

Puntos de vista

Modelos predictivos para la obesidad: inteligencia artificial, validez, sesgos y equidad en Cuba

Predictive Models for Obesity: Artificial Intelligence, Validity, Bases and Equity in Cuba

Belkis Mercedes Vicente Sánchez¹  Elodia María Rivas Alpizar¹  Annia Quintana Marrero¹ 

¹ Hospital General Universitario Dr. Gustavo Aldereguía Lima, Cienfuegos, Cienfuegos, Cuba

Cómo citar este artículo:

Vicente-Sánchez B, Rivas-Alpizar E, Quintana-Marrero A. Modelos predictivos para la obesidad: inteligencia artificial, validez, sesgos y equidad en Cuba. **Revista Finlay** [revista en Internet]. 2026 [citado 2026 Nov 1]; 16(0):[aprox. 0 p.]. Disponible en: <https://revfinlay.sld.cu/index.php/finlay/article/view/1710>

Resumen

Los modelos predictivos ofrecen posibilidades para identificar personas en riesgo de obesidad y orientar decisiones preventivas, pero su utilidad no depende exclusivamente de la complejidad tecnológica. Este punto de vista examina críticamente los requisitos de validez, los sesgos y los desafíos de equidad asociados con su aplicación en Cuba. Se diferencia la medición antropométrica de la clasificación y la predicción y se cuestiona la superioridad automática de la inteligencia artificial frente a los métodos estadísticos convencionales. Se destacan la discriminación, la calibración, la validación externa y la evaluación del desempeño en subgrupos como condiciones para valorar los modelos. Asimismo, se consideran los principios de TRIPOD+AI y PROBAST+AI para orientar la comunicación transparente y la evaluación crítica de la evidencia. Para la Atención Primaria cubana se propone una agenda basada en desenlaces definidos, datos fiables, comparación de métodos y evaluación independiente. La implementación debe proteger la información y evitar que el acceso a dispositivos digitales condicione los beneficios. Se sostiene que una mejora predictiva no demuestra por sí misma un beneficio sanitario: su valor requiere vincular la estimación del riesgo con intervenciones accesibles y efectivas, sin desplazar el juicio clínico ni reproducir desigualdades.

Palabras clave: obesidad, inteligencia artificial, aprendizaje automático, modelos de atención de salud, equidad en salud

Abstract

Predictive models offer possibilities for identifying individuals at risk of obesity and guiding preventive decisions, but their usefulness does not depend solely on technological complexity. This perspective critically examines the validity requirements, biases, and equity challenges associated with their application in Cuba. It differentiates between anthropometric measurement, classification, and prediction, and questions the automatic superiority of artificial intelligence over conventional statistical methods. Discrimination, calibration, external validation, and performance evaluation in subgroups are highlighted as conditions for assessing models. Furthermore, the principles of TRIPOD+AI and PROBAST+AI are considered to guide transparent communication and critical appraisal of the evidence. For Cuban primary care, an agenda based on defined outcomes, reliable data, methodological comparison, and independent evaluation is proposed. Implementation must protect information and prevent access to digital devices from conditioning the benefits. It is argued that predictive improvement does not, in itself, demonstrate a health benefit: its value requires linking risk estimation with accessible and effective interventions, without displacing clinical judgment or reproducing inequalities.

Key words: obesity, artificial intelligence, machine learning, healthcare models, health equity

Recibido: 2026-09-04 12:58:35

Aprobado: 2026-09-10 10:42:25

Correspondencia: Belkis Mercedes Vicente Sánchez. Hospital General Universitario Dr. Gustavo Aldereguía Lima. Cienfuegos. belkisvi67@gmail.com

INTRODUCCIÓN

La obesidad en adultos constituye un desafío para la Salud Pública que requiere de estrategias de prevención y atención integrales. En América Latina y el Caribe, su abordaje debe considerar la interacción entre condiciones biológicas, hábitos de vida y circunstancias sociales, sin reducir el exceso de peso a una responsabilidad exclusivamente individual. La literatura sobre obesidad, sobrepeso y diabetes mellitus tipo 2 muestra la relevancia de estudiar conjuntamente estas condiciones y sus implicaciones sanitarias.⁽¹⁾

