

USO DE HERRAMIENTAS DE INTELIGENCIA ARTIFICIAL PARA LA DETECCIÓN TEMPRANA DE ALTERACIONES DEL NEURODESARROLLO EN LA PRIMERA INFANCIA: REVISIÓN SISTEMÁTICA 2020-2026
USE OF ARTIFICIAL INTELLIGENCE TOOLS FOR THE EARLY DETECTION OF NEURODEVELOPMENTAL DISORDERS IN EARLY CHILDHOOD: A SYSTEMATIC REVIEW 2020-2026

Autores: ¹Heidy Tanya Mayorga Sánchez, ²Karla Gabriela Mora Alvarado, ³Wilson Oswaldo Sánchez Macías y ⁴Diego Esteban Fernández Olivo.

¹ORCID ID: <https://orcid.org/0000-0003-0833-0832>

²ORCID ID: <https://orcid.org/0000-0003-1265-0716>

³ORCID ID: <https://orcid.org/0009-0000-3003-1279>

⁴ORCID ID: <https://orcid.org/0000-0001-8408-2012>

¹E-mail de contacto: hmayorgas@unemi.edu.ec

²E-mail de contacto: kmoraa@unemi.edu.ec

³E-mail de contacto: wsanchezm2@unemi.edu.ec

⁴E-mail de contacto: esteban.fernandez@ucacue.edu.ec

Afiliación: ^{1*2*3*}Universidad Estatal de Milagro, (Ecuador). ^{4*}Universidad Católica de Cuenca, (Ecuador).

Artículo recibido: 13 de Mayo del 2026

Artículo revisado: 15 de Mayo del 2026

Artículo aprobado: 17 de Mayo del 2026

¹Licenciada en Ciencias de la Educación mención Mercadotecnia y Publicidad, graduada en la Universidad de Guayaquil, (Ecuador). Máster Universitario en Tecnología Educativa y Competencias Digitales, graduada en la Universidad Internacional de la Rioja, (España). Magíster en Educación mención en Pedagogía graduada en la Universidad Tecnológica Empresarial de Guayaquil, (Ecuador). Magíster en Educación Inicial por la Universidad Estatal de Milagro, (Ecuador).

²Psicóloga Clínica Educativa, graduada de la Universidad Estatal de Milagro, (UNEMI). Máster en Neuropsicología y Educación en la Universidad Internacional de La Rioja, (UNIR), (Ecuador). Posgrado en Neuropsicología Clínica en la Universidad de Nebrija, (España). Actualmente, cursando el doctorado en Educación en la Universidad Espíritu Santo (UEES), (Ecuador).

³Ingeniero en Electricidad Especialización Electrónica, egresado de la Escuela Superior Politécnica del Litoral, (Ecuador). Magíster en Gerencia Educativa, graduado en la Universidad Central del Ecuador, (Ecuador). Especialista en Gestión de Procesos Educativos, graduado en la Universidad Central del Ecuador, (Ecuador). Magíster en Matemática mención en Modelación Matemática, graduado de la Universidad Estatal de Milagro, (Ecuador).

⁴Licenciado en Ciencias de la Educación en la Especialización de Lengua, Literatura y Lenguajes Audiovisuales, graduado en la Universidad de Cuenca, (Ecuador). Máster Universitario en Tecnología Educativa y Competencias Digitales, graduado en la Universidad Internacional de la Rioja, (España).

Resumen

Esta revisión sistemática analiza la evidencia científica publicada entre 2020 y mayo de 2026 sobre el uso de herramientas de inteligencia artificial para apoyar la detección temprana de alteraciones del neurodesarrollo en niños de 0 a 5 años. El estudio se estructuró conforme a PRISMA 2020 y organizó la evidencia en función de las modalidades de datos, las familias algorítmicas, la condición objetivo y las exigencias de validación clínica. Se consideraron investigaciones que aplicaron aprendizaje automático, aprendizaje profundo, visión por computador, procesamiento de lenguaje natural, análisis acústico, seguimiento ocular, registros clínicos electrónicos y enfoques multimodales. Los hallazgos muestran un campo en rápida expansión,

concentrado principalmente en el cribado del trastorno del espectro autista y, en menor medida, en la predicción temprana de parálisis cerebral mediante análisis automatizado de movimientos espontáneos. Aunque varios estudios reportan desempeños prometedores en exactitud, sensibilidad, especificidad y AUC, la robustez de la evidencia se encuentra condicionada por la heterogeneidad metodológica, el predominio de validaciones internas, la limitada evaluación prospectiva y la escasa comprobación del rendimiento por subgrupos. La revisión concluye que la inteligencia artificial posee valor como andamiaje técnico para fortalecer el tamizaje temprano, la vigilancia del desarrollo y la priorización de derivaciones; sin embargo, su adopción en salud y educación infantil exige

validación externa, explicabilidad, supervisión profesional, protección reforzada de datos y criterios de equidad diagnóstica.

Palabras clave: Alteraciones, Inteligencia artificial, Neurodesarrollo, Detección temprana, Primera infancia.

Abstract

This systematic review analyzes the scientific evidence published between 2020 and May 2026 on the use of artificial intelligence tools to support the early detection of neurodevelopmental disorders in children aged 0 to 5 years. The study was structured according to PRISMA 2020 and organized the evidence based on data modalities, algorithmic families, target condition, and clinical validation requirements. Research applying machine learning, deep learning, computer vision, natural language processing, acoustic analysis, eye tracking, electronic health records, and multimodal approaches was considered. The findings show a rapidly expanding field, primarily focused on screening for autism spectrum disorder and, to a lesser extent, on the early prediction of cerebral palsy through automated analysis of spontaneous movements. Although several studies report promising performance in accuracy, sensitivity, specificity, and AUC, the robustness of the evidence is limited by methodological heterogeneity, the predominance of internal validations, the limited prospective evaluation, and the scarcity of subgroup performance testing. This review concludes that artificial intelligence has value as a technical framework to strengthen early screening, developmental monitoring, and referral prioritization; however, its adoption in early childhood health and education requires external validation, explainability, professional oversight, enhanced data protection, and diagnostic equity criteria.

Keywords: Disorders, Artificial intelligence,

Neurodevelopment, Early detection, Early childhood.

Sumario

Esta revisão sistemática analisa as evidências científicas publicadas entre 2020 e maio de 2026 sobre o uso de ferramentas de inteligência artificial para apoiar a detecção precoce de transtornos do neurodesenvolvimento em crianças de 0 a 5 anos. O estudo foi estruturado de acordo com o PRISMA 2020 e organizou as evidências com base em modalidades de dados, famílias algorítmicas, condição alvo e requisitos de validação clínica. Foram consideradas pesquisas que aplicaram aprendizado de máquina, aprendizado profundo, visão computacional, processamento de linguagem natural, análise acústica, rastreamento ocular, registros eletrônicos de saúde e abordagens multimodais. Os resultados mostram um campo em rápida expansão, focado principalmente na triagem para transtorno do espectro autista e, em menor grau, na predição precoce de paralisia cerebral por meio da análise automatizada de movimentos espontâneos. Embora diversos estudos relatem desempenho promissor em acurácia, sensibilidade, especificidade e AUC, a robustez das evidências é limitada pela heterogeneidade metodológica, pela predominância de validações internas, pela avaliação prospectiva limitada e pela escassez de testes de desempenho em subgrupos. Esta revisão conclui que a inteligência artificial tem valor como uma estrutura técnica para fortalecer a triagem precoce, o monitoramento do desenvolvimento e a priorização de encaminhamentos; No entanto, sua adoção na saúde e educação da primeira infância requer validação externa, explicabilidade, supervisão profissional, proteção de dados aprimorada e critérios de equidade diagnóstica.

