

MODELOS PREDICTIVOS DE OBESIDAD EN JÓVENES, IMPLICACIONES EN SALUD PÚBLICA

PREDICTIVE MODELS OF OBESITY IN YOUTH, IMPLICATIONS IN PUBLIC HEALTH

Carlos Eduardo Sarmiento Herrera

Docente Investigador de la Universidad de los Llanos- Magister en Actividad Física y Deporte, Estudiante de Doctorado en Ciencias y Tecnologías de la Actividad Física y el Deporte, Universidad Manuela Beltrán

<https://orcid.org/0000-0002-8536-8124>

lic.eduardosarmientoherrera@gmail.com;

eduardosarmiento.ch@academia.umb.edu.co

David Leonardo Rodriguez Sarmiento

Docente Investigador, Ingeniero Biomedico Doctor en Ciencias de la Salud, Universidad Manuela Beltrán

<https://orcid.org/0000-0002-9811-940X>

David.RodriguezS@docentes.umb.edu.co

Mauricio Javier Prada Rozo,

Docente Investigador, Magister en Actividad Física Salud y Gestión en el Entrenamiento Deportivo, Estudiante de Doctorado en Ciencias y Tecnologías de la Actividad Física y el Deporte Universidad Manuela Beltrán

<https://orcid.org/0000-0001-9752-0552>

mauricioprada.jr@academia.umb.edu.co

Nestor Javier Murcia Izquierdo

Magister en Pedagogía de la Cultura física, Estudiante de Doctorado en Ciencias y Tecnologías de la Actividad Física y el Deporte, Universidad Manuela Beltrán

<https://orcid.org/0009-0009-0710-173X>

nestorjizquierdo@gmail.com; nestormurcia.ji@academia.umb.edu.co

Mercedes Mendoza Hinestroza

Magister en gestión de las Organizaciones, Estudiante de Doctorado en Ciencias y Tecnologías de la Actividad Física y el Deporte, Universidad Manuela Beltrán

ORCID: <https://orcid.org/0009-0005-1018-7563>

mercedesmendoz1@gmail.com; mercedesmendoza.h@academia.umb.edu.co

Resumen

La obesidad, que es una condición de salud crónica, se ha establecido como uno de los problemas más importantes de salud pública a nivel mundial. Su efecto es extenso, ya que no solo deteriora la calidad de vida de los afectados, sino que también hace que los costos a los que deben enfrentarse los sistemas sanitarios aumenten significativamente. Hoy en día, se considera a la población infantil y

juvenil como uno de los sectores más vulnerables, pues la obesidad tiene el potencial de presentarse desde una edad temprana y causar problemas metabólicos, cardiovasculares y psicosociales durante todo el ciclo vital.

Con el objetivo de crear tácticas eficaces que traten tanto la prevención como la intervención precoz, este reto requiere respuestas completas y sostenidas de las ciencias de la salud y disciplinas relacionadas. La investigación reciente indica que, para tratar la obesidad infantil, es necesario entender en profundidad sus determinantes, que abarcan elementos de tipo socioeconómico, ambiental, conductual y genético.

Este documento presenta un estado del arte actualizado acerca de la obesidad en individuos menores de edad, destacando los progresos que se han hecho en los últimos cinco años en el desarrollo de modelos predictivos. Estos modelos han hecho posible la identificación de factores determinantes relacionados con el riesgo de obesidad, como los hábitos alimentarios, la actividad física, las medidas antropométricas y los entornos familiares y escolares.

Detectar estos predictores de manera anticipada es esencial para dirigir las intervenciones fundamentadas en evidencia que ayudan a mejorar el bienestar de las generaciones venideras. Paralelamente, estas estrategias tienen como objetivo tener un impacto positivo en la disminución de los costos que esta situación supone para la salud pública.

Palabras Clave

Obesidad infantil; Obesidad juvenil; modelo predictivo; revisión sistemática; contexto educativo; tecnología en salud.

Abstract

Obesity, which is a chronic health condition, has established itself as one of the most important public health problems worldwide. Its effect is extensive, as it not only deteriorates the quality of life of those affected, but also causes the costs faced by health systems to increase significantly. Today, children and young people are considered to be one of the most vulnerable sectors, as obesity has the potential to occur from an early age and cause metabolic, cardiovascular and psychosocial problems throughout the life cycle.

In order to create effective tactics that address both prevention and early intervention, this challenge requires comprehensive and sustained responses from the health sciences and related disciplines. Recent research indicates that treating childhood obesity requires an in-depth understanding of its determinants, which encompass socioeconomic, environmental, behavioral and genetic elements.

