo 2**.

Haciendo referencia a los **algoritmos de aprendizaje automático** descritos en las publicaciones estudiadas, objetivamos que el método más empleado es el aprendizaje supervisado, utilizado en 59 de los estudios, lo que corresponde al 90,77% del total. El método no supervisado fue estudiado por 5 de las publicaciones, y el aprendizaje por refuerzo sólo fue estudiado en una de ellas. En cuanto a las **funciones desempeñadas** por los diferentes algoritmos, como hemos mencionado previamente, encontramos dos: sistema de apoyo a la decisión clínica (“Clinical Decision Support System, CDSS”) y diagnóstico automatizado. El 58,06% de los estudios utilizan algoritmos de sistemas de apoyo a la decisión clínica, correspondiente a 36 publicaciones. Del mismo modo, el 41,94% utilizan algoritmos de diagnóstico automatizado, equivalente a 26 publicaciones. Por otra parte, el **tipo de algoritmo** más empleado es el de clasificación con un total de 52 artículos, lo que hace referencia al 82,54% del total. En cuanto al tipo regresión encontramos 4 artículos publicados, y el tipo clusterización o segmentación ha sido estudiado en 7 de los artículos. Estos hallazgos se recogen en la **Tabla 1** y en la **Figura 5**.

Por otra parte, los **algoritmos utilizados** mayormente corresponden a los árboles de decisión y las redes neuronales. En concreto resaltamos el árbol tipo Random Forest (RF), utilizado en 12 de los artículos y Gradient tree boosting (XGboost), empleado en 10 artículos. En cuanto a las redes neuronales, destaca el aprendizaje profundo o “deep-learning”, estudiado del mismo modo en 12 artículos.

En lo referente a la **muestra estudiada** en los diferentes artículos, podemos concluir que el artículo número 5 es el más numeroso con 1.362.559 historias clínicas electrónicas incluidas en el estudio. Por contra, el artículo 19 cuenta con el menor tamaño muestral estudiado correspondiendo a 19 imágenes de tomografía computarizada (TC).

Con respecto a las **variables** utilizadas en cada uno de los algoritmos, encontramos que el artículo 61 ha introducido un total de 225.532 variables en su estudio, siendo el de mayor número del total de artículos. Por el contrario, objetivamos que el artículo 2 incluyó una única variable en su algoritmo de estudio, siendo esta la edad del paciente.

Analizando el **método de comparación** de los algoritmos estudiados, podemos observar que la mayoría de las publicaciones se han contrastado con el método clínico utilizado habitualmente, correspondiendo a un total de 21 artículos. Además, 13 de las publicaciones fueron comparadas con la opinión de médicos expertos en la materia a tratar, y otros 13 lo hicieron con escalas y protocolos encontrados en la literatura. Por otro lado, 9 artículos confrontan un nuevo algoritmo desarrollado con otros modelos de algoritmo empleados. Por último, 3 estudios fueron contrastados con los resultados pertenecientes a consorcios y registros de hospitales, 2 artículos lo hicieron con una muestra de población con diferente patología a la incluida en el algoritmo, y finalmente, un único estudio fue comparado con otros estudios realizados anteriormente.

Para realizar dicha comparación, la **métrica** mayormente empleada han sido las curvas ROC, encontrando en la totalidad de los artículos un área bajo la curva (AUC) mayor de 0,50. Esto indica que generalmente obtienen un buen rendimiento. Visualizamos que el artículo 23 consigue un AUC de 0,984 siendo el mayor resultado objetivado, por el contrario, el artículo 6 refleja el menor AUC hallado, siendo este de 0,60 para predecir la mortalidad tras el trasplante cardíaco a los 5 años.

Centrándonos en los **resultados de los algoritmos**, podemos concluir que, en 29 de las 62 publicaciones analizadas, el algoritmo obtiene mejores rendimientos que su comparativa. Además, visualizamos que en 27 publicaciones más, el algoritmo obtiene una buena predicción sobre el objetivo a estudio. En 5 de las publicaciones restantes, el resultado de dichos algoritmos fue similar al objetivo a comparar. Por último, solo en una publicación correspondiente al artículo 8, no obtuvo buenos resultados en comparación con el método clasificador original. Por otra parte, encontramos que el tipo Random Forest (RF) obtiene los mejores resultados, destacando su rendimiento en 4 publicaciones. A dicho algoritmo le siguen los tipos Artificial neural network (ANN) y Gradient tree boosting (XGboost), destacando con mejor rendimiento en 2 artículos cada uno. Finalmente, el artículo 62 realiza un modelo híbrido, Hybrid Model (HyM), con mejor rendimiento.

Por lo referente a las principales **limitaciones de los estudios**, encontramos que la mayor de ellas se debe al uso de datos limitados.

Seguidamente observamos que la mayoría han trabajado con un tamaño muestral insuficiente, y, además, se desarrollan en pocas instituciones o en un único centro. Otras limitaciones relevantes son el no incluir otras patologías o características propias de los pacientes a estudio, tratarse en su mayoría de estudios retrospectivos, así como tener un carácter subjetivo en cuanto a la comparación con pocos médicos expertos en la materia. Para finalizar, otra limitación a tener en cuenta es no poseer cohorte de validación externa.

El listado de artículos se encuentra en el **Anexo 1**.

4. DISCUSIÓN

La IA en medicina se ha convertido en centro de estudio durante los últimos años, incluyendo el área pediátrica en sus investigaciones. Podemos observar que el año donde mayor peso ha cobrado este ámbito corresponde al 2021. Se objetiva un orden creciente de publicaciones desde el 2018 hasta dicha fecha, y por el contrario una decadencia posterior. En este último año 2023 el campo de la pediatría sólo ha contado con la publicación de Mao, C. et al. (6), tratándose del primer estudio publicado para dirigir automáticamente a los pacientes a la especialidad adecuada en función de sus síntomas. Por tanto, a pesar de ser un tema a la orden del día, vemos que la pediatría ha sufrido una disminución en su interés.

Estados Unidos se ha convertido en la mayor potencia de investigación sobre el tema, siendo el lugar con mayor número de publicaciones. También encontramos varios estudios en los que participan autores de diferentes lugares. Entre ellas se encuentran los estudios de Barroso-García, V. et al. (7) y García-Canadilla, P et al. (8), publicados en nuestro país en los años 2020 y 2021 respectivamente. Dichos estudios pertenecen a las provincias de Valladolid, en colaboración con Estados Unidos, y Barcelona, en conjunto con Canadá. A pesar de esto, la mayoría de los estudios se han realizado en un único distrito, dificultando así su posterior generalización.

Además, haciendo referencia a los distintos ámbitos que abarca la pediatría, en nuestra revisión vemos que la Radiología es el más relevante. Como dice el estudio de Summers, R.M. (9), el aprendizaje automático en este campo es un tema candente, que puede utilizarse para un gran número de aplicaciones como la detección automatizada de enfermedades a través de imágenes. Dermicioğlu, A. et al. (10) afirman que una automatización reduciría el esfuerzo de tiempo, mientras del mismo modo conduciría a una mayor estandarización evitando la variabilidad intra e inter-evaluador. Tras obtener buenos resultados, esta materia de la medicina podría convertirse en la primera en ampliar sus estudios para una futura aplicación en la práctica clínica diaria.

Por otra parte, la subespecialidad de Neurología pediátrica también ha sido de gran interés. Encontramos estudios como los de Wissel, B.D. et al. (11) que utiliza el aprendizaje automático para identificar pacientes con epilepsia candidatos a cirugía; o los de Qi, Y. and Han, J.X. (12) en el que se desarrolla un modelo de algoritmo para modificar juguetes utilizados en la terapia de rehabilitación de niños con autismo. Esto supondría un gran avance en el futuro, mejorando las medidas terapéuticas de diversas patologías o seleccionando a aquellos pacientes que puedan beneficiarse realmente de ellas.