Palavras-chave: Transtornos, Inteligência artificial, Neurodesenvolvimento, Deteção precoce, Primeira infância.

Introducción

Durante los primeros años de vida, la organización neurológica, la maduración

sensoriomotora, la emergencia del lenguaje, la regulación socioemocional y la configuración de patrones de interacción se producen con una intensidad que difícilmente vuelve a repetirse en etapas posteriores. Draper et al. (2024) sostienen que el periodo comprendido entre los dos y cinco años constituye una continuidad decisiva de las inversiones realizadas durante los primeros mil días, debido a que en esta etapa se consolidan condiciones fundamentales para la salud, el aprendizaje y el desarrollo infantil. En la misma línea Bondi et al. (2024) advierten que la evaluación del neurodesarrollo en la infancia temprana requiere marcos conceptuales y herramientas sensibles a la complejidad de dominios como la cognición, el lenguaje, la motricidad, la conducta adaptativa y la regulación socioemocional.

Sin embargo, Sandbank et al. (2023) muestran que la evidencia sobre intervenciones tempranas en niños autistas ha aumentado de manera significativa en los últimos años, aunque también señalan que la calidad metodológica y la vigilancia de efectos adversos siguen siendo aspectos críticos para interpretar sus resultados. Esta constatación refuerza una idea central: detectar temprano solo adquiere sentido si la identificación del riesgo se articula con rutas de intervención oportunas, éticas y sostenidas. Desde la mirada educativa, esta relación entre detección y respuesta es decisiva, porque la alerta temprana pierde valor si no se traduce en apoyos pedagógicos, acompañamiento familiar, adaptación del ambiente y derivación oportuna.

La inteligencia artificial ha ingresado en este debate como una tecnología capaz de extraer patrones de grandes volúmenes de datos y convertir señales conductuales, clínicas o sensoriales en indicadores de riesgo. Marschik et al. (2023) explican que las soluciones

móviles para vigilancia clínica en la infancia han abierto nuevas posibilidades para capturar videos de movimientos generales mediante aplicaciones y dispositivos cotidianos, aunque insisten en que su desarrollo exige estandarización, adaptación contextual, privacidad y sostenibilidad tecnológica. Este desplazamiento no es menor: la observación del desarrollo deja de depender exclusivamente del consultorio y comienza a extenderse hacia escenarios cotidianos, donde el niño se mueve, mira, vocaliza, interactúa y responde a estímulos en condiciones más cercanas a su vida diaria.

En el caso de la parálisis cerebral, Abbasi et al. (2023) reportan que los movimientos generales anormales constituyen un predictor relevante de trastornos progresivos del neurodesarrollo, incluida la parálisis cerebral, y plantean que la automatización de su evaluación puede contribuir a superar barreras de escalabilidad asociadas a la disponibilidad limitada de evaluadores expertos. A su vez, Passmore et al. (2024) demuestran que el aprendizaje profundo aplicado a videos capturados con teléfonos inteligentes permite rastrear movimientos infantiles entre las 12 y 18 semanas de edad corregida y predecir clasificaciones de movimientos generales fuera de entornos clínicos altamente controlados.

En el trastorno del espectro autista, Rajagopalan et al. (2024) desarrollan y validan un modelo de aprendizaje automático para predecir TEA a partir de un conjunto mínimo de información médica y antecedentes, lo que muestra el potencial de variables disponibles tempranamente para identificar niños con mayor probabilidad de presentar rasgos compatibles con esta condición. Chen et al. (2023) complementan esta perspectiva al integrar datos estructurados de historias clínicas

electrónicas y narrativas clínicas para mejorar la predicción temprana del autismo antes de los cuatro años. Más recientemente, Kim et al. (2025) evidencian la factibilidad de un sistema automatizado de identificación de TEA a partir de videos domésticos, reforzando el interés por herramientas que capturen señales conductuales en contextos naturales. Esta ampliación de modalidades también se observa en técnicas que buscan objetivar señales específicas del comportamiento infantil. Antolí et al. (2025) aplican aprendizaje automático explicable a datos de seguimiento ocular procedentes de tareas de atención social, con el propósito de clasificar perfiles y reconocer variables que diferencian a niños con TEA, trastorno del desarrollo del lenguaje y desarrollo típico. De forma convergente, Han et al. (2026) señalan, mediante una revisión sistemática con metaanálisis, que los modelos de aprendizaje automático basados en eye-tracking muestran rendimiento diagnóstico prometedor para diferenciar TEA, aunque la heterogeneidad de protocolos y algoritmos limita todavía su traducción clínica directa. En paralelo, Laguna et al. (2025) exploran el análisis automático del llanto mediante aprendizaje profundo como vía de cribado temprano para TEA, mostrando que las vocalizaciones infantiles pueden contener rasgos acústicos con valor discriminativo.

No obstante, Shahini et al. (2025) advierten, en una revisión sistemática sobre tecnologías asistidas por inteligencia artificial para niños con trastornos del neurodesarrollo, que los patrones de implementación difieren según la condición estudiada y que la heterogeneidad metodológica sigue siendo uno de los principales límites para comparar resultados. Del mismo modo, Ramírez et al. (2026) concluyen que la inteligencia artificial puede contribuir al diagnóstico temprano y a la toma de decisiones clínicas en neurodesarrollo

pediátrico, pero enfatizan que la variabilidad en diseños, poblaciones, estandarización algorítmica, interpretabilidad, privacidad, equidad y sesgo dificulta su traducción clínica sin validaciones multicéntricas y marcos regulatorios claros.

En consecuencia, el objetivo de este artículo es analizar la evidencia científica publicada entre 2020 y mayo de 2026 sobre el uso de herramientas de inteligencia artificial para la detección temprana de alteraciones del neurodesarrollo en niños de 0 a 5 años, con el fin de caracterizar las modalidades tecnológicas empleadas, valorar su rendimiento, identificar limitaciones metodológicas y discutir sus implicaciones clínicas, educativas y éticas. La ruta argumentativa se organiza en cuatro momentos: primero, se describe el procedimiento metodológico de la revisión; segundo, se presentan los estudios empíricos y los documentos de apoyo clasificados según su aporte; tercero, se discuten los hallazgos desde la relación entre desempeño algorítmico y aplicabilidad contextual; y, finalmente, se delimitan las condiciones mínimas para una adopción responsable en escenarios de salud y educación infantil.

Materiales y Métodos

La revisión adoptó como marco general las directrices PRISMA 2020 para organizar el reporte del proceso de búsqueda, selección, extracción y síntesis. Page et al. (2021) señalan que la transparencia en las revisiones sistemáticas requiere documentar de manera explícita fuentes de información, criterios de elegibilidad, proceso de selección y estrategia de síntesis. En el caso de estudios con inteligencia artificial, esta exigencia se vuelve aún más relevante, porque las decisiones sobre datos, predictores, arquitectura algorítmica, validación y métricas pueden modificar

sustantivamente la interpretación del rendimiento. En esa línea, Collins et al. (2024) proponen TRIPOD+AI como una actualización orientada a mejorar el reporte de estudios que desarrollan, validan o actualizan modelos predictivos con regresión o aprendizaje automático. Moons et al. (2025) sostienen que la evaluación crítica de modelos predictivos con IA requiere instrumentos adaptados a sus fuentes específicas de sesgo y a sus problemas de aplicabilidad. Dado que se trató de una investigación secundaria basada en documentos publicados, no se requirió aprobación ética institucional; no obstante, se asumieron principios de integridad científica, trazabilidad, consistencia metodológica y reporte honesto de las limitaciones.