En Cuba, la prevención de la obesidad se inscribe en las prioridades de control de las enfermedades no transmisibles y sus factores de riesgo. Los estudios locales aportan información sobre contextos específicos: en una población rural de Yaguajay, Sancti Spíritus, donde se han examinado la alimentación y el estado nutricional. Estos antecedentes justifican considerar las particularidades territoriales al proponer herramientas para identificar riesgos y orientar acciones preventivas, sin extrapolar resultados de una comunidad a toda la población cubana.^(2,3)

La evaluación antropométrica constituye un punto de partida accesible. El índice de masa corporal (IMC) permite clasificar el estado nutricional, pero no proporciona por sí solo una caracterización completa de la composición corporal ni del riesgo individual. Su interpretación debe complementarse con otras medidas y con la evaluación clínica. Reconocer estas limitaciones no implica abandonar la antropometría, sino precisar su función dentro de un abordaje más amplio.^(4,5)

La inteligencia artificial y el aprendizaje automático ofrecen posibilidades para analizar información relacionada con la obesidad y explorar herramientas de apoyo a la atención. Estas aplicaciones requieren una valoración crítica de sus alcances: disponer de más datos o utilizar algoritmos complejos no debe presentarse como prueba suficiente de mayor utilidad. Las aportaciones tecnológicas deben examinarse en relación con la pregunta que se pretende responder y el escenario donde se utilizarán.⁽⁶⁾

Desde esta perspectiva, las autoras consideran necesario distinguir entre medir el estado antropométrico, clasificar una condición presente y estimar un desenlace futuro. También debe separarse la capacidad de generar una

predicción de la posibilidad de convertirla en una decisión preventiva efectiva. En el desarrollo se examinan estas distinciones, los requisitos de evaluación de los modelos y las condiciones para una aplicación responsable.

Este punto de vista sostiene que el valor de los modelos predictivos para la obesidad en Cuba debe juzgarse por su validez, factibilidad y contribución a una atención equitativa, no por su complejidad tecnológica. Se discuten sus oportunidades y limitaciones y se plantea una agenda de evaluación en Atención Primaria basada en datos pertinentes, protección de la información y participación comunitaria.

DESARROLLO

De la medición antropométrica a la predicción

La discusión sobre modelos predictivos requiere distinguir entre medir, clasificar y predecir. El índice de masa corporal y la circunferencia de la cintura aportan información sobre el estado antropométrico, pero no constituyen por sí solos modelos multivariados. Un modelo combina predictores para estimar un desenlace presente o futuro, por ello, debe especificar población, uso previsto y, cuando corresponda, horizonte temporal. Clasificar obesidad actual no equivale a anticipar su aparición.^(4,5,7)

La inteligencia artificial puede ampliar las opciones analíticas, pero no debe plantearse como sustitución inevitable de la regresión. La selección del método debe responder a la pregunta clínica, los datos disponibles y el desempeño en la población destinataria. Una revisión sistemática general no encontró evidencia de superioridad del aprendizaje automático sobre la regresión logística en las comparaciones de bajo riesgo de sesgo. Esta conclusión no excluye ventajas en aplicaciones particulares, pero impide asumirlas sin evaluación.^(6,8)

La evidencia específica sobre obesidad refuerza esta cautela. Boakye y cols. incluyeron 28 estudios, de los cuales el 75 % presentó alto riesgo de sesgo, ninguno evaluó calibración. En el metaanálisis de 14 estudios, las áreas bajo la curva agrupadas fueron 0,75 para regresión logística y 0,76 para aprendizaje automático, sin diferencia significativa. Este resultado no demuestra equivalencia entre los métodos y debe interpretarse al considerar las limitaciones de los estudios incluidos. Por tanto, la

complejidad tecnológica no constituye una prueba de mayor utilidad.⁽⁹⁾

Requisitos de validez y utilidad clínica

El desempeño debe examinarse más allá de la exactitud global. La discriminación indica cuánto distingue el modelo entre personas con y sin el desenlace, la calibración expresa la concordancia entre probabilidades estimadas y resultados observados. Una discriminación aceptable puede coexistir con estimaciones de riesgo mal calibradas, lo que limita su utilización para decisiones individuales.^(7,10)

La validación interna permite estimar el optimismo asociado al desarrollo, mientras que la externa evalúa el desempeño en participantes independientes. Deben justificarse el tamaño muestral, el manejo de datos faltantes y los procedimientos para evitar sobreajuste y fuga de información. La selección de predictores y el ajuste del algoritmo no deben utilizar información del conjunto reservado para evaluación.^(7,10)