Las Unidades de Cuidados Intensivos Pediátricos (UCIP) también se encuentran en el punto de mira para el desarrollo de los sistemas de aprendizaje automático, y es que, como dicen Kim, S.Y. et al. (13), las escalas empleadas en UCIP no se adaptan a la clínica y progresión del paciente y ofrecen poca ayuda para una gestión individual. Por ello, el desarrollo del aprendizaje automático ofrece oportunidades de nuevas puntuaciones de predicción en los cuidados críticos. Según Mast, M. et al. (14), la práctica médica, especialmente dentro de los cuidados intensivos pediátricos, se encuentra bajo la presión del tiempo. Para lograr un éxito a largo plazo del tratamiento del paciente, sería provechoso apoyarse en los sistemas de IA.

Haciendo referencia al método algorítmico más empleado, concluimos que se trata del supervisado, es decir, aquel en el que los datos de aprendizaje están etiquetados con un resultado. Como expresan Kim, C.H. et al. (15), la IA todavía está limitada en el dominio clínico y la supervisión debería ser necesaria durante su desarrollo y validación. A pesar de ello, García-Canadilla, P et al. (8) comentan que el uso de la IA sin supervisión está evolucionando en poblaciones adultas. Esta diferencia puede ser debida al problema ético que plantea la población pediátrica a la hora de realizar investigaciones en su terreno.

Por otro lado, las funciones de los algoritmos estudiadas se encuentran con porcentajes no muy alejados entre sí. Esto nos orienta a que tanto los CDSS como el diagnóstico automatizado aportan grandes beneficios a la salud. Los CDSS comportan un sostén objetivo para los sanitarios a la hora de tomar decisiones, como por ejemplo el estudio publicado por Smith, J.C. et al. (16), el cual menciona que la aplicación de los CDSS puede guiar a un tratamiento adecuado para cada paciente. En lo referente al diagnóstico automatizado, se

trata de una herramienta eficaz a la hora de gestionar tanto el tiempo como los recursos económicos, además de reducir las variabilidades entre facultativos.

La aplicación más relevante de estos algoritmos es la clasificación, es decir, distribuir los resultados en función de sus características. Por ejemplo, en el estudio de Hurst, J.H. et al. (17), utilizan un modelo de aprendizaje automático para clasificar a los niños asmáticos en función del riesgo de presentar una exacerbación. Otro ejemplo de esta aplicación lo podemos ver en el estudio de Novak, J. et al. (18), en el que clasifican a los pacientes según su patología en tres tipos de tumores cerebrales: meduloblastomas, ependimomas y astrocitomas pilocíticos.

Con respecto a los algoritmos empleados, destacamos una preferencia por los árboles de decisión, en especial, los Random Forest (RF). Estos últimos se tratan de una multiplicidad de varios árboles de decisión constituyendo un aprendizaje conjunto, dando así mejores rendimientos. Un ejemplo podemos verlo en el estudio de Jones, C.M.A. et al. (19), que utiliza RF para clasificar la respuesta al tratamiento y predecir los niveles de calprotectina fecal en la enfermedad de Crohn. La ventaja de los árboles de decisión frente a algoritmos más complejos como son las redes neuronales es que nos permiten la interpretación del modelo, es decir, se puede llegar a entender cómo clasifica el algoritmo. Otros modelos notables son las redes neuronales, desde las Support Vector Machines (SVM) que son las más remotas, hasta los nuevos modelos de aprendizaje profundo (“deep learning”) que comprende aplicaciones más complejas, como el estudio de Mutasa, S. et al. (20) para identificar la edad ósea en niños.

Al mismo tiempo, observamos un auge en los modelos de Natural Language Processing (NLP) (procesamiento del lenguaje natural), en los que se extraen los datos directamente de textos clínicos. Un ejemplo de ello es el estudio de Yu, G. et al. (21), en el que a través de notas clínicas el modelo es capaz de diagnosticar enfermedades respiratorias en el momento de admisión en urgencias. Otra aplicación de este modelo a destacar es el estudio de Annapragada, A.V. et al. (22), en el que mediante las historias clínicas electrónicas pediátricas puede ser capaz de identificar el abuso infantil.

En relación a esto y al número de variables que utiliza cada algoritmo para su desarrollo, concluimos que la mayoría de los datos necesarios para su proceso se extraen de las historias clínicas electrónicas. Sin embargo, observamos que la principal limitación de la IA es poseer datos limitados. Como dicen Walker, L.W. et al. (23) en su publicación, la aplicación de métodos de aprendizaje automático a grandes conjuntos de datos basados en las historias clínicas electrónicas puede proporcionar predicciones que podrían mejorar la toma de decisiones clínicas. Por lo tanto, la solución a dicho problema puede ubicarse en el futuro adaptando el modo de recoger las historias clínicas electrónicas, de tal manera que tengan un enfoque práctico al aprendizaje automático.

Por otro lado, a pesar de que la utilización de curvas ROC es una forma útil de evaluar la precisión de los resultados, encontramos limitaciones a la hora de comparar estos modelos. Como hemos mencionado previamente, la mayoría de los estudios analizados han sido comparados con el método clínico utilizado habitualmente, en cambio, este método puede no ser exacto con respecto al realizado en otro centro. Un ejemplo es el estudio de Drysdale, E. et al. (24), en el que las indicaciones de realizar una pieloplastia varían entre instituciones y médicos dependiendo del programa de seguimiento. Asimismo, al contrastar los modelos algorítmicos con expertos clínicos, una limitación es el carácter subjetivo de estas opiniones. Todo ello, conlleva a una difícil generalización de los estudios a la práctica habitual.

Por tanto, visualizamos que los resultados de estos estudios son favorecedores, al ofrecer un diagnóstico preciso y más rápido, agilizar los tiempos, aliviar la carga de trabajo a profesionales médicos e incluso en la gestión de los recursos económicos. Roquette, B.P. et al. (25) comentan que, para el hospital, la detección temprana de admisiones usando machine learning se traduce en una mejor gestión de los costes. Sin embargo, esta novedosa tecnología se ve muy limitada en el campo de la medicina pediátrica. Se trata de estudios con un tamaño muestral reducido y realizados en un único distrito con una población muy determinada, lo que lleva a una dificultad a la hora de establecer si estos algoritmos son realmente beneficiosos en la propagación a la práctica médica rutinaria en otras partes del mundo. Del mismo modo, se tratan

de estudios retrospectivos, por lo que sería necesario una validación prospectiva futura antes de asumir su rendimiento.

Finalmente, a pesar de que la IA es un tema que actualmente ha ido cobrando mayor interés, en el terreno de la medicina, y más concretamente en el campo pediátrico, aún es necesaria la continuación de investigaciones. Una manera de promover los estudios a grandes escalas podría darse formando a los profesionales sanitarios e incluso a estudiantes de medicina, para así fomentar el interés y el conocimiento en la materia. Una práctica clínica que incluya el aprendizaje automático en su rutina obtendría numerosas ventajas en el futuro.