La pregunta orientadora fue la siguiente: ¿qué evidencia científica se ha publicado entre 2020 y mayo de 2026 sobre el uso de herramientas de inteligencia artificial para la detección temprana de alteraciones del neurodesarrollo en niños de 0 a 5 años? Esta formulación permitió integrar estudios de exactitud diagnóstica, clasificación, predicción o cribado, siempre que incorporaran de forma explícita técnicas de aprendizaje automático o aprendizaje profundo y reportaran métricas de desempeño. Las fuentes de información consideradas fueron Scopus, PubMed, Web of Science, PsycINFO, IEEE Xplore y ACM Digital Library. La búsqueda cubrió el periodo comprendido entre el 1 de enero de 2020 y mayo de 2026. No se aplicó restricción geográfica. En cuanto al idioma, se priorizaron documentos en inglés, español y portugués, así como artículos en otros idiomas cuando el título, el resumen o la versión accesible permitieran determinar su elegibilidad. La estrategia de búsqueda combinó tres bloques conceptuales: población, condición objetivo y tecnología. El bloque de población incluyó términos como infant,

toddler, early childhood, preschool, primera infancia, lactante, niño pequeño y 0-5 years. El bloque de condición incorporó neurodevelopmental disorders, developmental delay, autism spectrum disorder, ASD, cerebral palsy, language delay, motor delay, global developmental delay y equivalentes en español. El bloque tecnológico incorporó artificial intelligence, machine learning, deep learning, computer vision, convolutional neural networks, transformers, eye-tracking, speech analysis, cry analysis, electronic health records, digital phenotyping, screening, prediction model y early detection.

La gestión de referencias se realizó mediante depuración de duplicados y revisión manual de registros. El cribado se organizó en dos fases. En la primera, se evaluaron títulos y resúmenes para descartar documentos claramente ajenos al objetivo. En la segunda, se revisaron textos completos para verificar criterios de elegibilidad. La extracción de datos se realizó mediante una matriz estandarizada que registró autoría, año, diseño, condición objetivo, rango etario, tamaño muestral, modalidad de datos, tipo de algoritmo, estrategia de validación, métricas reportadas, principales hallazgos, limitaciones y aporte para la detección temprana.

Para investigaciones de exactitud diagnóstica se consideraron los dominios clásicos de QUADAS-2 y los desarrollos recientes orientados a QUADAS-AI. Guni et al. (2024) sostienen que los estudios diagnósticos basados en IA requieren herramientas específicas de evaluación, debido a que el pipeline algorítmico introduce riesgos de sesgo que no siempre son capturados por instrumentos tradicionales. Para modelos predictivos se adoptaron criterios derivados de PROBAST+AI, con atención a selección de participantes, definición del

resultado, manejo de predictores, división entre entrenamiento y prueba, validación, sobreajuste, calibración, datos faltantes, fuga de información y aplicabilidad. De forma complementaria, Vasey et al. (2022), Cruz Rivera et al. (2020) y Liu et al. (2020) se emplearon como referentes para discutir la transición desde prototipos retrospectivos hacia estudios clínicos prospectivos y reportes de intervención con IA.

La síntesis fue narrativa y estructurada, debido a la heterogeneidad de poblaciones, condiciones, modalidades de datos, algoritmos y métricas. Los hallazgos se agruparon en cinco ejes: video y visión por computador; registros clínicos electrónicos e información médica mínima; seguimiento ocular; análisis acústico de llanto, voz o vocalización; y enfoques multimodales. No se realizó metaanálisis propio, ya que los estudios diferían en estándares de referencia, edad, contexto de captura, definición de desenlace y estrategias de validación. En su lugar, se desarrolló una interpretación crítica centrada en el equilibrio entre rendimiento técnico, validez externa, factibilidad, equidad y responsabilidad ética.

Tabla 1. Criterios de elegibilidad aplicados en la revisión

Criterio	Inclusión	Exclusión
Periodo	Publicaciones entre enero de 2020 y mayo de 2026.	Documentos fuera del periodo definido.
Población	Niños de 0 a 5 años o subgrupos identificables dentro de ese rango.	Población mayor sin desagregación por edad.
Condición objetivo	TEA, parálisis cerebral, retraso global del desarrollo, retrasos motores, lingüísticos o perfiles neurodesarrollativos tempranos.	Condiciones no relacionadas con neurodesarrollo o sin interés en detección temprana.
Tecnología	IA, aprendizaje automático, aprendizaje profundo, visión por computador, NLP, análisis acústico, eye-tracking, EHR o multimodalidad.	Herramientas tradicionales sin componente algorítmico o intervenciones no basadas en IA.
Resultado	Métricas de desempeño o utilidad diagnóstica/predictiva.	Documentos sin resultados, protocolos sin datos o reportes sin métricas comparables.
Tipo de documento	Estudios empíricos y evidencia de síntesis relevante; documentos metodológicos recientes usados como apoyo interpretativo.	Opiniones, editoriales sin método o textos sin información suficiente para evaluación crítica.

Fuente: Elaboración propia

Se identificaron 97 registros iniciales; tras eliminar 62 duplicados, quedaron 35 registros para cribado. De estos, 11 fueron excluidos por título y resumen, y 24 informes fueron buscados para recuperación. Trece informes no pudieron recuperarse o no ofrecieron información suficiente. Finalmente, 11 documentos fueron evaluados a texto completo; de ellos, 9 estudios empíricos cumplieron los criterios para integrar la síntesis principal. Dos documentos metodológicos o de síntesis fueron considerados de forma complementaria para apoyar la interpretación de calidad, sesgo, aplicabilidad y condiciones de implementación.

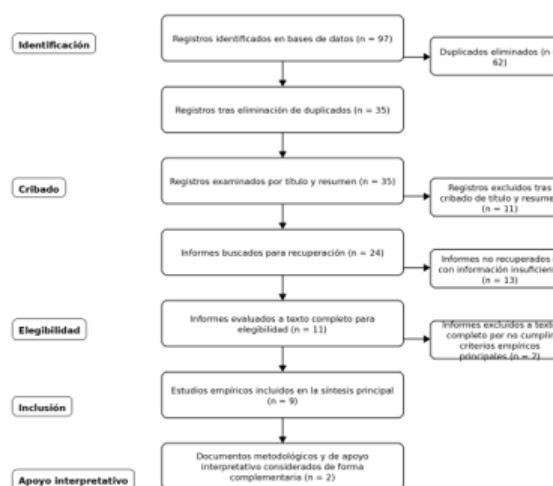


Figura 1. Diagrama de flujo PRISMA 2020

Fuente: Elaboración propia

Resultados y Discusión

La evidencia revisada muestra un campo en expansión, aunque todavía marcado por una maduración metodológica desigual. La mayor concentración de estudios se ubica en el trastorno del espectro autista (TEA), seguido por investigaciones orientadas a la identificación automatizada de patrones motores asociados al riesgo de parálisis cerebral. Esta distribución no resulta casual: el TEA y la parálisis cerebral constituyen dos

condiciones en las que la detección temprana puede modificar de manera significativa las rutas de derivación, acompañamiento e intervención. Para evitar una interpretación metodológicamente ambigua de la evidencia, los documentos revisados se organizaron en dos grupos. El primero corresponde a estudios empíricos que desarrollaron, validaron o aplicaron herramientas de inteligencia artificial para detección, cribado, clasificación o predicción de alteraciones del neurodesarrollo en la infancia temprana. El segundo reúne guías metodológicas, revisiones de síntesis y marcos de apoyo interpretativo empleados para valorar la calidad del reporte, el riesgo de sesgo, la aplicabilidad clínica y las implicaciones éticas de los modelos.

En términos de modalidades, predominaron los estudios basados en video doméstico, video clínico, registros clínicos electrónicos, información médica mínima, seguimiento ocular y análisis acústico del llanto. Estas fuentes expresan una transformación relevante en la forma de observar el neurodesarrollo infantil: el análisis ya no se limita exclusivamente a instrumentos clínicos aplicados en entornos especializados, sino que comienza a incorporar señales producidas en escenarios cotidianos, como el hogar, las interacciones familiares o los registros generados durante la atención habitual.