This paper presents an up-to-date state-of-the-art on obesity in underage individuals, highlighting the progress that has been made over the past five years

in the development of predictive models. These models have made it possible to identify determinants related to obesity risk, such as eating habits, physical activity, anthropometric measurements, and family and school environments.

Detecting these predictors early is essential to targeting evidence-based interventions that help improve well-being for generations to come. At the same time, these strategies aim to have a positive impact on reducing the costs that this situation entails for public health.

Keywords

Childhood obesity; predictive modeling; systematic review; educational context; technology in health.

Introducción

A nivel mundial, la promoción de la salud en niños y adolescentes constituye una prioridad orientada a la adopción de hábitos y estilos de vida saludables. Sin embargo, la obesidad se reconoce hoy como una de las enfermedades más complejas y, al mismo tiempo, como un factor determinante en el desarrollo de enfermedades crónicas no transmisibles (ECNT), lo que la convierte en un desafío creciente para la salud pública (Ortega et al., 2022). En América Latina, se han implementado políticas públicas y estrategias con el propósito de contener su avance, aunque los resultados aún muestran limitaciones (Ríos-Reyna C et al., 2022).

En Colombia, esta condición ha sido identificada como una problemática en aumento. Los datos de la Encuesta Nacional de Situación Nutricional (ENSIN) 2015, analizados por Osorio-Mejía et al. (2022), evidencian un incremento significativo en la masa corporal de los niños de educación primaria, además de un fuerte desequilibrio social que profundiza el riesgo de sobrepeso y obesidad en la infancia. De forma paralela, en Chile la prevalencia de sobrepeso y obesidad en niños de seis años se ha triplicado en las últimas tres décadas, lo que confirma la magnitud de la situación en la región (Miranda et al., 2023).

La literatura reciente identifica factores demográficos y socioeconómicos como determinantes importantes (Gamboa-Gamboa et al., 2021). Así mismo, la evidencia muestra una relación directa entre el tiempo de exposición a pantallas, la condición física y el aumento de la masa corporal (Lehnhard et al., 2023). Otro hallazgo relevante es la asociación entre experiencias de violencia en la infancia y el riesgo de obesidad, lo que pone de manifiesto la influencia de los contextos interpersonales en la salud infantil (Coelho et al., 2021).

La presencia de un alto porcentaje de grasa corporal en los padres no se vincula de manera directa con un mayor riesgo de enfermedad cardíaca en los hijos, mientras que variables como el nivel educativo de la madre o la presencia de hermanos se relacionan significativamente con el aumento del porcentaje de grasa

corporal en los niños. Por otro lado, el uso frecuente de tablets en preescolares se ha asociado con mayores niveles de presión arterial y con una disminución de la fuerza prensil, lo que refleja un impacto temprano en indicadores de salud (Calderón et al., 2024) . De forma complementaria, la evidencia también ha señalado una conexión entre la aptitud física y el rendimiento académico en escolares (Bielik et al., 2025).

En relación con el entorno geográfico, las zonas urbanas presentan un mayor impacto debido a la facilidad de acceso a alimentos ultra procesados, sumada a la cultura del sedentarismo y al uso excesivo de pantallas. Estos factores refuerzan el incremento de la obesidad, incluso en contextos donde existen infraestructuras adecuadas para la práctica de actividad física (Lehnhard et al., 2023).

Analizar la interacción entre estas variables resulta fundamental para comprender la predisposición a la obesidad infantil y juvenil, y permite orientar estrategias de intervención temprana. Este panorama resalta la necesidad de contar con herramientas predictivas que faciliten la identificación oportuna de riesgos, apoyen la toma de decisiones en salud y contribuyan a mitigar una problemática social de creciente impacto.

Metodología

Para el desarrollo del presente documento, la búsqueda fue rigurosa y detallada en cuanto a las referencias bibliográficas desde varias bases de búsqueda de datos digitales de reconocido uso y prestigio en el ámbito científico, académico y de la salud. Se contemplo el uso de palabras claves como obesidad infantil, obesidad juvenil y modelos predictivos. Las bases de datos consultadas fueron: PubMed, SCIENTEDIRECT, LILACS, Google Scholar y SciELO.

En el proceso de revisión, se filtró por: artículos cuya publicación fuera desde el año 2020 hasta la fecha actual, e idioma inglés y español. Se incluyeron artículos que hablaran sobre la obesidad infantil, juvenil y modelos predictivos en obesidad.