5. CONCLUSIONES

1. La Inteligencia Artificial en la salud es un tema cada vez más investigado y de mayor interés, sin embargo, sus estudios en Pediatría han ido decayendo en los últimos dos años. Terrenos como la Radiología, la Neurología y las Unidades de Cuidados Críticos han sido las más relevantes en su aplicación.
2. Para el desarrollo de algoritmos, la mayoría de los datos necesarios son extraídos de historias clínicas electrónicas. Esto nos invita en el futuro a la recogida de estas bases de datos enfocándose a su aplicación en aprendizaje automático.
3. La aplicación de la IA consigue ser un apoyo para el sistema sanitario a través de sistemas que ayudan a los profesionales sanitarios a tomar decisiones, o realizando diagnósticos de un modo más objetivo. Todo ello conlleva un ahorro del tiempo, mejor gestión económica y alivio en la carga de trabajo de los profesionales.
4. A pesar del buen rendimiento observado en los estudios individuales, se trata de publicaciones con escasa validez externa, dificultando su generalización a otras poblaciones. Por tanto, un mayor fomento en los profesionales de la salud o la introducción de la materia en las Facultades de Medicina podría lograr un mayor interés en el tema y motivar a realizar futuros estudios.

6. BIBLIOGRAFÍA

1. Ibeas J, Macias E, Boltà H, Serrano J, Morell A, Suppi R, et al. M1. Inteligencia Artificial en Salud. Institut Universitari Parc Taulí - Universidad Autònoma de Barcelona; 2023.
2. Rubin J, Potes C, Xu-Wilson M, Dong J, Rahman A, Nguyen H, et al. An ensemble boosting model for predicting transfer to the pediatric intensive care unit. *Int J Med Inform.* 2018;112:15–20.
3. Liang H, Tsui BY, Ni H, Valentim CCS, Baxter SL, Liu G, et al. Evaluation and accurate diagnoses of pediatric diseases using artificial intelligence. *Nat Med.* 2019;25(3):433–8.
4. Wadhvani SI, Hsu EK, Shaffer ML, Anand R, Ng VL, Bucuvalas JC. Predicting ideal outcome after pediatric liver transplantation: An exploratory study using machine learning analyses to leverage Studies of Pediatric Liver Transplantation Data. *Pediatr Transplant.* 2019;23(7):e13554.
5. Liang G, Zheng L. A transfer learning method with deep residual network for pediatric pneumonia diagnosis. *Comput Meth Prog Bio.* 2020;187:104964.
6. Mao C, Zhu Q, Chen R, Su W. Automatic medical specialty classification based on patients' description of their symptoms. *Bmc Med Inform Decis.* 2023;23(1):15.
7. Barroso-García V, Gutiérrez-Tobal GC, Kheirandish-Goza L, Álvarez D, Vaquerizo-Villar F, Núñez P, et al. Usefulness of recurrence plots from airflow recordings to aid in paediatric sleep apnoea diagnosis. *Comput Meth Prog Bio.* 2020;183:105083.
8. Garcia-Canadilla P, Sanchez-Martinez S, Martí-Castellote PM, Storch C, Hui W, Piella G, et al. Machine-learning-based exploration to identify remodeling patterns associated with death or heart-transplant in pediatric-dilated cardiomyopathy. *J Hear Lung Transplant.* 2022;41(4):516–26.
9. Summers RM. Deep Learning Lends a Hand to Pediatric Radiology. *Radiology.* 2018;287(1):323–5.
10. Demircioğlu A, Quinsten AS, Forsting M, Umutlu L, Nassenstein K. Pediatric age estimation from radiographs of the knee using deep learning. *Eur Radiol.* 2022;32(7):4813–22.

11. Wissel BD, Greiner HM, Glauser TA, Pestian JP, Kemme AJ, Santel D, et al. Early identification of epilepsy surgery candidates: A multicenter, machine learning study. *Acta Neurol Scand.* 2021;144(1):41–50.
12. Qi Y, Han JX. Rehabilitation Educational Design for Children with Autism Based on the Radial Basis Function Neural Network. *J Healthc Eng.* 2021;2021:2961546.
13. Kim SY, Kim S, Cho J, Kim YS, Sol IS, Sung Y, et al. A deep learning model for real-time mortality prediction in critically ill children. *Crit Care.* 2019;23(1):279.
14. Institut ESGBMWMSRJBRBKPWGAHSF c PLRI for MI of TB and HMS Hannover, Germany d Department of Pediatric Cardiology and Intensive Care Medicine, Hannover Medical School, Hannover, Germany e, Mast M, Marschollek M, Jack T, Wulff A. Informatics and Technology in Clinical Care and Public Health. *Stud Health Technol.* 2022;289:228–31.
15. Kim CH, Hahm MH, Lee DE, Choe JY, Ahn JY, Park SY, et al. Clinical usefulness of deep learning-based automated segmentation in intracranial hemorrhage. *Technol Health Care.* 2021;29(5):881–95.
16. Smith JC, Spann A, McCoy AB, Johnson JA, Arnold DH, Williams DJ, et al. Natural Language Processing and Machine Learning to Enable Clinical Decision Support for Treatment of Pediatric Pneumonia. *Amia Annu Symposium Proc Amia Symposium.* 2020;2020:1130–9.
17. Hurst JH, Zhao C, Hostetler HP, Gorveh MG, Lang JE, Goldstein BA. Environmental and clinical data utility in pediatric asthma exacerbation risk prediction models. *Bmc Med Inform Decis.* 2022;22(1):108.
18. Novak J, Zarinabad N, Rose H, Arvanitis T, MacPherson L, Pinkey B, et al. Classification of paediatric brain tumours by diffusion weighted imaging and machine learning. *Sci Rep-uk.* 2021;11(1):2987.
19. Jones CMA, Connors J, Dunn KA, Bielawski JP, Comeau AM, Langille MGI, et al. Bacterial Taxa and Functions Are Predictive of Sustained Remission Following Exclusive Enteral Nutrition in Pediatric Crohn's Disease. *Inflamm Bowel Dis.* 2020;26(7):1026–37.
20. Mutasa S, Chang PD, Ruzal-Shapiro C, Ayyala R. MABAL: a Novel Deep-Learning Architecture for Machine-Assisted Bone Age Labeling. *J Digit Imaging.* 2018;31(4):513–9.

21. Yu G, Yu Z, Shi Y, Wang Y, Liu X, Li Z, et al. Identification of pediatric respiratory diseases using a fine-grained diagnosis system. *J Biomed Inform.* 2021;117:103754.
22. Annapragada AV, Donaruma-Kwoh MM, Annapragada AV, Starosolski ZA. A natural language processing and deep learning approach to identify child abuse from pediatric electronic medical records. *Plos One.* 2021;16(2):e0247404.
23. Walker LW, Nowalk AJ, Visweswaran S. Predicting outcomes in central venous catheter salvage in pediatric central line–associated bloodstream infection. *J Am Med Inform Assn.* 2021;28(4):ocaa328.
24. Drysdale E, Khondker A, Kim JK, Kwong JCC, Erdman L, Chua M, et al. Personalized application of machine learning algorithms to identify pediatric patients at risk for recurrent ureteropelvic junction obstruction after dismembered pyeloplasty. *World J Urol.* 2022;40(2):593–9.
25. Roquette BP, Nagano H, Marujo EC, Maiorano AC. Prediction of admission in pediatric emergency department with deep neural networks and triage textual data. *Neural Networks.* 2020;126:170–7.