Un primer resultado relevante es que el video se ha consolidado como una modalidad privilegiada para la detección temprana. En TEA, los videos domésticos han sido utilizados para capturar atención social, expresividad, respuesta al nombre, juego, imitación e interacción familiar. En parálisis cerebral, los videos de lactantes permiten analizar movimientos espontáneos, simetría, fluidez, variabilidad motora y patrones corporales

tempranos. Esta modalidad resulta especialmente atractiva porque aprovecha dispositivos ampliamente disponibles, aunque también introduce desafíos de iluminación, encuadre, duración de la grabación, ruido contextual y participación de los cuidadores.

Un segundo resultado se relaciona con el uso de datos clínicos ya existentes, como registros electrónicos de salud, narrativas médicas o información mínima de antecedentes. Estos enfoques poseen un alto potencial de escalamiento porque no dependen necesariamente de nuevas pruebas, sino de datos generados en la atención habitual. Sin embargo, esta línea presenta una vulnerabilidad epistemológica particular: los registros clínicos no son una representación neutral del desarrollo infantil, sino el resultado de trayectorias de acceso, prácticas institucionales de documentación, decisiones profesionales, disponibilidad de servicios y desigualdades previas en la atención.

Un tercer resultado apunta a la búsqueda creciente de interpretabilidad. Los estudios basados en seguimiento ocular y aprendizaje automático explicable no se orientan únicamente a clasificar casos, sino a identificar qué variables diferencian perfiles de desarrollo. Esta orientación resulta crucial en salud y educación infantil, debido a que no basta con que un algoritmo emita un puntaje de riesgo; es necesario comprender qué señales sostienen esa clasificación, cómo se relacionan con la trayectoria evolutiva del niño y de qué manera pueden dialogar con la evaluación clínica, psicológica o educativa. Varios estudios reportan métricas prometedoras, pero no siempre documentan validación externa, calibración, rendimiento por subgrupos, comparación con evaluadores humanos.

Tabla 2. Estudios empíricos principales sobre inteligencia artificial para la detección temprana de alteraciones del neurodesarrollo

Autor/año	Condición objetivo	Modalidad de datos	Enfoque algorítmico	Hallazgo principal	Lectura crítica
Leblanc et al. (2020)	TEA	Video doméstico	Aprendizaje automático con reemplazo de características	Mostraron que los métodos de reemplazo de características permiten trabajar con datos incompletos de videos caseros sin deterioro sustancial del rendimiento del modelo.	Aporta realismo metodológico, debido a que los datos capturados en el hogar suelen ser incompletos, heterogéneos y dependientes del contexto familiar.
Groos et al. (2022)	Parálisis cerebral	Videos de movimientos espontáneos	Aprendizaje profundo	Desarrollaron y validaron un método para predecir parálisis cerebral en lactantes de alto riesgo a partir de movimientos espontáneos.	El diseño multicéntrico fortalece la evidencia; sin embargo, la población de alto riesgo limita la extrapolación directa a tamizaje universal.
Abbasi et al. (2023)	Riesgo motor / parálisis cerebral	Video de dispositivos móviles	Estimación de pose sin marcadores	Propusieron un sistema automatizado para rastrear movimientos infantiles en videos de dispositivos móviles sin uso de marcadores corporales.	Fortalece la posibilidad de vigilancia remota, aunque su desempeño depende de la calidad del video, la estandarización de captura y la validez en contextos no controlados.
Chen et al. (2023)	TEA	Registros clínicos electrónicos y narrativas clínicas	Modelos predictivos y ensamble	Integraron datos estructurados y narrativas clínicas para anticipar diagnósticos posteriores de TEA antes de los cuatro años.	Tiene alto potencial de escalamiento, pero es sensible a sesgos de registro, diferencias de acceso al sistema de salud y variabilidad en la documentación clínica.
Passmore et al. (2024)	Movimientos anómalos / parálisis cerebral	Videos de teléfonos inteligentes	Aprendizaje profundo y seguimiento corporal	Predijeron clasificaciones de movimientos generales a partir de videos capturados fuera de entornos clínicos controlados.	Relevante para detección remota y vigilancia temprana; requiere validación prospectiva, protocolos de captura y análisis de factibilidad operativa.
Rajagopalan et al. (2024)	TEA	Información médica y antecedentes mínimos	Aprendizaje automático supervisado	Desarrollaron modelos para predecir TEA con un conjunto reducido de variables tempranas y validación en cohortes independientes.	Prometedor para triage y priorización de derivaciones, aunque no sustituye evaluación diagnóstica especializada y requiere evaluación de equidad por subgrupos.
Antolí et al. (2025)	TEA y trastorno del desarrollo del lenguaje	Eye-tracking en tareas de atención social	Aprendizaje automático explicable	Identificaron variables oculométricas relevantes para diferenciar perfiles de desarrollo.	Avanza hacia modelos interpretables, aunque su implementación demanda equipamiento específico, protocolos estandarizados y validación clínica.
Kim et al. (2025)	TEA	Videos domésticos breves	Aprendizaje profundo y clasificadores de ensamble	Propusieron un sistema automatizado de identificación de TEA a partir de videos del hogar con tareas breves.	Muestra potencial de escalabilidad, pero su utilidad clínica depende de validación externa, regulación del uso de videos familiares y supervisión profesional.
Laguna et al. (2025)	TEA	Llanto infantil	Aprendizaje profundo aplicado a señales acústicas	Exploraron rasgos acústicos del llanto como apoyo al cribado temprano de TEA.	Línea innovadora y potencialmente accesible, aunque vulnerable al ruido ambiental, al dispositivo de grabación y a la variabilidad cultural-contextual.

Fuente: Elaboración propia

La tabla incluye estudios empíricos centrados en detección, cribado, clasificación o predicción basada en inteligencia artificial. Los documentos metodológicos, normativos y de apoyo interpretativo se presentan por separado para evitar mezclar evidencia primaria con guías de reporte, evaluación o gobernanza. Los

resultados de esta revisión permiten sostener que la inteligencia artificial ha dejado de ocupar un lugar marginal en la investigación sobre neurodesarrollo infantil para convertirse en un componente emergente de los sistemas de vigilancia temprana.

Tabla 3. Documentos metodológicos, evidencia de síntesis y marcos de apoyo interpretativo empleados en la revisión

Documento	Tipo de aporte	Uso en el artículo	Razón para no tratarlo como estudio empírico incluido
Page et al. (2021)	Guía PRISMA 2020	Estructura el reporte del proceso de revisión sistemática, especialmente identificación, cribado, elegibilidad e inclusión.	Es una guía metodológica de reporte, no un estudio sobre IA aplicada a neurodesarrollo.
Collins et al. (2024)	TRIPOD+AI	Aporta criterios para valorar el reporte de estudios que desarrollan, validan o actualizan modelos predictivos con IA.	No evalúa población infantil ni herramientas específicas de detección temprana.
Moons et al. (2025)	PROBAST+AI	Orienta la evaluación crítica del riesgo de sesgo, calidad y aplicabilidad de modelos predictivos con IA.	Es una herramienta metodológica para valoración de modelos, no evidencia primaria de detección.
Guni et al. (2024)	QUADAS-AI	Apoya la discusión sobre calidad y aplicabilidad de estudios de exactitud diagnóstica basados en IA.	Es un protocolo/herramienta de evaluación metodológica, no un estudio empírico en población infantil.
Vasey et al. (2022)	DECIDE-AI	Permite discutir la evaluación clínica temprana de sistemas de apoyo a decisiones basados en IA.	No reporta desempeño de herramientas de IA en detección del neurodesarrollo.
Cruz Rivera et al. (2020)	SPIRIT-AI	Informa criterios para protocolos de ensayos clínicos con intervenciones basadas en IA.	Documento de reporte de protocolos; no constituye evidencia empírica de cribado infantil.
Liu et al. (2020)	CONSORT-AI	Aporta criterios para reportar ensayos clínicos que involucran IA.	Documento metodológico de reporte; no evalúa herramientas de detección temprana.
Sandbank et al. (2023)	Metaanálisis de intervención temprana en TEA	Justifica la relevancia clínica y educativa de detectar tempranamente para activar apoyos oportunos.	Evalúa intervenciones tempranas, no herramientas de IA para detección o cribado.
Shahini et al. (2025)	Revisión sistemática sobre IA en trastornos del neurodesarrollo	Permite contextualizar la heterogeneidad del campo, las modalidades tecnológicas y los desafíos de implementación.	Es evidencia de síntesis, no estudio primario de detección en primera infancia.
Ramírez et al. (2026)	Revisión de alcance sobre IA en diagnóstico de trastornos del neurodesarrollo pediátrico	Apoya la discusión sobre oportunidades, limitaciones y condiciones de traducción clínica de la IA.	Es revisión de alcance; no constituye evidencia primaria ni se limita necesariamente a 0-5 años.