Resultados

A partir del análisis de la bibliografía consultada, se evidencia que la obesidad en menores de 18 años es una condición multifactorial, es decir, esta se encuentra bajo la influencia de variables biológicas, conductuales, parentales, y contextuales. Los factores que más se destacan son los siguientes:

Factores individuales: La evidencia científica confirma que los comportamientos personales son determinantes en el riesgo de desarrollar obesidad. Biadgilign et al. (2023) señalan que los hábitos alimenticios inadecuados, la escasa o nula práctica de actividad física y el consumo habitual de bebidas azucaradas se asocian con un incremento del índice de masa corporal (IMC) y con mayor probabilidad de obesidad. De manera complementaria, Shinoda et al. (2023) destacan que el sobrepeso durante el primer año de vida constituye un predictor significativo de

obesidad tanto en la adolescencia como en la adultez. En la misma línea, Wu et al. (2024) evidencian que el tipo de dieta es un factor de riesgo clave en niños de entre 3 y 6 años. Además, Danielsen et al. (2021) subrayan la influencia de los patrones de sueño: la duración insuficiente del descanso, especialmente durante los días de semana, se vincula con una mayor prevalencia de obesidad en la infancia.

Factores familiares: La influencia del entorno familiar también es decisiva. Lim et al. (2023) documentan que variables como el nivel educativo de los padres, los estilos de crianza y aspectos psicológicos, por ejemplo, la autoestima materna guarda una estrecha relación con la obesidad infantil.

Factores socioeconómicos: La posición socioeconómica constituye otro elemento crítico. Hamann et al. (2023) señalan que pertenecer a estratos muy bajos o muy altos aumenta la probabilidad de desarrollar obesidad en la niñez. En el caso de Costa Rica, Gamboa-Gamboa et al. (2021) muestran que la prevalencia de sobrepeso y obesidad en escolares de primaria se encuentra asociada con el tipo de institución educativa (pública, privada o mixta), su localización geográfica (rural o urbana) y el nivel socioeconómico del distrito.

Factores asociados a conductas sedentarias: El uso excesivo y sin control de pantallas (televisión, videojuegos o teléfonos móviles) se relaciona con la reducción de la actividad física y con un incremento en el IMC Radó et al. (2024). De igual forma, Lehnhard et al. (2023), en un estudio longitudinal de tres años con niños y adolescentes, concluyen que pasar más tiempo frente a pantallas, combinado con baja aptitud cardiorrespiratoria, se asocia con una mayor circunferencia de cintura. En contraste, Wang et al. (2023) reportan que la práctica de actividad física en los primeros años de vida ejerce un efecto positivo, contribuyendo a niveles más bajos de masa grasa en la niñez.

Evolución de los modelos predictivos

Los modelos desarrollados en las décadas del 90 y los 2000, se basaron principalmente en análisis de regresión logística (Boakye et al., 2025). Estos enfoques iniciales tenían como objetivo identificar los factores de riesgo tempranos, como el peso al nacer, el índice de masa corporal (IMC) de los padres, el aumento de peso durante el embarazo o la lactancia, con el fin de estimar la probabilidad de que un niño desarrolle obesidad en la infancia o la adolescencia. Si bien estos modelos eran fáciles de interpretar y accesibles para la práctica clínica, su capacidad predictiva estaba limitada por la dificultad de capturar relaciones no lineales y complejas entre variables.

Con la expansión de la historia clínica electrónica de pacientes y el aumento de la capacidad informática, a partir de la década de 2010 se integraron enfoques más sofisticados basados en el aprendizaje automático (ML). Algoritmos como Random Forest, Support Vector Machines o Gradient Boosting se aplicaron a grandes

bases de datos pediátricas, lo que condujo a mejoras significativas en la discriminación de riesgos. Un ejemplo es el estudio de Ziauddeen et al. (2023), publicado en el *International Journal of Obesity*, que entrenó modelos de ML para predecir la obesidad a la edad de 10 a 11 años en una cohorte del Reino Unido. Los autores reportaron áreas bajo la curva (AUC) de hasta 0,85, más altas que con los métodos estadísticos convencionales, lo que confirma el valor agregado de estas técnicas para capturar interacciones complejas entre factores genéticos, conductuales y ambientales.

Paralelamente Welten et al. (2020), desarrollaron un modelo dinámico en Obesidad Pediátrica que integró trayectorias de crecimiento longitudinales de 6 meses a 5 años. Este enfoque fue innovador para identificar a los niños con mayor riesgo de obesidad antes de los 5 años y abrió la puerta a intervenciones preventivas más tempranas. La inclusión de datos longitudinales es uno de los avances más importantes de los últimos tiempos, ya que permite modelar la evolución del crecimiento más allá de una foto estática del IMC.