7. TABLAS Y FIGURAS

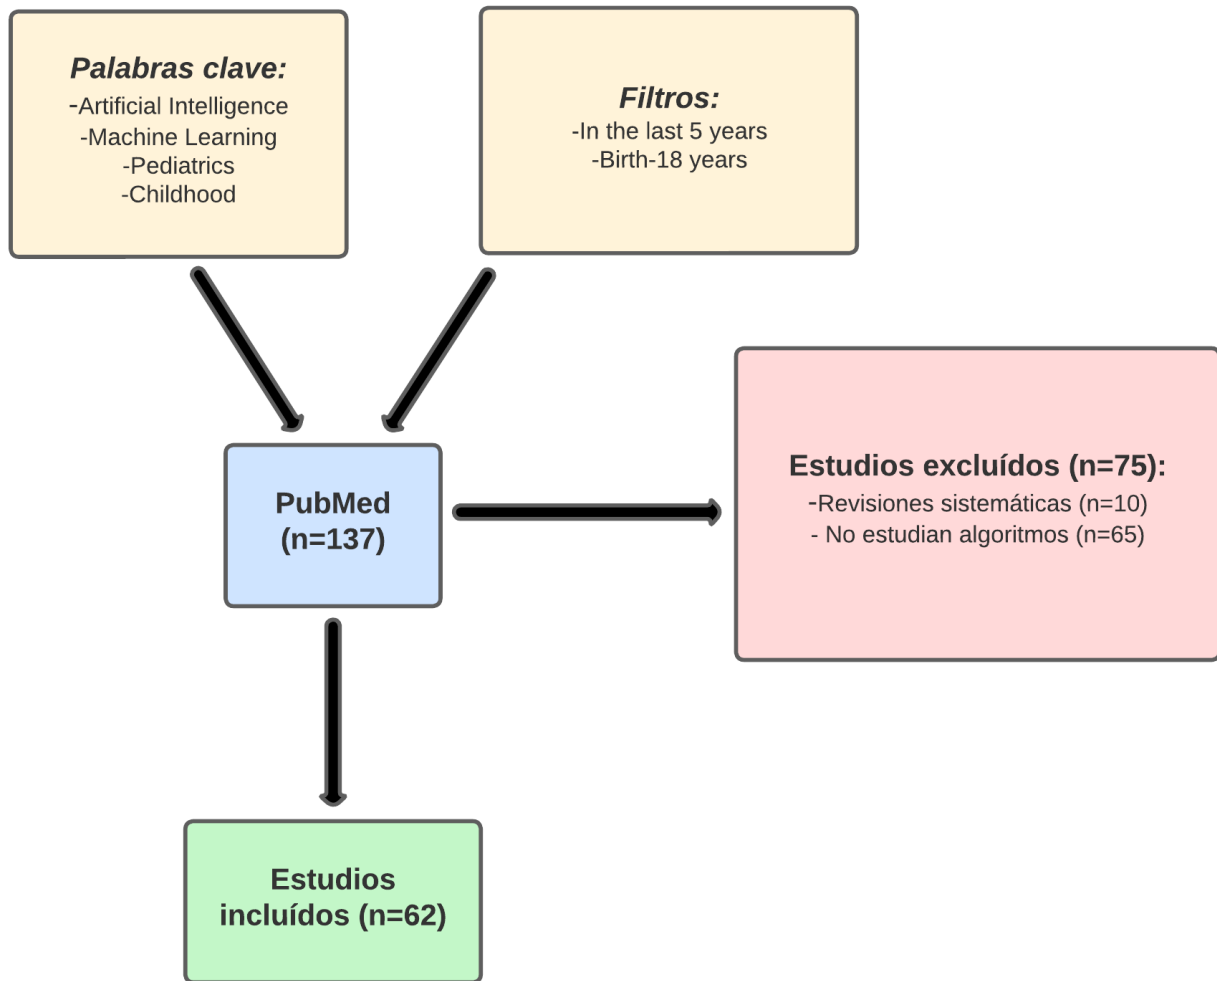


FIGURA 1. Flujograma de búsqueda de artículos.

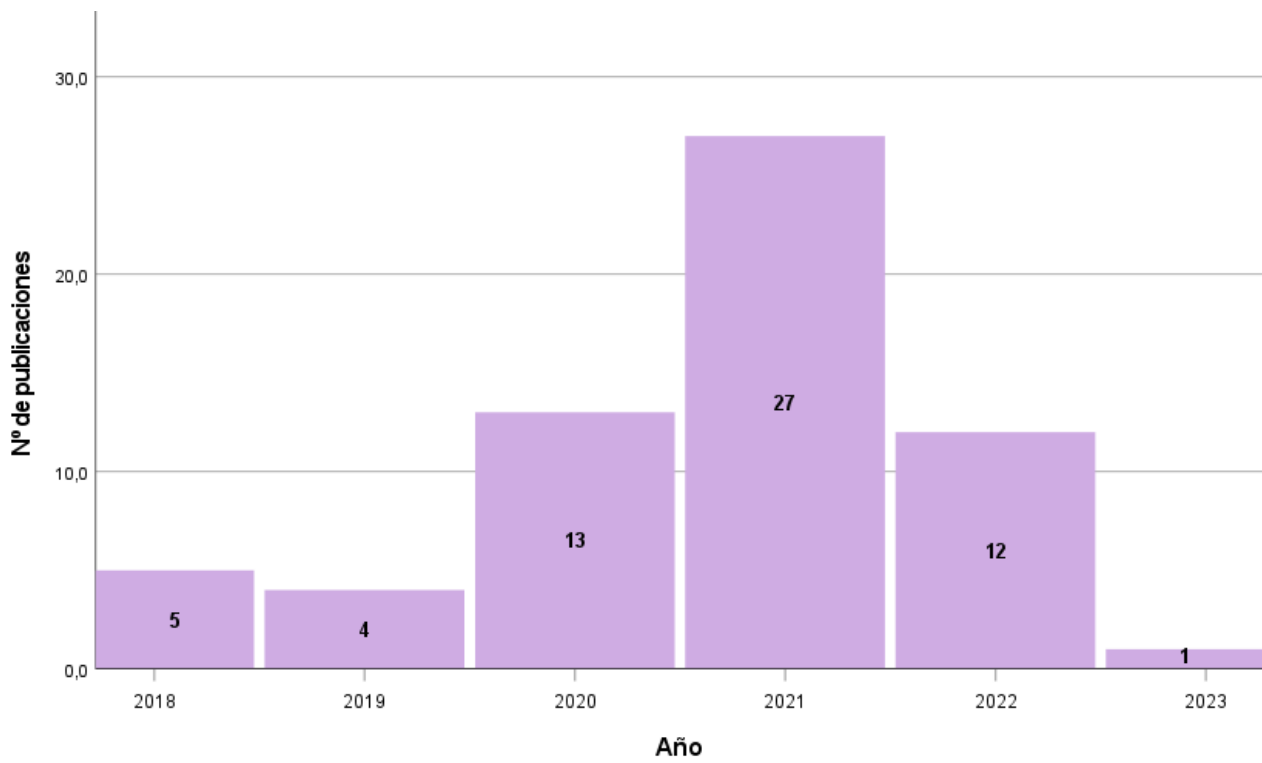


FIGURA 2. Número de publicaciones por año.