Fuente: Elaboración propia

No obstante, desde una mirada educativa, este avance no debe interpretarse únicamente como una innovación técnica aplicada al campo clínico, sino como una transformación potencial en la manera en que las instituciones educativas, las familias y los profesionales de apoyo pueden observar, registrar, interpretar y responder a las primeras señales del desarrollo infantil. En la introducción se planteó que la primera infancia constituye una zona crítica del desarrollo humano, donde la organización neurológica, la maduración motora, la emergencia del lenguaje, la interacción social y la regulación socioemocional se configuran de manera intensa. Los hallazgos confirman que la

IA ingresa precisamente en ese espacio de alta sensibilidad evolutiva, no para reemplazar la mirada profesional, sino para ampliar la capacidad de observación y apoyar decisiones más oportunas. Esta precisión es fundamental para un artículo construido desde el campo educativo. En educación inicial, la detección temprana no equivale al diagnóstico clínico, sino a la identificación de señales que pueden orientar apoyos, adaptaciones, derivaciones y procesos de acompañamiento familiar. Por ello, el valor de la IA no debe medirse únicamente por su exactitud, sensibilidad o especificidad, sino por su capacidad para fortalecer una cultura institucional de

observación del desarrollo. La escuela, el centro infantil o el servicio de educación inicial suelen ser espacios privilegiados para advertir diferencias en la comunicación, el juego, la interacción, la motricidad, la atención conjunta, la respuesta a rutinas o la participación social. Desde esta perspectiva, la IA puede entenderse como un andamiaje técnico que ayuda a organizar señales dispersas, pero la interpretación pedagógica de esas señales continúa siendo una responsabilidad humana, situada y contextual.

La concentración de estudios en trastorno del espectro autista confirma una tendencia relevante del campo. El TEA aparece como la condición más explorada por modelos de IA debido a la complejidad de su fenotipo temprano y a la diversidad de señales conductuales que pueden observarse en contextos naturales. Rajagopalan et al. (2024) muestran que un conjunto mínimo de información médica y antecedentes puede contribuir a estimar riesgo de TEA, mientras que Chen et al. (2023) amplían esta posibilidad al integrar registros clínicos electrónicos y narrativas médicas para anticipar diagnósticos posteriores.

Estos estudios dialogan con el marco teórico de la introducción, en el que se señalaba que la IA convierte señales conductuales, clínicas o sensoriales en indicadores de riesgo. Sin embargo, desde una perspectiva educativa, esta conversión debe ser interpretada con prudencia. Un dato médico o conductual puede orientar una alerta, pero no sustituye la comprensión pedagógica del niño en su ambiente de aprendizaje, su historia familiar, sus oportunidades de interacción, su cultura comunicativa ni sus formas particulares de participación. En este punto emerge una tensión clave entre predicción y comprensión.

Los modelos de Rajagopalan et al. (2024) y Chen et al. (2023) muestran que es posible anticipar riesgo mediante datos relativamente disponibles, lo cual podría facilitar rutas de triage en sistemas con alta demanda. Sin embargo, el educador no trabaja únicamente con probabilidades, sino con trayectorias. Un niño no se reduce a una variable de riesgo; su desarrollo se expresa en una historia de relaciones, oportunidades, apoyos, barreras y respuestas del entorno. Por tanto, cuando estos modelos se trasladan al campo educativo, deben emplearse como insumos para fortalecer la observación y no como mecanismos de clasificación.

Los estudios basados en video doméstico, representados por Leblanc et al. (2020) y Kim et al. (2025), resultan especialmente relevantes para la educación inicial porque desplazan la observación del desarrollo hacia escenarios cotidianos. Leblanc et al. (2020) muestran que los modelos pueden trabajar con datos incompletos de videos caseros mediante técnicas de reemplazo de características, lo cual reconoce un problema real: los videos familiares rara vez se producen bajo condiciones controladas. Kim et al. (2025), por su parte, avanzan hacia sistemas automatizados de identificación de TEA a partir de videos breves del hogar.

En términos educativos, estos hallazgos son importantes porque conectan con una práctica habitual de los docentes de primera infancia: interpretar conductas en contexto. La conducta infantil no ocurre en abstracto; aparece durante el juego, la alimentación, el movimiento, la interacción con adultos, la imitación, la exploración de objetos y las rutinas de cuidado. El video permite capturar parte de esa riqueza contextual, aunque también exige criterios éticos y pedagógicos claros sobre qué se graba,

para qué se graba, quién observa y cómo se utiliza la información. Desde la educación, el hogar y la escuela no pueden convertirse en simples fuentes de datos. La observación audiovisual de niños pequeños implica rostros, voces, cuerpos, interacciones familiares y espacios íntimos. Por eso, si los videos domésticos o escolares llegaran a incorporarse en procesos de tamizaje, deberían existir protocolos rigurosos de consentimiento informado, resguardo de información, finalidad educativa y devolución comprensible de resultados. Además, las familias y los docentes necesitan saber que un video analizado por IA no produce un diagnóstico, sino una señal que requiere interpretación profesional.

La evidencia relacionada con parálisis cerebral presenta una configuración distinta. Groos et al. (2022), Abbasi et al. (2023) y Passmore et al. (2024) se orientan hacia el análisis automatizado de movimientos espontáneos del lactante, apoyándose en una tradición clínica previamente consolidada. A diferencia del TEA, donde las señales son más heterogéneas y dependen fuertemente del contexto social y comunicativo, el análisis de movimientos generales se vincula con patrones motores observables en ventanas tempranas específicas.

Groos et al. (2022) desarrollan y validan un método de aprendizaje profundo para predecir parálisis cerebral en lactantes de alto riesgo; Abbasi et al. (2023) proponen seguimiento automatizado de movimientos infantiles mediante videos de dispositivos móviles; y Passmore et al. (2024) avanzan en la identificación de movimientos anómalos a partir de videos capturados con teléfonos inteligentes. Desde el enfoque educativo, la parálisis cerebral y las alteraciones motoras tempranas no afectan únicamente el desarrollo clínico del niño, sino también su acceso al

juego, la exploración, la autonomía, la comunicación corporal y la participación en experiencias educativas tempranas. Una identificación más oportuna puede facilitar intervenciones de estimulación motora, adaptaciones del ambiente, orientación a cuidadores, adecuaciones de materiales y coordinación con terapias de apoyo. Sin embargo, también se requiere cautela: los estudios con lactantes de alto riesgo no pueden extrapolarse de manera directa a poblaciones generales de educación inicial.