Recientemente, el desarrollo de modelos basados en deep learning ha alcanzado un nuevo hito. Gupta et al. (2024) en *The Lancet Digital Health* entrenó redes neuronales profundas con millones de registros electrónicos de niños. Estos modelos lograron puntajes de AUC superiores a 0,85 en el grupo de desarrollo, aunque su desempeño en la validación en otros sistemas de salud disminuyó, lo que refleja el desafío continuo de la generalización externa. Este hallazgo es consistente con lo reportado en revisiones sistemáticas como la de Ziauddeen et al. (2022) en *PLOS Global Public Health*, que mostró que la mayoría de los modelos no tienen una validación externa adecuada y tienen una calibración inadecuada, lo que limita su aplicación clínica universal.

Predictores de la obesidad en población menores de 18 años de edad

La evidencia científica más actual muestra que la obesidad sigue siendo un fenómeno complejo en nuestro todos los contextos, determinado por la interacción de los diversos factores de riesgo. Los estudios han identificado explícitamente un conjunto de variables predictoras robustas que se encuentran presentes desde los primeros estados del desarrollo. El análisis desarrollado en el estudio de Gamboa-Gamboa et al. (2021) destaca la importancia de la trayectoria de crecimiento, señalando que las mediciones de las variables antropométricas a temprana edad, como es el índice de masa corporal (IMC) y el z-score del IMC, son marcadores confiables para la identificación temprana del riesgo de obesidad. Estos hallazgos muestran que el monitoreo de patrones de crecimiento acelerado y el cruce ascendente de percentiles de peso y talla, son variables claves para la identificación temprana de individuos potencialmente en riesgo de padecer obesidad.

Adicionalmente, se ha evidenciado que los factores familiares y perinatales tienen una influencia significativa en la posibilidad de padecer obesidad. El estudio

desarrollado por Welten et al. (2020) muestra que el IMC materno y paterno, así como el aumento de peso gestacional y el peso al nacer del neonato, son predictores confiables e importantes. Mientras que la duración de la lactancia materna, por su parte, se ha asociado con un efecto protector.

El comportamiento y la dinámica dentro del núcleo familiar también presentan un papel importante en la modulación del riesgo de padecer obesidad. Diversos análisis han determinado la prevalencia de la obesidad a partir de la influencia de variables como los patrones dietéticos, los niveles de actividad física, el tiempo de exposición a las pantallas y la calidad del sueño. Un estudio realizado en Corea y publicado en Scientific Reports por Lim et al. (2023) puso de manifiesto que las percepciones maternas sobre el peso de sus hijos y los hábitos de sueño infantiles son predictores significativos del desarrollo de obesidad a los 10 años de edad, lo que amplía la comprensión de los factores conductuales y psicológicos en la génesis de esta condición.

Finalmente, en el contexto socioeconómico y ambiental emergen como un determinante fundamental de la obesidad infantil, investigaciones como la de Gamboa-Gamboa et al. (2021) han evidenciado una correlación entre el menor nivel educativo de los padres, los ingresos familiares bajos, la urbanización y la limitada disponibilidad de espacios seguros para la realización de actividad física, con una mayor prevalencia para padecer obesidad. Estas desigualdades socioeconómicas, que se reflejan en el acceso menos favorable a los entornos saludables y patrones de alimentación, demuestran que la obesidad no se restringe exclusivamente a factores individuales, sino que está profundamente conectada a las condiciones sociales y ambientales en las que los niños y adolescentes se desarrollan.

Tabla 1
Principales predictores de la obesidad según la literatura científica

Categoría	Predictores principales	Fuente
Antropometría	- IMC y z-IMC en estadios tempranos - Trayectorias de crecimiento - Cruce de percentiles de peso y talla	Gamboa-Gamboa et al., 2021
Factores familiares y perinatales	- IMC de la madre y el padre - Aumento de peso durante el embarazo - Peso al nacer - Duración de la lactancia materna	Welten et al., 2020
Comportamiento	- Patrones dietéticos - Nivel de actividad física - Tiempo frente a pantallas - Calidad del sueño - Percepciones maternas sobre el	Lim et al., 2023

		peso y los hábitos de sueño de los niños (predictores significativos a los 10 años)	
Factores socioeconómicos y ambientales		<ul style="list-style-type: none">- Nivel de educación de los padres- Ingresos familiares- Urbanización- Disponibilidad de espacios para actividad física	Gamboa-Gamboa et al., 2021

Fuente: Elaboración propia

Validación y rendimiento del modelo

En términos de rendimiento, la mayoría de los modelos predictivos alcanzan valores de AUC entre 0,70 y 0,90 en la validación interna. Sin embargo, cuando se aplica en cohortes externas, los valores caen a rangos de 0,60 a 0,75, lo que refleja la necesidad de recalibración. Esta brecha entre el desempeño interno y externo ha sido ampliamente discutida en la literatura. Estudios recientes confirman esta tendencia: Siontis et al. (2015) reportaron que la mayoría de los modelos reducen su discriminación cuando se evalúan en poblaciones externas, Collins et al. (2014) enfatiza que la recalibración es esencial para evitar la pérdida de validez y asegurar una adecuada aplicabilidad clínica en escenarios heterogéneos.