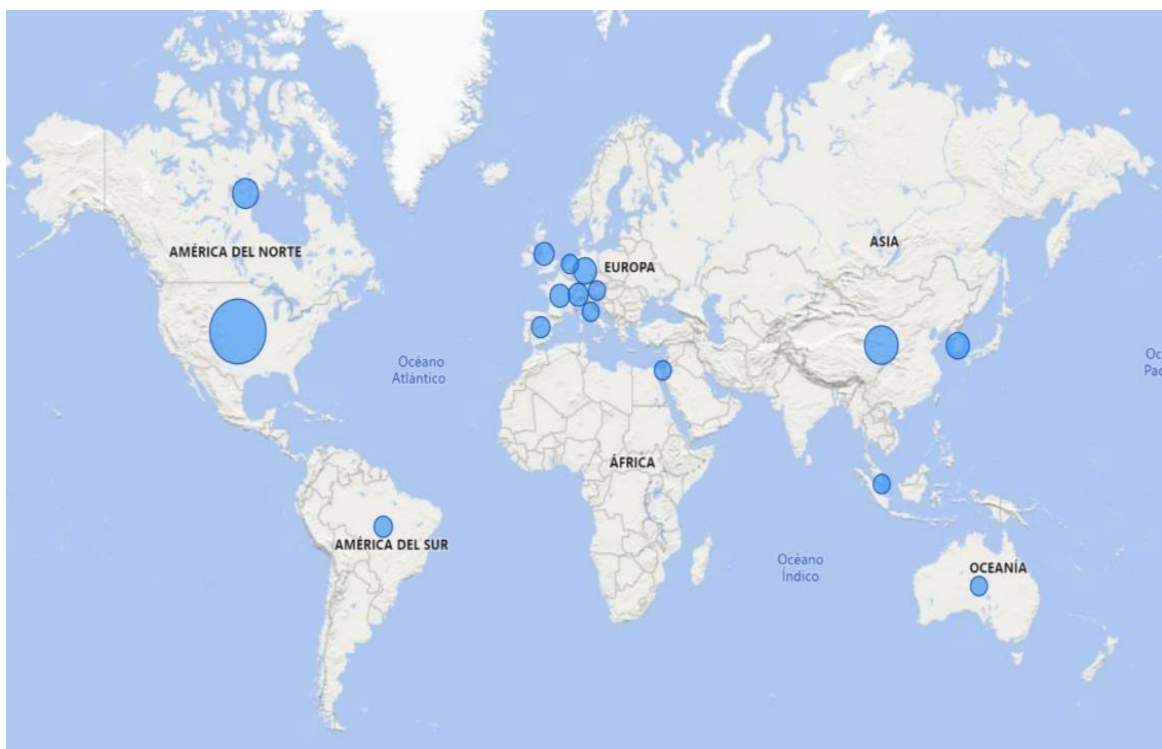


FIGURA 3. Publicaciones por ubicación geográfica.




FIGURA 4. Porcentaje de publicaciones por ámbito pediátrico.




FIGURA 5. Proporción de estudios según el método algorítmico, función desempeñada y tipo de algoritmo empleado.

Localización	Estados Unidos	27
	China	12
	Canadá	7
	Alemania	5
	Corea	5
	Francia	3
	Reino Unido	3
	Suiza	3
	Brasil	2
	España	2
	Australia	1
	Austria	1
	Israel	1
	Italia	1
	Países Bajos	1
Singapur	1	

TABLA 1. Número de publicaciones por localización geográfica.

		Recuento	%
Método AA	Supervisado	59	90,77%
	Por refuerzo	1	1,54%
	No supervisado	5	7,69%
Función	CDSS	36	58,06%
	Diagnóstico automatizado	26	41,94%
Tipo de algoritmo	Clasificación	52	82,54%
	Clusterización	7	11,11%
	Regresión	4	6,35%

TABLA 2. Clasificación de las publicaciones según el método algorítmico, función desempeñada y tipo de algoritmo empleado.

8. ANEXOS

ANEXO 1. Listado de artículos analizados.

1. [An ensemble boosting model for predicting transfer to the pediatric intensive care unit.](#)
Rubin J, Potes C, Xu-Wilson M, Dong J, Rahman A, Nguyen H, Moromisato D.
Int J Med Inform. 2018 Apr;112:15-20. doi: 10.1016/j.ijmedinf.2018.01.001. Epub 2018 Jan 9.
PMID: 29500014
2. [Deep Learning Lends a Hand to Pediatric Radiology.](#)
Summers RM.
Radiology. 2018 Apr;287(1):323-325. doi: 10.1148/radiol.2018172898.
PMID: 29558310 **Free PMC article.** No abstract available.
3. [MABAL: a Novel Deep-Learning Architecture for Machine-Assisted Bone Age Labeling.](#)
Mutasa S, Chang PD, Ruzal-Shapiro C, Ayyala R.
J Digit Imaging. 2018 Aug;31(4):513-519. doi: 10.1007/s10278-018-0053-3.
PMID: 29404850 **Free PMC article.**
4. [Using an artificial neural network to predict traumatic brain injury.](#)
Hale AT, Stonko DP, Lim J, Guillamondegui OD, Shannon CN, Patel MB.
J Neurosurg Pediatr. 2018 Nov 2;23(2):219-226. doi: 10.3171/2018.8.PEDS18370.
PMID: 30485240 **Free PMC article.**
5. [Evaluation and accurate diagnoses of pediatric diseases using artificial intelligence.](#)
Liang H, Tsui BY, Ni H, Valentim CCS, Baxter SL, Liu G, Cai W, Kermany DS, Sun X, Chen J, He L, Zhu J, Tian P, Shao H, Zheng L, Hou R, Hewett S, Li G, Liang P, Zang X, Zhang Z, Pan L, Cai H, Ling R, Li S, Cui Y, Tang S, Ye H, Huang X, He W, Liang W, Zhang Q, Jiang J, Yu W, Gao J, Ou W, Deng Y, Hou Q, Wang B, Yao C, Liang Y, Zhang S, Duan Y, Zhang R, Gibson S, Zhang CL, Li O, Zhang ED, Karin G, Nguyen N, Wu X, Wen C, Xu J, Xu W, Wang B, Wang W, Li J, Pizzato B, Bao C, Xiang D, He W, He S, Zhou Y, Haw W, Goldbaum M, Tremoulet A, Hsu CN, Carter H, Zhu L, Zhang K, Xia H.
Nat Med. 2019 Mar;25(3):433-438. doi: 10.1038/s41591-018-0335-9.
Epub 2019 Feb 11.
PMID: 30742121
6. [Prediction of mortality following pediatric heart transplant using machine learning algorithms.](#)
Miller R, Tumin D, Cooper J, Hayes D Jr, Tobias JD.

- Pediatr Transplant. 2019 May;23(3):e13360. doi: 10.1111/petr.13360.
Epub 2019 Jan 29.
PMID: 30697906
7. [A deep learning model for real-time mortality prediction in critically ill children.](#)
Kim SY, Kim S, Cho J, Kim YS, Sol IS, Sung Y, Cho I, Park M, Jang H, Kim YH, Kim KW, Sohn MH.
Crit Care. 2019 Aug 14;23(1):279. doi: 10.1186/s13054-019-2561-z.
PMID: 31412949 **Free PMC article.**
 8. [Predicting ideal outcome after pediatric liver transplantation: An exploratory study using machine learning analyses to leverage Studies of Pediatric Liver Transplantation Data.](#)
Wadhvani SI, Hsu EK, Shaffer ML, Anand R, Ng VL, Bucuvalas JC.
Pediatr Transplant. 2019 Nov;23(7):e13554. doi: 10.1111/petr.13554.
Epub 2019 Jul 22.
PMID: 31328849 **Free PMC article.**
 9. [Deep learning to automate Brasfield chest radiographic scoring for cystic fibrosis.](#)
Zucker EJ, Barnes ZA, Lungren MP, Shpanskaya Y, Seekins JM, Halabi SS, Larson DB.
J Cyst Fibros. 2020 Jan;19(1):131-138. doi: 10.1016/j.jcf.2019.04.016.
Epub 2019 May 2.
PMID: 31056440
 10. [Usefulness of recurrence plots from airflow recordings to aid in paediatric sleep apnoea diagnosis.](#)
Barroso-García V, Gutiérrez-Tobal GC, Kheirandish-Gozal L, Álvarez D, Vaquerizo-Villar F, Núñez P, Del Campo F, Gozal D, Hornero R.
Comput Methods Programs Biomed. 2020 Jan;183:105083. doi: 10.1016/j.cmpb.2019.105083. Epub 2019 Sep 18.
PMID: 31590097
 11. [A transfer learning method with deep residual network for pediatric pneumonia diagnosis.](#)
Liang G, Zheng L.
Comput Methods Programs Biomed. 2020 Apr;187:104964. doi: 10.1016/j.cmpb.2019.06.023. Epub 2019 Jun 26.
PMID: 31262537
 12. [Prediction of admission in pediatric emergency department with deep neural networks and triage textual data.](#)
Roquette BP, Nagano H, Marujo EC, Maiorano AC.
Neural Netw. 2020 Jun;126:170-177. doi: 10.1016/j.neunet.2020.03.012.
Epub 2020 Mar 18.
PMID: 32240912
 13. [A Time-Updated, Parsimonious Model to Predict AKI in Hospitalized Children.](#)