En contextos educativos, donde la prevalencia puede ser menor y la diversidad del desarrollo más amplia, los falsos positivos podrían generar ansiedad familiar o derivaciones innecesarias, mientras que los falsos negativos podrían retrasar apoyos necesarios. Por ello, el uso educativo de estas herramientas debería vincularse con protocolos de vigilancia del desarrollo y no con decisiones aisladas basadas en una única medición algorítmica. La línea de seguimiento ocular, representada por Antolí et al. (2025), aporta otro elemento central para el diálogo entre IA y educación: la interpretabilidad.

Los resultados muestran que los modelos basados en eye-tracking no solo buscan clasificar perfiles, sino identificar variables oculométricas relacionadas con atención social y diferencias en el desarrollo. Esta posibilidad es valiosa porque la atención visual, la orientación hacia estímulos sociales, la mirada compartida y el seguimiento de interacciones son componentes estrechamente relacionados con la participación en actividades de aula, el aprendizaje por imitación y la comunicación temprana. Sin embargo, que un modelo identifique una variable oculométrica discriminativa no significa que el docente cuente automáticamente con una estrategia

educativa pertinente. La pregunta pedagógica es más amplia: cómo se expresa esa diferencia en la interacción cotidiana, qué apoyos necesita el niño para participar, qué ajustes debe realizar el entorno y cómo evitar que la señal se convierta en etiqueta.

El análisis acústico del llanto, explorado por Laguna et al. (2025), abre una línea innovadora pero todavía incipiente. Este enfoque parte de la idea de que el llanto, la voz y las vocalizaciones tempranas pueden contener rasgos acústicos asociados a diferencias neurodesarrollativas. En principio, su atractivo educativo y comunitario radica en su bajo costo potencial y en la posibilidad de capturar señales tempranas sin equipamiento sofisticado. No obstante, desde una mirada educativa, esta línea exige una lectura especialmente cuidadosa. Las vocalizaciones infantiles están profundamente mediadas por el contexto de cuidado, la edad, el estado emocional, la lengua, las prácticas familiares, la salud del niño y el ambiente sonoro. Por tanto, aunque Laguna et al. (2025) muestran un camino prometedor, su uso en escenarios educativos debe considerarse todavía exploratorio.

Antes de pensar en implementación, se requiere validación externa, diversidad cultural y protocolos que eviten interpretar diferencias comunicativas como déficit sin considerar el contexto. En conjunto, estos resultados confirman la noción de fenotipado digital del neurodesarrollo planteada en la introducción. Los modelos revisados convierten videos, movimientos, miradas, registros clínicos, antecedentes y señales acústicas en representaciones computacionales del desarrollo infantil. Esta operación tiene potencial, pero también introduce una tensión epistemológica relevante para los educadores: el desarrollo no es solo un patrón de datos, sino

una trayectoria situada. La IA puede identificar regularidades, pero la educación trabaja con singularidades. En el aula, dos niños con señales similares pueden requerir apoyos distintos porque sus historias, contextos familiares, estilos comunicativos y oportunidades de aprendizaje no son iguales. Por ello, la IA no debe conducir a una pedagogía de la predicción, sino a una pedagogía de la observación informada, donde la tecnología ayude a mirar mejor, pero no decida por el docente ni por el equipo interdisciplinario. Desde el punto de vista metodológico, los resultados muestran una brecha clara entre rendimiento técnico y madurez de implementación. Varios estudios reportan desempeños prometedores, pero no siempre documentan validación externa, calibración, análisis por subgrupos, comparación con evaluadores humanos o evaluación prospectiva en flujos reales de atención.

Esta limitación es particularmente importante para educación, porque una herramienta que funciona en una muestra controlada puede comportarse de manera diferente en un centro infantil con diversidad cultural, lingüística, socioeconómica y familiar. Collins et al. (2024), mediante TRIPOD+AI, insisten en la necesidad de reportar con transparencia el desarrollo, validación y actualización de modelos predictivos con IA. Moons et al. (2025), desde PROBAST+AI, amplían esta exigencia al análisis de riesgo de sesgo y aplicabilidad. Guni et al. (2024), con QUADAS-AI, refuerzan la necesidad de herramientas específicas para valorar estudios diagnósticos basados en IA. Estas orientaciones son fundamentales porque un modelo educativo-clínico no puede evaluarse solo por su exactitud; debe analizarse también su robustez, trazabilidad, equidad y utilidad

contextual. La dimensión de equidad merece un lugar central en la discusión. En la introducción se señaló que la detección temprana adquiere especial relevancia en territorios con desigualdad de acceso, escasez de profesionales y baja disponibilidad de servicios especializados. Los resultados muestran que algunas modalidades, como videos domésticos o información médica mínima, podrían ampliar el alcance del tamizaje. Sin embargo, también pueden reproducir desigualdades.

Las familias con mayor alfabetización digital pueden grabar mejores videos; los niños con mayor acceso al sistema de salud tendrán registros clínicos más completos; los contextos urbanos podrían estar mejor representados en las bases de datos; y las prácticas comunicativas de determinados grupos culturales podrían ser interpretadas como desviaciones si el modelo no fue entrenado con suficiente diversidad. Por ello, la equidad diagnóstica debe entenderse como una dimensión del desempeño del modelo y no como una reflexión posterior. Un sistema de IA que presenta buenos indicadores globales, pero falla en niños de determinados contextos sociales, culturales o lingüísticos, no puede considerarse aceptable para educación inicial.

La finalidad educativa de la detección temprana no es clasificar niños, sino garantizar apoyos. Esto implica que todo sistema de IA debería ser evaluado en función de su contribución a reducir barreras y no de su capacidad para producir etiquetas. Desde esta lógica, la pregunta central no es solo qué tan bien predice, sino a quién beneficia, a quién puede perjudicar, qué decisiones activas, qué apoyos genera y cómo se asegura que el resultado no derive en exclusión. En el plano ético, la aplicación de IA en primera infancia exige una protección reforzada. La infancia

temprana se caracteriza por una autonomía limitada para decidir sobre la captura, almacenamiento y procesamiento de datos. Esta situación obliga a que el consentimiento familiar no sea tratado como un trámite, sino como un proceso informado, comprensible y situado. Cuando se trabaja con videos, audios, registros clínicos o datos de interacción, no solo se registra al niño, sino también parte de su entorno familiar y educativo. Esto demanda criterios de minimización de datos, finalidad explícita, seguridad, anonimización, control de acceso y mecanismos de auditoría.

Desde la educación, además, debe garantizarse que la información obtenida no sea utilizada para excluir, etiquetar o limitar expectativas, sino para activar apoyos oportunos y respetuosos. La comunicación de resultados constituye otro punto sensible. Un puntaje de riesgo puede ser útil para priorizar una derivación, pero también puede generar ansiedad familiar o interpretaciones deterministas si se comunica sin mediación profesional. En educación inicial, donde las familias suelen buscar respuestas ante señales que les preocupan, el docente y el equipo de apoyo deben evitar convertir la alerta en diagnóstico. El algoritmo no dice quién es el niño; solo ofrece una estimación basada en datos y modelos.

La responsabilidad educativa consiste en traducir esa información en acompañamiento, observación ampliada, diálogo con la familia y derivación pertinente cuando sea necesario. Por tanto, el lenguaje utilizado debe ser prudente: hablar de señales, riesgo, necesidad de valoración o seguimiento, no de diagnóstico cerrado. Esta discusión permite precisar la contribución del artículo. La IA puede fortalecer la detección temprana de alteraciones del neurodesarrollo, pero solo si se

integra en una lógica educativa, inclusiva e interdisciplinaria. Su aporte más valioso no es sustituir al especialista ni al educador, sino ampliar las condiciones para que el desarrollo infantil sea observado de manera más sistemática, sensible y oportuna. Desde esta perspectiva, el docente de educación inicial no se convierte en operador pasivo de una herramienta tecnológica, sino en mediador crítico entre los datos, el contexto y las decisiones pedagógicas. Esta mediación es fundamental porque la educación trabaja con posibilidades de desarrollo, no únicamente con indicadores de riesgo.