Contexto latinoamericano

En el contexto latinoamericano, los modelos predictivos de obesidad en menores de 18 años han evolucionado gracias a la aplicación de métodos estadísticos y de aprendizaje automático que integran variables accesibles. En Chile, Solorzano et al. (2023) desarrollaron diversos modelos diagnósticos para identificar el riesgo de síndrome metabólico en escolares (6-11 años) utilizando tanto indicadores antropométricos como biomarcadores lipídicos, y encontraron que las variables lipídicas (HDL-c y triglicéridos) proporcionaron mayor capacidad predictiva con tasas de validez superiores al 80%.

Por otro lado, a escala global, Colmenarejo (2020) ha publicado una reciente revisión de los modelos de aprendizaje automático utilizados para predecir la obesidad infantil y adolescente, destacando el potencial de incluir múltiples variables (como antecedentes familiares, patrones de comportamiento y mediciones tempranas) para mejorar la precisión predictiva.

También Torres-Martos et al. (2023) ilustraron el uso de datos "ómicos" (genómicos o metabolómicos) como predictores de obesidad infantil y enfatizaron la importancia del preprocesamiento informático en la creación de modelos robustos.

Estos aportes latinoamericanos subrayan la importancia de tener en cuenta las especificidades contextuales y culturales en la creación de modelos, así como la

urgencia de cohortes multicéntricas regionales que permitan validar y transportar modelos desarrollados en otras latitudes.

Desafíos y brechas

A pesar de los avances, siguen existiendo importantes desafíos:

Generalización limitada: Los modelos desarrollados en Europa y Asia no siempre son aplicables a América Latina debido a diferencias genéticas, socioeconómicas y del sistema de salud.

Calibración inadecuada: La mayoría de los estudios enfatizan la discriminación (AUC), pero pocos informan la calibración o realizan una validación externa.

Sesgo y equidad: Es necesario evaluar cómo funcionan los modelos en subgrupos de género, edad y ascendencia para evitar una recurrencia de las desigualdades en salud.

Implementación clínica: Son pocos los estudios que evalúan el impacto real del uso de modelos predictivos en la reducción de la obesidad a través de intervenciones guiadas en atención primaria o en el ámbito escolar.

Prioridades de investigación del futuro

Para el futuro, las prioridades de investigación en el sector de la salud y la obesidad en América Latina tienen que enfocarse en consolidar pruebas científicas y crear soluciones nuevas.

En esta línea, se propone la necesidad de crear cohortes regionales que incluyan información sobre antropometría, salud clínica, comportamiento y medioambiente. Esta táctica posibilitaría tener acceso a datos sólidos y contextualizados, lo cual es fundamental para entender la complejidad de los factores que determinan la salud en el área, que se distingue por su diversidad cultural, geográfica y socioeconómica.

Además, es esencial avanzar en la fusión de fuentes de datos multimodales. La utilización de grabaciones escolares, aplicaciones móviles y aparatos portátiles supone una oportunidad para recabar datos en tiempo real y de forma constante, lo cual facilitaría un estudio más exhaustivo y dinámico de los elementos vinculados con la salud la prevención de la obesidad de niños y jóvenes.

La articulación de estas fuentes permitiría detectar patrones de conducta y crear intervenciones más adaptadas a las condiciones locales. El desarrollo de modelos de inteligencia artificial que sean explicables es otra línea prioritaria de investigación. Estos modelos tienen como objetivo no solo mejorar la capacidad de predicción, sino también proporcionar confianza y transparencia a los expertos en la predicción de la obesidad, que necesitan entender cómo funcionan los procesos detrás de las decisiones algorítmicas. Por lo tanto, con el fin de promover su

utilización y empleo responsable en la práctica de los contextos educativos, deportivos y familiares, la aplicabilidad de la inteligencia artificial se vuelve un elemento fundamental.

Así mismo, se subraya la relevancia de analizar el impacto que tienen los modelos predictivos en la salud pública por medio de ensayos clínicos pragmáticos. Estas evaluaciones posibilitarían calcular la eficacia y utilidad de las herramientas diseñadas en contextos reales, garantizando de esta manera que las soluciones ofrecidas aborden las necesidades y limitaciones del sistema de salud.