- Sandokji I, Yamamoto Y, Biswas A, Arora T, Ugwuowo U, Simonov M, Saran I, Martin M, Testani JM, Mansour S, Moledina DG, Greenberg JH, Wilson FP.
J Am Soc Nephrol. 2020 Jun;31(6):1348-1357. doi: 10.1681/ASN.2019070745. Epub 2020 May 7.
PMID: 32381598 **Free PMC article.**
14. [Bacterial Taxa and Functions Are Predictive of Sustained Remission Following Exclusive Enteral Nutrition in Pediatric Crohn's Disease.](#)
Jones CMA, Connors J, Dunn KA, Bielawski JP, Comeau AM, Langille MGI, Van Limbergen J.
Inflamm Bowel Dis. 2020 Jun 18;26(7):1026-1037. doi: 10.1093/ibd/izaa001.
PMID: 31961432 **Free PMC article.**
15. [Evaluation of Different Learning Algorithms of Neural Networks for Drug Dosing Recommendations in Pediatrics.](#)
Rödle W, Caliskan D, Prokosch HU, Kraus S.
Stud Health Technol Inform. 2020 Jun 23;271:271-276. doi: 10.3233/SHTI200106.
PMID: 32578573
16. [Reliability and accuracy of EEG interpretation for estimating age in preterm infants.](#)
Stevenson NJ, Tataranno ML, Kaminska A, Pavlidis E, Clancy RR, Griesmaier E, Roberts JA, Klebermass-Schrehof K, Vanhatalo S.
Ann Clin Transl Neurol. 2020 Sep;7(9):1564-1573. doi: 10.1002/acn3.51132. Epub 2020 Aug 7.
PMID: 32767645 **Free PMC article.**
17. [A decision support tool to find the best cyclosporine dose when switching from intravenous to oral route in pediatric stem cell transplant patients.](#)
Leclerc V, Bleyzac N, Ceraulo A, Bertrand Y, Ducher M.
Eur J Clin Pharmacol. 2020 Oct;76(10):1409-1416. doi: 10.1007/s00228-020-02918-9. Epub 2020 Jun 12.
PMID: 32533216
18. [Bone age assessment based on deep convolution neural network incorporated with segmentation.](#)
Gao Y, Zhu T, Xu X.
Int J Comput Assist Radiol Surg. 2020 Dec;15(12):1951-1962. doi: 10.1007/s11548-020-02266-0. Epub 2020 Sep 28.
PMID: 32986142
19. [Improving Image Quality and Reducing Radiation Dose for Pediatric CT by Using Deep Learning Reconstruction.](#)
Brady SL, Trout AT, Somasundaram E, Anton CG, Li Y, Dillman JR.
Radiology. 2021 Jan;298(1):180-188. doi: 10.1148/radiol.2020202317. Epub 2020 Nov 17.
PMID: 33201790

20. [Clinical usefulness of deep learning-based automated segmentation in intracranial hemorrhage.](#)
Kim CH, Hahm MH, Lee DE, Choe JY, Ahn JY, Park SY, Lee SH, Kwak Y, Yoon SY, Kim KH, Kim M, Chang SH, Son J, Cho J, Park KS, Kim JK.
Technol Health Care. 2021;29(5):881-895. doi: 10.3233/THC-202533.
PMID: 33682736
21. [Natural Language Processing and Machine Learning to Enable Clinical Decision Support for Treatment of Pediatric Pneumonia.](#)
Smith JC, Spann A, McCoy AB, Johnson JA, Arnold DH, Williams DJ, Weitkamp AO.
AMIA Annu Symp Proc. 2021 Jan 25;2020:1130-1139. eCollection 2020.
PMID: 33936489 **Free PMC article.**
22. [The impact of segmentation on whole-lung functional MRI quantification: Repeatability and reproducibility from multiple human observers and an artificial neural network.](#)
Willers C, Bauman G, Andermatt S, Santini F, Sandkühler R, Ramsey KA, Cattin PC, Bieri O, Pusterla O, Latzin P.
Magn Reson Med. 2021 Feb;85(2):1079-1092. doi: 10.1002/mrm.28476.
Epub 2020 Sep 6.
PMID: 32892445
23. [Classification of paediatric brain tumours by diffusion weighted imaging and machine learning.](#)
Novak J, Zarinabad N, Rose H, Arvanitis T, MacPherson L, Pinkey B, Oates A, Hales P, Grundy R, Auer D, Gutierrez DR, Jaspan T, Avula S, Abernethy L, Kaur R, Hargrave D, Mitra D, Bailey S, Davies N, Clark C, Peet A.
Sci Rep. 2021 Feb 4;11(1):2987. doi: 10.1038/s41598-021-82214-3.
PMID: 33542327 **Free PMC article.**
24. [A natural language processing and deep learning approach to identify child abuse from pediatric electronic medical records.](#)
Annapragada AV, Donaruma-Kwoh MM, Annapragada AV, Starosolski ZA.
PLoS One. 2021 Feb 26;16(2):e0247404. doi: 10.1371/journal.pone.0247404. eCollection 2021.
PMID: 33635890 **Free PMC article.**
25. [Predicting outcomes in central venous catheter salvage in pediatric central line-associated bloodstream infection.](#)
Walker LW, Nowalk AJ, Visweswaran S.
J Am Med Inform Assoc. 2021 Mar 18;28(4):862-867. doi: 10.1093/jamia/ocaa328.
PMID: 33463685 **Free PMC article.**
26. [Catheter related thrombosis in hospitalized infants: A neural network approach to predict risk factors.](#)