En síntesis, el campo se encuentra en una fase de transición. Los estudios de Leblanc et al. (2020), Kim et al. (2025), Rajagopalan et al. (2024), Chen et al. (2023), Antolí et al. (2025), Laguna et al. (2025), Groos et al. (2022), Abbasi et al. (2023) y Passmore et al. (2024) muestran rutas tecnológicas diversas y prometedoras para ampliar el tamizaje temprano. Sin embargo, la evidencia todavía requiere mayor validación externa, diversidad muestral, estudios prospectivos, análisis de equidad, evaluación de aceptabilidad familiar y profesional, y pruebas de impacto en escenarios reales de salud y educación. La agenda futura debería priorizar investigaciones que no solo midan desempeño algorítmico, sino que examinen cómo estas herramientas modifican las rutas de derivación, la coordinación familia-escuela, la planificación de apoyos, la inclusión educativa y la participación infantil.

Conclusiones

La revisión sistemática permitió responder al objetivo del estudio al analizar la evidencia científica publicada entre 2020 y mayo de 2026 sobre el uso de herramientas de inteligencia artificial para la detección temprana de alteraciones del neurodesarrollo en niños de 0 a

5 años. Los hallazgos muestran que la IA ha adquirido una presencia creciente en este campo, especialmente en el cribado del trastorno del espectro autista y en la predicción temprana de parálisis cerebral mediante el análisis automatizado de movimientos espontáneos.

Las modalidades con mayor desarrollo fueron el video doméstico, la visión por computador, los registros clínicos electrónicos, la información médica mínima, el seguimiento ocular, el análisis acústico del llanto y los enfoques multimodales. Esta diversidad evidencia que la detección temprana está transitando desde modelos centrados exclusivamente en la observación clínica especializada hacia formas de vigilancia más amplias, apoyadas en datos conductuales, motores, sensoriales y clínicos capturados en contextos cotidianos. Desde una perspectiva educativa, el principal aporte de estas herramientas no radica en reemplazar la valoración profesional, sino en fortalecer los procesos de observación, alerta temprana y derivación oportuna.

En educación inicial, donde el docente observa diariamente el juego, la interacción, la comunicación, la motricidad, la atención y la participación del niño, la IA puede funcionar como un andamiaje técnico que ayude a organizar señales de riesgo y a fundamentar decisiones de acompañamiento. Su utilidad más relevante se ubica, por tanto, en el tamizaje inicial, la priorización de derivaciones y la articulación entre familia, escuela y servicios especializados. No obstante, la revisión también permitió establecer que el rendimiento algorítmico, por sí solo, no justifica la implementación de estas tecnologías en escenarios educativos o clínicos. La sensibilidad, especificidad, exactitud o AUC deben interpretarse junto con otros criterios

igualmente importantes: validación externa, calibración, explicabilidad, desempeño por subgrupos, diversidad de las muestras, calidad de los datos, protección de la privacidad y utilidad real en los flujos de atención.

En el campo educativo, esta exigencia es aún más sensible, porque una alerta mal interpretada puede generar etiquetamiento prematuro, ansiedad familiar o decisiones pedagógicas inadecuadas. Por ello, cualquier herramienta de IA aplicada a la primera infancia debe utilizarse como apoyo a la toma de decisiones, no como mecanismo autónomo de clasificación o diagnóstico. El desafío futuro no será únicamente desarrollar modelos más precisos, sino construir sistemas de detección temprana pedagógicamente pertinentes, clínicamente robustos, éticamente seguros y contextualmente viables. Para ello, se requieren estudios prospectivos, multicéntricos y culturalmente diversos que evalúen no solo el desempeño técnico de los algoritmos, sino también su impacto en la inclusión educativa, la reducción de barreras, la articulación familia-escuela, la oportunidad de las derivaciones y la calidad de los apoyos ofrecidos a la infancia. Solo bajo estas condiciones la inteligencia artificial podrá traducirse en una herramienta real para ampliar oportunidades de desarrollo, fortalecer la respuesta educativa y garantizar que la detección temprana conduzca a acompañamientos más humanos, oportunos e inclusivos.

Referencias Bibliográficas

- Abbasi, H., Mollet, S., Williams, S., Lim, L., Battin, M., Besier, T. F., & McMorland, A. J. C. (2023). Deep-learning for automated markerless tracking of infants' spontaneous movements in consumer mobile device video recordings. *Research on Biomedical Engineering*. <https://doi.org/10.1007/s41870-023-01497-z>
- Antolí, A., Rodríguez, F., Juan, J., Vacas, J., Cuadrado, F., Sánchez, A., Pérez, C., & Gámez, J. (2025). Using explainable machine learning and eye-tracking for diagnosing autism spectrum and developmental language disorders in social attention tasks. *Frontiers in Neuroscience*, 19, Article 1558621. <https://doi.org/10.3389/fnins.2025.1558621>
- Bondi, B., Tassone, V., Buceasa, O., Desrocher, M., & Pepler, D. (2024). A systematic review of neurodevelopmental assessments in infancy and early childhood: Developing a conceptual framework, repository of measures, and clinical recommendations. *Neuropsychology Review*, 35(2), 337–353. <https://doi.org/10.1007/s11065-024-09641-7>
- Chen, J., Engelhard, M., Henao, R., Berchuck, S., Eichner, B., Perrin, E., Sapiro, G., & Dawson, G. (2023). Enhancing early autism prediction based on electronic health records using clinical narratives. *Journal of Biomedical Informatics*, 144, Article 104390. <https://doi.org/10.1016/j.jbi.2023.104390>
- Collins, G., Dhiman, P., Ma, J., Schluskel, M. M., Archer, L., Van Calster, B., et al. (2024). TRIPOD+AI statement: Updated guidance for reporting clinical prediction models that use regression or machine learning methods. *BMJ*, 385, Article e078378. <https://doi.org/10.1136/bmj-2023-078378>
- Cruz, S., Liu, X., Chan, A., Denniston, A., Calvert, M., (2020). Guidelines for clinical trial protocols for interventions involving artificial intelligence: The SPIRIT-AI extension. *BMJ*, 370, Article m3210. <https://doi.org/10.1136/bmj.m3210>
- Draper, C., Yousafzai, A., McCoy, D., Cuartas, J., Obradović, J., Bhopal, S., et al. (2024). The next 1000 days: Building on early investments for the health and development of young children. *The Lancet*, 404(10467), 2094–2116. [https://doi.org/10.1016/S0140-6736\(24\)01389-8](https://doi.org/10.1016/S0140-6736(24)01389-8)
- Groos, D., Adde, L., Aubert, S., Boswell, L., de Regnier, R.-A., Fjørtoft, T., et al. (2022). Development and validation of a deep learning method to predict cerebral palsy from spontaneous movements in infants at high risk. *JAMA Network Open*, 5(7), Article