Finalmente, se enfatiza la importancia de incorporar la variable de la genética de manera responsable, teniendo en cuenta la gran diversidad étnica y cultural que existe en la población latinoamericana. Considerar estas particularidades en los estudios genómicos es esencial para evitar sesgos y asegurar que los resultados obtenidos contribuyan a la equidad en salud. Esta perspectiva permitirá avanzar hacia un conocimiento más inclusivo y pertinente, orientado a mejorar la prevención y el tratamiento de enfermedades en la región.

Tabla 2
Prioridades de investigación futura en obesidad

Área prioritaria	Descripción
Cohortes regionales	Construir cohortes latinoamericanas que integren datos antropométricos, clínicos, conductuales y ambientales.
Datos multimodales	Integrar fuentes de datos diversas, incluidas grabaciones escolares, aplicaciones móviles y dispositivos portátiles.
Inteligencia artificial explicable	Desarrollar modelos de IA explicables que aumenten la confianza de los profesionales sanitarios.
Impacto en salud pública	Evaluar el efecto de los modelos predictivos en la salud pública mediante ensayos clínicos pragmáticos.
Genética y diversidad	Integrar la genética de manera responsable, considerando la diversidad étnica y cultural de la población latinoamericana.

Fuente: Elaboración propia

Conclusiones

La revisión del estado del arte confirma que la obesidad en menores de 18 años constituye una condición compleja y multifactorial, influenciada por factores biológicos, conductuales, familiares y contextuales. Entre los elementos más destacados se encuentran los hábitos alimenticios inadecuados, el sedentarismo, el consumo excesivo de bebidas azucaradas y los patrones de sueño insuficientes, los cuales se asocian de manera consistente con el incremento del índice de masa corporal (IMC) y con un mayor riesgo de obesidad. De igual forma, la evidencia muestra que el sobrepeso en las etapas tempranas, particularmente durante el primer año de vida, se configura como un predictor relevante de obesidad en la

adolescencia y en la adultez. En el plano familiar, variables como el nivel educativo de los padres, sus estilos de crianza y factores psicológicos, junto con condiciones socioeconómicas extremas, se relacionan con la prevalencia de esta condición.

En relación con la detección y el monitoreo, el IMC continúa siendo el indicador de referencia, aunque suele complementarse con otras medidas antropométricas, como la circunferencia de la cintura y la bioimpedancia eléctrica, para obtener una estimación más precisa de la composición corporal. En este escenario, las tecnologías emergentes, entre ellas la inteligencia artificial y los dispositivos de censados, están transformando el estudio de la obesidad infantil al facilitar el análisis de grandes volúmenes de datos y el diseño de modelos predictivos con mayor exactitud. Así mismo, las aplicaciones educativas y las intervenciones gamificadas representan estrategias innovadoras para fomentar la adquisición de hábitos saludables en niños y adolescentes.

No obstante, aún existen vacíos de conocimiento, especialmente en torno a la relación causal entre los factores de riesgo y la obesidad, así como en el diseño de intervenciones personalizadas que contemplen las diferencias individuales y contextuales. También se reconoce la necesidad de estudios longitudinales que permitan valorar el impacto de la obesidad infantil en el desarrollo cognitivo y en la efectividad de las estrategias preventivas a lo largo del tiempo. En síntesis, enfrentar la obesidad en la niñez y la adolescencia exige un enfoque integral que articule la identificación temprana de factores de riesgo, el aprovechamiento de tecnologías avanzadas y la implementación de intervenciones multidisciplinarias ajustadas a las particularidades de cada población. Las investigaciones futuras deberán orientarse a cerrar las brechas actuales de conocimiento y a aprovechar el potencial de las herramientas tecnológicas para diseñar estrategias sostenibles y efectivas en la prevención y el manejo de este problema de salud pública.

Referencias

- Biadgilign, S., Mgutshini, T., Gebremichael, B., Berhanu, L., Cook, C., Deribew, A., Gebre, B., & Memiah, P. (2023). Association between dietary Intake, eating behavior, and childhood obesity among children and adolescents in Ethiopia. *BMJ Nutrition, Prevention and Health*, 6(2), 203–211. <https://doi.org/10.1136/bmjnp-2021-000415>
- Bielik, V., Nosál, V., Nechalová, L., Špánik, M., Žilková, K., & Grendar, M. (2025). The prediction model of academic achievement based on cardiorespiratory fitness and BMI status for ninth-grade students. *BMC Pediatrics*, 25(1). <https://doi.org/10.1186/s12887-024-05353-2>
- Boakye, N. F., O'Toole, C. C., Jalali, A., & Hannigan, A. (2025). Comparing logistic regression and machine learning for obesity risk prediction: A systematic review