- Badheka AV, Hodge D, Ramesh S, Bloxham J, Espinoza E, Allareddy V, Karhade DS, Chegondi M, Allareddy V.
Thromb Res. 2021 Apr;200:34-40. doi: 10.1016/j.thromres.2021.01.009.
Epub 2021 Jan 27.
PMID: 33529871
27. [Sensitization to peanut, egg or pets is associated with skin barrier dysfunction in children with atopic dermatitis.](#)
Sherenian MG, Kothari A, Biagini JM, Kroner JW, Baatyrbek Kyzy A, Johannson E, Atluri G, He H, Martin LJ, Khurana Hershey GK.
Clin Exp Allergy. 2021 May;51(5):666-673. doi: 10.1111/cea.13866.
Epub 2021 Mar 21.
PMID: 33721370 **Free PMC article.**
28. [Identification of pediatric respiratory diseases using a fine-grained diagnosis system.](#)
Yu G, Yu Z, Shi Y, Wang Y, Liu X, Li Z, Zhao Y, Sun F, Yu Y, Shu Q.
J Biomed Inform. 2021 May;117:103754. doi: 10.1016/j.jbi.2021.103754.
Epub 2021 Apr 6.
PMID: 33831537
29. [Prediction of Adult Height by Machine Learning Technique.](#)
Shmoish M, German A, Devir N, Hecht A, Butler G, Niklasson A, Albertsson-Wikland K, Hochberg Z.
J Clin Endocrinol Metab. 2021 Jun 16;106(7):e2700-e2710. doi: 10.1210/clinem/dgab093.
PMID: 33606028
30. [Machine learning model on heart rate variability metrics identifies asymptomatic toddlers exposed to zika virus during pregnancy.](#)
Herry CL, Soares HMF, Schuler-Faccini L, Frasc MG.
Physiol Meas. 2021 Jun 17;42(5). doi: 10.1088/1361-6579/ac010e.
PMID: 33984844
31. [A deep learning framework for ¹⁸F-FDG PET imaging diagnosis in pediatric patients with temporal lobe epilepsy.](#)
Zhang Q, Liao Y, Wang X, Zhang T, Feng J, Deng J, Shi K, Chen L, Feng L, Ma M, Xue L, Hou H, Dou X, Yu C, Ren L, Ding Y, Chen Y, Wu S, Chen Z, Zhang H, Zhuo C, Tian M.
Eur J Nucl Med Mol Imaging. 2021 Jul;48(8):2476-2485. doi: 10.1007/s00259-020-05108-y. Epub 2021 Jan 9.
PMID: 33420912 **Free PMC article.**
32. [Age-Net: An MRI-Based Iterative Framework for Brain Biological Age Estimation.](#)
Armanious K, Abdulatif S, Shi W, Salian S, Kustner T, Weiskopf D, Hepp T, Gatidis S, Yang B.
IEEE Trans Med Imaging. 2021 Jul;40(7):1778-1791. doi: 10.1109/TMI.2021.3066857. Epub 2021 Jun 30.
PMID: 33729932

33. [Early identification of epilepsy surgery candidates: A multicenter, machine learning study.](#)
Wissel BD, Greiner HM, Glauser TA, Pestian JP, Kemme AJ, Santel D, Ficker DM, Mangano FT, Szczesniak RD, Dexheimer JW.
Acta Neurol Scand. 2021 Jul;144(1):41-50. doi: 10.1111/ane.13418. Epub 2021 Mar 26.
PMID: 33769560 **Free PMC article.**
34. [The detection of mild traumatic brain injury in paediatrics using artificial neural networks.](#)
Ellethy H, Chandra SS, Nasrallah FA.
Comput Biol Med. 2021 Aug;135:104614. doi: 10.1016/j.combiomed.2021.104614. Epub 2021 Jun 30.
PMID: 34229143
35. [Machine learning model for early prediction of acute kidney injury \(AKI\) in pediatric critical care.](#)
Dong J, Feng T, Thapa-Chhetry B, Cho BG, Shum T, Inwald DP, Newth CJL, Vaidya VU.
Crit Care. 2021 Aug 10;25(1):288. doi: 10.1186/s13054-021-03724-0.
PMID: 34376222 **Free PMC article.**
36. [Artificial Neural Network Algorithms to Predict Resting Energy Expenditure in Critically Ill Children.](#)
Spolidoro GCI, D'Oria V, De Cosmi V, Milani GP, Mazzocchi A, Akhondi-Asl A, Mehta NM, Agostoni C, Calderini E, Grossi E.
Nutrients. 2021 Oct 26;13(11):3797. doi: 10.3390/nu13113797.
PMID: 34836053 **Free PMC article.**
37. [A Clinical Decision Support Tool to Find the Best Initial Intravenous Cyclosporine Regimen in Pediatric Hematopoietic Stem Cell Transplantation.](#)
Leclerc V, Ducher M, Ceraulo A, Bertrand Y, Bleyzac N.
J Clin Pharmacol. 2021 Nov;61(11):1485-1492. doi: 10.1002/jcph.1924. Epub 2021 Jul 20.
PMID: 34105165
38. [Application of machine learning to predict the outcome of pediatric traumatic brain injury.](#)
Tunthanathip T, Oearsakul T.
Chin J Traumatol. 2021 Nov;24(6):350-355. doi: 10.1016/j.cjtee.2021.06.003. Epub 2021 Jun 8.
PMID: 34284922 **Free PMC article.**
39. [Rehabilitation Educational Design for Children with Autism Based on the Radial Basis Function Neural Network.](#)
Qi Y, Han JX.
J Healthc Eng. 2021 Nov 5;2021:2961546. doi: 10.1155/2021/2961546. eCollection 2021.
PMID: 34777730 **Free PMC article.**

40. [Characteristics of Fecal Microbiota and Machine Learning Strategy for Fecal Invasive Biomarkers in Pediatric Inflammatory Bowel Disease.](#)
Wang X, Xiao Y, Xu X, Guo L, Yu Y, Li N, Xu C.
Front Cell Infect Microbiol. 2021 Dec 7;11:711884. doi: 10.3389/fcimb.2021.711884. eCollection 2021.
PMID: 34950604 **Free PMC article.**
41. [Hybrid Method Incorporating a Rule-Based Approach and Deep Learning for Prescription Error Prediction.](#)
Lee S, Shin J, Kim HS, Lee MJ, Yoon JM, Lee S, Kim Y, Kim JY, Lee S.
Drug Saf. 2022 Jan;45(1):27-35. doi: 10.1007/s40264-021-01123-6. Epub 2021 Nov 12.
PMID: 34766251
42. [Application of deep learning image reconstruction algorithm to improve image quality in CT angiography of children with Takayasu arteritis.](#)
Sun J, Li H, Li H, Li M, Gao Y, Zhou Z, Peng Y.
J Xray Sci Technol. 2022;30(1):177-184. doi: 10.3233/XST-211033.
PMID: 34806646
43. [Developing a Data Driven Approach for Early Detection of SIRS in Pediatric Intensive Care Using Automatically Labeled Training Data.](#)
Mast M, Marschollek M, Jack T, Wulff A; Elise Study Group.
Stud Health Technol Inform. 2022 Jan 14;289:228-231. doi: 10.3233/SHTI210901.
PMID: 35062134
44. [Personalized application of machine learning algorithms to identify pediatric patients at risk for recurrent ureteropelvic junction obstruction after dismembered pyeloplasty.](#)
Drysdale E, Khondker A, Kim JK, Kwong JCC, Erdman L, Chua M, Keefe DT, Lolas M, Dos Santos J, Tasian G, Rickard M, Lorenzo AJ.
World J Urol. 2022 Feb;40(2):593-599. doi: 10.1007/s00345-021-03879-z. Epub 2021 Nov 13.
PMID: 34773476
45. [Development and validation of a deep-learning-based pediatric early warning system: A single-center study.](#)
Park SJ, Cho KJ, Kwon O, Park H, Lee Y, Shim WH, Park CR, Jhang WK.
Biomed J. 2022 Feb;45(1):155-168. doi: 10.1016/j.bj.2021.01.003. Epub 2021 Jan 18.
PMID: 35418352 **Free PMC article.**
46. [Assessment of Machine Learning-Based Medical Directives to Expedite Care in Pediatric Emergency Medicine.](#)
Singh D, Nagaraj S, Mashouri P, Drysdale E, Fischer J, Goldenberg A, Brudno M.
JAMA Netw Open. 2022 Mar 1;5(3):e222599. doi: 10.1001/jamanetworkopen.2022.2599.