El aprendizaje automático comprende métodos que aprenden patrones a partir de datos para generar clasificaciones o predicciones. Su evaluación debe considerar la interpretabilidad: profesionales y usuarios necesitan comprender el uso previsto y las limitaciones de las estimaciones. Las explicaciones del algoritmo no sustituyen la validación ni demuestran relaciones causales. TRIPOD+AI orienta la comunicación transparente de los estudios, mientras que PROBAST+AI permite examinar calidad, riesgo de sesgo y aplicabilidad. Ambos abarcan regresión y métodos de inteligencia artificial y se emplean aquí como marcos de lectura crítica, no como certificación de una evaluación formal realizada por las autoras.^(7,10)

La predicción tampoco equivale a intervención. Recopilar datos, estimar riesgos, decidir e intervenir son etapas diferentes. Debe explicitarse, qué acción apoyará el modelo, para quién y con qué recursos. Su utilidad clínica exige valorar si las decisiones asistidas ofrecen beneficios frente a las alternativas disponibles, se deben considerar errores de clasificación, recursos y posibles daños. Una mejora del desempeño predictivo no demuestra por sí sola mejores resultados en salud, estos requieren evaluación durante la implementación.^(7,10)

Sesgos, aplicabilidad y equidad

Aplicar un modelo fuera de su población de desarrollo exige evaluar su aplicabilidad, no presumirla. Las diferencias entre fuentes de datos, medición de predictores, población y desenlace pueden comprometer su aplicabilidad. Además del desempeño global, deben examinarse calibración, discriminación y consecuencias de uso en subgrupos pertinentes, como sexo, edad, territorio y condiciones socioeconómicas.^(7,10)

La equidad requiere evitar que el modelo o su implementación desfavorezcan injustificadamente a determinados grupos. La propuesta de las autoras es que una herramienta para Atención Primaria no dependa de manera obligada de dispositivos personales o conectividad domiciliaria. También debería contemplar protección de datos, supervisión clínica y participación de pacientes y comunidades. Estas condiciones deben evaluarse desde el diseño, no añadirse después de desarrollar el algoritmo.^(7,10)

La transferencia de modelos debe examinarse según la representatividad de los datos, su desempeño local y las consecuencias de su uso. La procedencia de la tecnología no determina por sí sola su adecuación: esta debe demostrarse en la población y el contexto en el que será aplicado. Su adopción requiere valorar quiénes podrían beneficiarse, quiénes podrían quedar excluidos y qué medidas permitirían reducir esas diferencias.^(7,10)

Una agenda factible para Cuba

En coherencia con las prioridades cubanas de prevención de enfermedades no transmisibles y las particularidades territoriales, se propone estimar obesidad incidente en adultos sin obesidad al inicio, atendidos en Atención Primaria. La población debería incluir centros urbanos y rurales y documentar las pérdidas de seguimiento. El horizonte temporal se definiría según la utilidad preventiva y la factibilidad del seguimiento. Esta propuesta constituye una agenda de investigación, no un modelo ya desarrollado.^(2,3)

Los predictores iniciales podrían incluir: edad, sexo, antropometría, trayectoria ponderal y variables clínicas, conductuales y sociales disponibles antes del desenlace. Su incorporación dependería de medición fiable, disponibilidad y justificación, no solo de asociaciones publicadas. Debería compararse una regresión parsimoniosa con alternativas de aprendizaje automático en la

misma población y bajo procedimientos equivalentes y evitar información que revele anticipadamente el desenlace.^(7,9,10)

El desarrollo exigiría evaluación interna y externa en otros centros o periodos, con estimaciones de incertidumbre y análisis por subgrupos. El riesgo estimado podría apoyar la intensificación del seguimiento preventivo o la derivación a intervenciones disponibles, sin restringir la atención básica de quienes presenten menor riesgo. Antes de ampliar su uso, deberían definirse responsabilidades y monitorizarse desempeño y cobertura, así como, evaluar su impacto frente a la práctica habitual y la distribución de beneficios entre grupos.^(7,10)

CONCLUSIONES

La utilidad de los modelos predictivos para la obesidad debe juzgarse por su validez y contribución a decisiones preventivas, no por su complejidad tecnológica. Su aplicación requiere evaluación del desempeño, validación externa y análisis por subgrupos, sin presumir la superioridad de la inteligencia artificial. En Cuba, su incorporación a la Atención Primaria debe priorizar datos fiables, factibilidad operativa, protección de la información y acceso equitativo. La innovación tendrá valor cuando las predicciones orienten intervenciones accesibles y efectivas, sin desplazar el juicio clínico ni reproducir desigualdades.