- e2221325.
<https://doi.org/10.1001/jamanetworkopen.2022.21325>
- Guni, A., Sounderajah, V., Whiting, P., Bossuyt, P., Darzi, A., & Ashrafian, H. (2024). Revised tool for the quality assessment of diagnostic accuracy studies using artificial intelligence (QUADAS-AI): Protocol for a qualitative study. *JMIR Research Protocols*, *13*, Article e58202. <https://doi.org/10.2196/58202>
- Han, W., Yang, X., Li, X., Wang, J., Liu, J., & Pang, W. (2026). Machine learning-based diagnosis of autism spectrum disorder in children and adolescents using eye-tracking data: A systematic review and meta-analysis. *International Journal of Medical Informatics*, *208*, Article 106235. <https://doi.org/10.1016/j.ijmedinf.2025.106235>
- Kim, D, Do, R., Shin, Y., Sim, H., Kim, H., Cho, S., et al. (2025). Automated AI-based identification of autism spectrum disorder from home videos. *npj Digital Medicine*, *8*, Article 607. <https://doi.org/10.1038/s41746-025-01993-5>
- Laguna, A., Pusil, S., Paltrinieri, A. L., & Orlandi, S. (2025). Automatic cry analysis: Deep learning for screening of autism spectrum disorder in early childhood. *Journal of Autism and Developmental Disorders*. <https://doi.org/10.1007/s10803-025-06811-1>
- Leblanc, E., Washington, P., Varma, M., Dunlap, K., Penev, Y., Kline, A., & Wall, D. P. (2020). Feature replacement methods enable reliable home video analysis for machine learning detection of autism. *Scientific Reports*, *10*, Article 21245. <https://doi.org/10.1038/s41598-020-76874-w>
- Liu, X., Cruz, S., Moher, D., Calvert, M, Denniston, A. K. (2020). Reporting guidelines for clinical trial reports for interventions involving artificial intelligence: The CONSORT-AI extension. *BMJ*, *370*, Article m3164. <https://doi.org/10.1136/bmj.m3164>
- Marschik, P, Kwong, A., Silva, N., Olsen, J., Schulte, M., Bölte, S., et al. (2023). Mobile solutions for clinical surveillance and evaluation in infancy: General movement apps. *Journal of Clinical Medicine*, *12*(10), Article 3576. <https://doi.org/10.3390/jcm12103576>
- Moons, K., Damen, J., Kaul, T., Hooft, L., Navarro, C. A., Dhiman, P., et al. (2025). PROBAST+AI: An updated quality, risk of bias, and applicability assessment tool for prediction models using regression or artificial intelligence methods. *BMJ*, *388*, Article e082505. <https://doi.org/10.1136/bmj-2024-082505>
- Page, M, McKenzie, J, Bossuyt, P., Boutron, I., Hoffmann, T, Mulrow, C., et al. (2021). The PRISMA 2020 statement: An updated guideline for reporting systematic reviews. *BMJ*, *372*, Article n71. <https://doi.org/10.1136/bmj.n71>
- Passmore, E., Kwong, A. K. L., Greenstein, S., Olsen, J. E., Eeles, A. L., & Cheong, J. L. Y. (2024). Automated identification of abnormal infant movements from smart phone videos using deep learning. *PLOS Digital Health*, *3*(2), Article e0000432. <https://doi.org/10.1371/journal.pdig.0000432>
- Rajagopalan, S., Zhang, Y., Yahia, A., & Tammimies, K. (2024). Machine learning prediction of autism spectrum disorder from a minimal set of medical and background information. *JAMA Network Open*, *7*(8), Article e2429229. <https://doi.org/10.1001/jamanetworkopen.2024.29229>
- Ramírez, M., Rodríguez, M, Salas, M., & Hernández, E. (2026). Artificial intelligence in diagnosis of pediatric neurodevelopmental disorders: A scoping review. *World Journal of Pediatrics*, *22*, 315–329. <https://doi.org/10.1007/s12519-025-00999-z>
- Sandbank, M., Bottema, K., Crowley, S., Cassidy, M., Dunham, K., & Feldman, J. (2023). Autism intervention meta-analysis of early childhood studies (Project AIM): Updated systematic review and secondary analysis. *BMJ*, *383*, Article e076733. <https://doi.org/10.1136/bmj-2023-076733>

Shahini, A., Kamath, A. P., Sharma, E., Salvi, M., Tan, R.-S., Siuly, S., et al. (2025). A systematic review for artificial intelligence-driven assistive technologies to support children with neurodevelopmental disorders. *Information Fusion*, 124, Article 103441. <https://doi.org/10.1016/j.inffus.2025.103441>

Vasey, B., Nagendran, M., Campbell, B., Clifton, D. A., Collins, G. S., Denaxas, S., et al. (2022). Reporting guideline for the early-

stage clinical evaluation of decision support systems driven by artificial intelligence: DECIDE-AI. *BMJ*, 377. <https://doi.org/10.1136/bmj-2022-070904>



Esta obra está bajo una licencia de Creative Commons Reconocimiento-No Comercial 4.0 Internacional. Copyright © Heidy Tanya Mayorga Sánchez, Karla Gabriela Mora Alvarado, Wilson Oswaldo Sánchez Macías y Diego Esteban Fernández Olivo.

Declaraciones éticas y editoriales del artículo
Contribución de los autores (Taxonomía CRediT) Heidy Tanya Mayorga Sánchez: conceptualización de la investigación, diseño metodológico, desarrollo del proceso investigativo, análisis formal de los datos, redacción del borrador original del manuscrito, revisión crítica del contenido científico y supervisión general del estudio. Karla Gabriela Mora Alvarado: curación y organización de los datos, participación en la recolección de información, validación de los resultados obtenidos y elaboración de representaciones gráficas y visualización de los datos. Wilson Oswaldo Sánchez Macías: provisión de recursos académicos y materiales para el desarrollo del estudio, apoyo en la administración del proyecto investigativo y revisión editorial del manuscrito antes de su publicación. Diego Esteban Fernández Olivo: conceptualización de la investigación, diseño metodológico, desarrollo del proceso investigativo, análisis formal de los datos, redacción del borrador original del manuscrito, revisión crítica del contenido científico y supervisión general del estudio.
Declaración de conflicto de intereses Los autores declaran que no existe conflicto de intereses en relación con la investigación presentada, la autoría del manuscrito ni la publicación del presente artículo.
Declaración de financiamiento La presente investigación no recibió financiamiento específico de agencias públicas, comerciales o de organizaciones sin fines de lucro. En caso de existir financiamiento institucional o externo, este deberá ser declarado explícitamente por los autores en esta sección.
Declaración del editor El editor responsable certifica que el proceso editorial del presente artículo se desarrolló conforme a los principios de integridad científica, transparencia y buenas prácticas editoriales. El manuscrito fue sometido a un proceso de evaluación mediante revisión por pares doble ciego, garantizando la confidencialidad de la identidad de los autores y revisores durante todo el proceso de dictamen académico. Asimismo, el editor declara que el artículo cumple con los criterios científicos, metodológicos y éticos establecidos por la revista.
Declaración de los revisores Los revisores externos que participaron en la evaluación del presente manuscrito declaran haber realizado el proceso de revisión de manera objetiva, independiente y confidencial. Asimismo, manifiestan que no mantienen conflictos de interés con los autores ni con la investigación evaluada, y que sus observaciones y recomendaciones se fundamentan exclusivamente en criterios científicos, metodológicos y académicos.
Declaración ética de la investigación Los autores declaran que la investigación se desarrolló respetando los principios éticos de la investigación científica, garantizando la confidencialidad de los datos y el respeto a los participantes del estudio. En los casos en que la investigación involucre seres humanos, los procedimientos deben ajustarse a los principios éticos establecidos en la Declaración de Helsinki y a las normativas institucionales correspondientes.
Declaración sobre el uso de inteligencia artificial Los autores declaran que el uso de herramientas de inteligencia artificial, en caso de haberse utilizado durante el proceso de investigación o redacción del manuscrito, se realizó únicamente como apoyo técnico para mejorar la claridad del lenguaje o el análisis de información, manteniendo siempre la responsabilidad intelectual sobre el contenido del artículo. Las herramientas de inteligencia artificial no fueron utilizadas como autoras del manuscrito ni sustituyen la responsabilidad académica de los investigadores.
Disponibilidad de datos Los datos que respaldan los resultados de esta investigación estarán disponibles previa solicitud razonable al autor de correspondencia, respetando las normas éticas y de confidencialidad establecidas por la investigación.