- PMID: 35294539 **Free PMC article.**
47. [Machine-learning-based exploration to identify remodeling patterns associated with death or heart-transplant in pediatric-dilated cardiomyopathy.](#)
Garcia-Canadilla P, Sanchez-Martinez S, Martí-Castellote PM, Slorach C, Hui W, Piella G, Aguado AM, Nogueira M, Mertens L, Bijnsens BH, Friedberg MK.
J Heart Lung Transplant. 2022 Apr;41(4):516-526. doi: 10.1016/j.healun.2021.11.020. Epub 2021 Dec 5.
PMID: 35063339
48. [Environmental and clinical data utility in pediatric asthma exacerbation risk prediction models.](#)
Hurst JH, Zhao C, Hostetler HP, Ghiasi Gorveh M, Lang JE, Goldstein BA.
BMC Med Inform Decis Mak. 2022 Apr 22;22(1):108. doi: 10.1186/s12911-022-01847-0.
PMID: 35459216 **Free PMC article.**
49. [With or without human interference for precise age estimation based on machine learning?](#)
Han M, Du S, Ge Y, Zhang D, Chi Y, Long H, Yang J, Yang Y, Xin J, Chen T, Zheng N, Guo YC.
Int J Legal Med. 2022 May;136(3):821-831. doi: 10.1007/s00414-022-02796-z. Epub 2022 Feb 14.
PMID: 35157129
50. [Construction of Prediction Model of Renal Damage in Children with Henoch-Schönlein Purpura Based on Machine Learning.](#)
Cao T, Zhu Y, Zhu Y.
Comput Math Methods Med. 2022 May 23;2022:6991218. doi: 10.1155/2022/6991218. eCollection 2022.
PMID: 35651924 **Free PMC article.**
51. [Segmentation of the Aorta and Pulmonary Arteries Based on 4D Flow MRI in the Pediatric Setting Using Fully Automated Multi-Site, Multi-Vendor, and Multi-Label Dense U-Net.](#)
Fujiwara T, Berhane H, Scott MB, Englund EK, Schäfer M, Fonseca B, Berthussen A, Robinson JD, Rigsby CK, Browne LP, Markl M, Barker AJ.
J Magn Reson Imaging. 2022 Jun;55(6):1666-1680. doi: 10.1002/jmri.27995. Epub 2021 Nov 18.
PMID: 34792835
52. [Pediatric age estimation from radiographs of the knee using deep learning.](#)
Demircioğlu A, Quinsten AS, Forsting M, Umutlu L, Nassenstein K.
Eur Radiol. 2022 Jul;32(7):4813-4822. doi: 10.1007/s00330-022-08582-0. Epub 2022 Mar 1.
PMID: 35233665 **Free PMC article.**

53. [MRI lung lobe segmentation in pediatric cystic fibrosis patients using a recurrent neural network trained with publicly accessible CT datasets.](#)
Pusterla O, Heule R, Santini F, Weikert T, Willers C, Andermatt S, Sandkühler R, Nyilas S, Latzin P, Bieri O, Bauman G.
Magn Reson Med. 2022 Jul;88(1):391-405. doi: 10.1002/mrm.29184.
Epub 2022 Mar 29.
PMID: 35348244 **Free PMC article.**
54. [Comparison of a Deep Learning-Based Reconstruction Algorithm with Filtered Back Projection and Iterative Reconstruction Algorithms for Pediatric Abdominopelvic CT.](#)
Son W, Kim M, Hwang JY, Kim YW, Park C, Choo KS, Kim TU, Jang JY.
Korean J Radiol. 2022 Jul;23(7):752-762. doi: 10.3348/kjr.2021.0466.
Epub 2022 May 27.
PMID: 35695313 **Free PMC article.**
55. [Retraining an Artificial Intelligence Algorithm to Calculate Left Ventricular Ejection Fraction in Pediatrics.](#)
Zuercher M, Ufkes S, Erdman L, Slorach C, Mertens L, Taylor K.
J Cardiothorac Vasc Anesth. 2022 Sep;36(9):3610-3616. doi: 10.1053/j.jvca.2022.05.004. Epub 2022 May 7.
PMID: 35641411
56. [Optimization of Vancomycin Initial Dose in Term and Preterm Neonates by Machine Learning.](#)
Ponthier L, Ensuque P, Destere A, Marquet P, Labriffe M, Jacqz-Aigrain E, Woillard JB.
Pharm Res. 2022 Oct;39(10):2497-2506. doi: 10.1007/s11095-022-03351-6. Epub 2022 Aug 3.
PMID: 35918452
57. [Criticality index conducted in pediatric emergency department triage.](#)
Heyming TW, Knudsen-Robbins C, Feaster W, Ehwerhemuepha L.
Am J Emerg Med. 2021 Oct;48:209-217. doi: 10.1016/j.ajem.2021.05.004. Epub 2021 May 6.
PMID: 33975133
58. [CT-based morphologic and radiomics features for the classification of MYCN gene amplification status in pediatric neuroblastoma.](#)
Tan E, Merchant K, Kn BP, Cs A, Zhao JJ, Saffari SE, Tan PH, Tang PH.
Childs Nerv Syst. 2022 Aug;38(8):1487-1495. doi: 10.1007/s00381-022-05534-3. Epub 2022 Apr 23.
PMID: 35460355
59. [Development and technical validation of a smartphone-based pediatric cough detection algorithm.](#)
Kruizinga MD, Zhuparris A, Dessing E, Krol FJ, Sprij AJ, Doll RJ, Stuurman FE, Exadaktylos V, Driessen GJA, Cohen AF.

Pediatr Pulmonol. 2022 Mar;57(3):761-767. doi: 10.1002/ppul.25801.
Epub 2022 Jan 11.

PMID: 34964557 **Free PMC article.**

60. [A Statistical-Learning Model for Unplanned 7-Day Readmission in Pediatrics.](#)

Ehwerhemuepha L, Pugh K, Grant A, Taraman S, Chang A, Rakovski C, Feaster W.

Hosp Pediatr. 2020 Jan;10(1):43-51. doi: 10.1542/hpeds.2019-0122. Epub 2019 Dec 6.

PMID: 31811046

61. [Quantifying fluctuation in glucose levels to identify early changes in glucose homeostasis in cystic fibrosis.](#)

Brugha R, Wright M, Nolan S, Bridges N, Carr SB.

J Cyst Fibros. 2018 Nov;17(6):791-797. doi: 10.1016/j.jcf.2017.12.004. Epub 2018 Jan 10.

PMID: 29329721

62. [Automatic medical specialty classification based on patients' description of their symptoms.](#)

Mao C, Zhu Q, Chen R, Su W.

BMC Med Inform Decis Mak. 2023 Jan 20;23(1):15. doi: 10.1186/s12911-023-02105-7.

PMID: 36670382 **Free PMC article.**

ANEXO 2. Distribución de artículos por subespecialidades pediátricas.

UCI	RADIOLOGÍA	NEUROLOGÍA	PRIMARIA	CARDIOLOGÍA	DIGESTIVO	NEUMO-ALERGIA	URGENCIAS	NEFRO-UROLOGÍA	FARMACOLOGÍA	HEMATOLOGÍA	ENDOCRINO	INFECCIOSAS	REUMATOLOGÍA	GESTIÓN
art. 1	art. 2	art. 4	art. 5	art. 6	art. 8	art. 10	art. 12	art. 13	art. 15	art. 17	art. 29	art. 30	art. 42	art. 60
art. 7	art. 3	art. 16	art. 24	art. 47	art. 14	art. 11	art. 46	art. 44	art. 56	art. 37	art. 61			art. 62
art. 25	art. 9	art. 20	art. 41	art. 55	art. 40	art. 21	art. 57	art. 50						
art. 26	art. 18	art. 23				art. 27								
art. 35	art. 19	art. 31				art. 28								
art. 36	art. 22	art. 33				art. 48								
art. 43	art. 32	art. 34				art. 59								
art. 45	art. 49	art. 38												
	art. 51	art. 39												
	art. 52													
	art. 53													
	art. 54													
	art. 58													