- and meta-analysis. In *International Journal of Medical Informatics* (Vol. 199). Elsevier Ireland Ltd. <https://doi.org/10.1016/j.ijmedinf.2025.105887>
- Calderón, I. O., Pizarro, Y. Á., Oyarzún, M. L., Arévalo, L. P., Armenta, J. G. L., & Álvarez, C. (2024). Association of cardiometabolic health of preschoolers and their parents with family sociodemographic characteristics. *Archivos Latinoamericanos de Nutricion*, 74(2), 83–96. <https://doi.org/10.37527/2024.74.2.002>
- Coelho, L. S. V. A., Soares, S. G., Carvalho, G. D., Oliveira, V. J., Belo, V. S., & Romano, M. C. C. (2021). Association between violence in childhood and increase in the body mass index among adolescents. *Texto e Contexto Enfermagem*, 30. <https://doi.org/10.1590/1980-265X-TCE-2020-0201>
- Collins, G. S., De Groot, J. A., Dutton, S., Omar, O., Shanyinde, M., Tajar, A., Voysey, M., Wharton, R., Yu, L. M., Moons, K. G., & Altman, D. G. (2014). External validation of multivariable prediction models: A systematic review of methodological conduct and reporting. In *BMC Medical Research Methodology* (Vol. 14, Issue 1). BioMed Central Ltd. <https://doi.org/10.1186/1471-2288-14-40>
- Colmenarejo, G. (2020). Machine learning models to predict childhood and adolescent obesity: A review. In *Nutrients* (Vol. 12, Issue 8, pp. 1–31). MDPI AG. <https://doi.org/10.3390/nu12082466>
- Danielsen, Y. S., Pallesen, S., Sivertsen, B., Stormark, K. M., & Hysing, M. (2021). Weekday time in bed and obesity risk in adolescence. *Obesity Science and Practice*, 7(1), 45–52. <https://doi.org/10.1002/osp4.455>
- Gamboa-Gamboa, T., Fantin, R., Cordoba, J., Caravaca, I., & Gómez-Duarte, I. (2021). Relationship between childhood obesity and socio-economic status among primary school children in Costa Rica. In *Public Health Nutrition* (Vol. 24, Issue 12, pp. 3825–3833). Cambridge University Press. <https://doi.org/10.1017/S1368980021002032>
- Gupta, M., Eckrich, D., Bunnell, H. T., Phan, T. L. T., & Beheshti, R. (2024). Reliable prediction of childhood obesity using only routinely collected EHRs may be possible. *Obesity Pillars*, 12. <https://doi.org/10.1016/j.obpill.2024.100128>
- Hamann, S. A., Thorup, L., Patsche, C. B., Hohwü, L., Hjortdal, V. E., Gyawali, B., Neupane, D., & Kallestrup, P. (2023). Association between nutritional status and socio-economic status among school children aged 9–17 years in a semi-urban area of Nepal. *Journal of Health, Population and Nutrition*, 42(1). <https://doi.org/10.1186/s41043-023-00392-4>
- Lehnhard, A. R., Sehn, A. P., de Castro Silveira, J. F., Burns, R. D., Reuter, C. P., & Franke, S. I. R. (2023). Longitudinal relationship between screen time, cardiorespiratory fitness, and waist circumference of children and adolescents: a 3-