Conflicto de intereses:

Las autoras declaran la no existencia de conflictos de intereses relacionados con el estudio.

Los roles de autoría:

1. Conceptualización: Belkis Mercedes Vicente Sánchez.
2. Investigación (búsqueda, selección y evaluación crítica de la literatura): Belkis Mercedes Vicente Sánchez, Elodia María Rivas Alpízar y Annia Quintana Marrero.
3. Redacción del borrador original: Belkis Mercedes Vicente Sánchez.
4. Redacción, revisión y edición: Belkis Mercedes Vicente Sánchez, Elodia María

- Rivas Alpízar, Annia Quintana Marrero.
5. Todas las autoras revisaron y aprobaron la versión final del manuscrito y asumen responsabilidad por su contenido.
6. Financiación: el trabajo no recibió financiación específica.

REFERENCIAS BIBLIOGRÁFICAS

1. Alcocer S, Marcillo AG, Macías LN, Medranda AF. Prevalencia de diabetes mellitus tipo 2, sobrepeso y obesidad en adultos a nivel global. Rev Cien Arbitrada Multidis PENTACIENCIAS[Internet]. 2023[citado 10/5/2025];5(5):[aprox. 10p.]. Disponible en: <https://editorialalema.org/index.php/pentaciencia/article/view/742>.
2. Santana S. Estrategia nacional para la prevención y el control de las enfermedades no transmisibles y sus factores de riesgo. Cuba 2020 - 2025. Rev Cubana Alimentación Nutrición[Internet]. 2021[citado 10/5/2025];31(2):[aprox. 5p.]. Disponible en: <https://revalnutricion.sld.cu/index.php/rcan/articloe/view/1258>.
3. Valdés D, Vázquez V, Rangel A. Cambios en la frecuencia del consumo de alimentos y el estado nutricional en campesinos de Yaguajay, centro de Cuba, 2017-2022. Rev Argen Antropol Biológica[Internet]. 2023[citado 23/11/2025];25(2):[aprox. 8p.]. Disponible en: https://www.scielo.org/ar/scielo.php?pid=S1514-79912023000200069&script=sci_arttext.
4. Bauce GJ. Índice de masa corporal, peso ideal y porcentaje de grasa corporal en personas de diferentes grupos etarios. Rev Digital Postgrado[Internet]. 2021[citado 7/5/2025];11(1):[aprox. 7p.]. Disponible en: https://saber.ucv.ve/ojs/index.php/rev_dp/article/view/22824.
5. Schlosser K, Barillas M. La obesidad: más allá del IMC. Rev Facultad Med[Internet]. 2024[citado 7/5/2025];2(2):[aprox. 12p.]. Disponible en: <https://revista-medicina.ufm.edu/index.php/revista/article/download/126/199>.
6. De la Torre I, Casas M, De Luis DA. Aportaciones de la inteligencia artificial en el área de la obesidad. Nutr Clin Med[Internet]. 2024[citado 16/5/2025];18(3):[aprox. 11p.]. Disponible en:

<https://nutricionclinicaenmedicina.com/pdf/NCM.2024.18.3.0004.pdf>.

7. Collins GS, Moons KGM, Dhiman P, Riley RD, Beam AL, Van Calster B, et al. TRIPOD+AI statement: updated guidance for reporting clinical prediction models that use regression or machine learning methods. *BMJ*. 2024;385(1):078378.

8. Christodoulou E, Ma J, Collins GS, Steyerberg EW, Verbakel JY, Van Calster B. A systematic review shows no performance benefit of machine learning over logistic regression for clinical prediction models. *J Clin Epidemiol*.

2019;110(1):12-22.

9. Boakye NF, O'Toole CC, Jalali A, Hannigan A. Comparing logistic regression and machine learning for obesity risk prediction: A systematic review and meta-analysis. *Int J Med Inform*. 2025;199(1):105887.

10. Moons KGM, Damen JAA, Kaul T, Hooft L, Andaur C, Dhiman P, et al. PROBAST+AI: an updated quality, risk of bias, and applicability assessment tool for prediction models using regression or artificial intelligence methods. *BMJ*. 2025;388(1):e082505.