- year cohort study. *BMC Pediatrics*, 23(1). <https://doi.org/10.1186/s12887-023-04378-3>
- Lim, H., Lee, H., & Kim, J. (2023). A prediction model for childhood obesity risk using the machine learning method: a panel study on Korean children. *Scientific Reports*, 13(1). <https://doi.org/10.1038/s41598-023-37171-4>
- Miranda, S. L., Serrano, M. D. M., & de Espinosa, M. G. M. (2023). Overweight and obesity in schoolchildren in the Magallanes and Chilean Antarctica Region, Chile, (2009 - 2019), and comparison of two methodologies for diagnosis. *Archivos Latinoamericanos de Nutricion*, 73(3), 180–190. <https://doi.org/10.37527/2023.73.3.002>
- Ortega, R. M., Ortega, A. I. J., Martinez Garcia, R. M., Aguilar-Aguilar, E., & Estevan, C. L. (2022). Childhood obesity as a health priority. Guidelines for improving weight control. *Nutricion Hospitalaria*, 39(Ext3), 35–38. <https://doi.org/10.20960/nh.04308>
- Osorio-Mejía, A. M., Martínez-Arbeláez, S., & Ramírez-Girón, N. (2022). Socioeconomic determinants of excess weight in Colombian preschool and school children. National Survey of Nutritional Situation 2015. Introduction. *Archivos Latinoamericanos de Nutricion*, 72(4), 243–252. <https://doi.org/10.37527/2022.72.4.002>
- Radó, S. I., Molnár, M., Széll, R., Szöllösi, G. J., Törő, V., Shehab, B., Manios, Y., Anastasiou, C., Iotova, V., Tsochev, K., Chakarova, N., Giménez-Legarre, N., Miguel Berges, M. L., Schwarz, P. E. H., Rurik, I., & Sárváry, A. (2024). Association between Screen Time and Sociodemographic Factors, Physical Activity, and BMI among Children in Six European Countries (Feel4Diabetes): A Cross-Sectional Study. *Children*, 11(4). <https://doi.org/10.3390/children11040458>
- Ríos-Reyna C, Díaz-Ramírez G, Castillo- Ruíz O, Pardo-Buitimea NY, & Alemán-Castillo SE. (2022). políticas y estrategias para combatir la obesidad en latinoamérica. *Rev Med Inst Mex*, 60, 666–674. <https://pmc.ncbi.nlm.nih.gov/articles/PMC10395955/>
- Shinoda, G., Nagaoka, Y., Ueno, F., Kurokawa, N., Takahashi, I., Onuma, T., Noda, A., Murakami, K., Ishikuro, M., Obara, T., Metoki, H., Sugawara, J., & Kuriyama, S. (2023). Association between being Overweight in Young Childhood and during School Age and Puberty. *Children*, 10(5). <https://doi.org/10.3390/children10050909>
- Siontis, G. C. M., Tzoulaki, I., Castaldi, P. J., & Ioannidis, J. P. A. (2015). External validation of new risk prediction models is infrequent and reveals worse prognostic discrimination. *Journal of Clinical Epidemiology*, 68(1), 25–34. <https://doi.org/10.1016/j.jclinepi.2014.09.007>
- Solorzano, M., Granfeldt, G., Ulloa, N., Molina-Recio, G., Molina-Luque, R., Aguayo, C., Petermann-Rocha, F., & Martorell, M. (2023). Comparison of Diagnostic Models to

Estimate the Risk of Metabolic Syndrome in a Chilean Pediatric Population: A Cross-Sectional Study. *Metabolites*, 13(2).
<https://doi.org/10.3390/metabo13020293>

Torres-Martos, Á., Bustos-Aibar, M., Ramírez-Mena, A., Cámara-Sánchez, S., Anguita-Ruiz, A., Alcalá, R., Aguilera, C. M., & Alcalá-Fdez, J. (2023). Omics Data Preprocessing for Machine Learning: A Case Study in Childhood Obesity. *Genes*, 14(2). <https://doi.org/10.3390/genes14020248>

Wang, Q., Guo, H., Chen, S., Ma, J., & Kim, H. (2023). The Association of Body Mass Index and Fat Mass with Health-Related Physical Fitness among Chinese Schoolchildren: A Study Using a Predictive Model. *International Journal of Environmental Research and Public Health*, 20(1).
<https://doi.org/10.3390/ijerph20010355>

Welten, M., Wijga, A. H., Hamoen, M., Gehring, U., Koppelman, G. H., Twisk, J. W. R., Raat, H., Heymans, M. W., & de Kroon, M. L. A. (2020). Dynamic prediction model to identify young children at high risk of future overweight: Development and internal validation in a cohort study. *Pediatric Obesity*, 15(9).
<https://doi.org/10.1111/ijpo.12647>

Wu, W. J., Chen, P. H., Huang, Z. N., Lei, X. L., Wang, C., Zhang, C. H., Wang, P., Huang, C. C., Luo, Q., & Fan, L. C. (2024). Prevalence of overweight and obesity among preschool children in Hainan: a cross-sectional study in China's largest free-trade zone. *Frontiers in Pediatrics*, 12.
<https://doi.org/10.3389/fped.2024.1476231>

Ziauddeen, N., Roderick, P. J., Santorelli, G., & Alwan, N. A. (2023). Prediction of childhood overweight and obesity at age 10–11: findings from the Studying Lifecourse Obesity PrEdictors and the Born in Bradford cohorts. *International Journal of Obesity*, 47(11), 1065–1073. <https://doi.org/10.1038/s41366-023-01356-8>

Ziauddeen, N., Roderick, P. J., Santorelli, G., Wright, J., & Alwan, N. A. (2022). Childhood overweight and obesity at the start of primary school: External validation of pregnancy and early-life prediction models. *PLOS Global Public Health*, 2(6).
<https://doi.org/10.1371/journal.pgph.0000258>