

SISTEMA BIOMÉDICO BASADO EN INTELIGENCIA ARTIFICIAL PARA ESTIMAR INDIRECTAMENTE SARCOPENIA EN PERSONAS ADULTAS MAYORES MEXICANAS

Santiago Arceo Díaz¹, Elena E. Bricio-Barrios², José R. González-Farías¹, Lina S. de la Madrid-Trevizo¹, Xochilt A. R. Trujillo-Trujillo^{*1}, Jaime A. Bricio-Barrios¹, Mónica Rios-Silva¹, Rosa Y. Cárdenas-María¹, Miguel Huerta-Viera¹

¹Universidad de Colima, Centro Universitario de Investigaciones Biomédicas. Av. Gonzalo De Sandoval 444, 28046, Colima, Col. México. e-mail: {santiagoarceo, jgonzalez90, rosio, jbricio, mrios, rosa_cardenas, huertam}@uclm.mx, lina.trevi@gmail.com

²Tecnológico Nacional de México-Instituto Tecnológico de Colima, Departamento de Ciencias Básicas. Avenida Tecnológico no. 128, Villa de Álvarez, 28976 Villa de Álvarez, Col. México. e-mail: elena.bricio@colima.tecnm.mx

RESUMEN.

En este trabajo se describe el diseño e implementación de una aplicación móvil, escrita en Python 3, que provee al personal médico de atención primaria a adultos mayores de modelos predictivos para la masa muscular y el porcentaje de grasa corporal basados en parámetros antropométricos. El objetivo principal es facilitar la evaluación del riesgo de sarcopenia de manera accesible y precisa. Los modelos se obtuvieron a partir de una muestra de personas adultas mayores en la Ciudad de Colima, Colima, México, utilizando técnicas de regresión lineal y árboles de decisión. La aplicación resultante es de libre acceso y provee al personal médico una alternativa viable para el registro y análisis de datos antropométricos, sin necesidad de estar familiarizados con la programación. Los beneficios incluyen la facilidad de uso, la accesibilidad y la capacidad de realizar evaluaciones rápidas y precisas en entornos con recursos limitados.

Palabras Clave: antropometría, adultos mayores, aplicación móvil.

ABSTRACT.

This work describes the design and implementation of a mobile application, written in Python 3, that provides primary care medical staff for older adults with predictive models for muscle mass and body fat percentage based on anthropometric parameters. The main objective is to facilitate the assessment of sarcopenia risk in an accessible and accurate manner. The models were obtained from a sample of older adults in the city of Colima, Colima, Mexico, using linear regression techniques and decision trees. The resulting application is freely accessible and provides medical staff with a viable alternative for recording and analyzing

anthropometric data without needing to be familiar with programming. The benefits include ease of use, accessibility, and the ability to perform quick and accurate assessments in resource-limited settings.

Keywords: antropometry, elderly people, mobile application.

1. INTRODUCCIÓN

En la actualidad, es posible monitorear en tiempo real las señales biomédicas de una persona. El funcionamiento de un sistema biomédico inicia al captar una señal física, como radiación, luz, sonido, ondas ultrasónicas, etc., que mediante un transductor se convierte en una señal eléctrica. Esta señal eléctrica es digitalizada para obtener una magnitud que se visualiza en una pantalla [1].

Estos sistemas biomédicos han permitido al personal médico y de apoyo disponer de un panorama más amplio para realizar un diagnóstico clínico certero de una enfermedad o para el seguimiento de la salud de un paciente que se realiza un chequeo regular. Sin embargo, estos dispositivos deben reemplazarse por equipos avanzados en personas con amputaciones o personas que no pueden mantenerse de pie por sí mismas debido a afecciones musculoesqueléticas como artritis, osteoporosis y dolor lumbar [2].

Esta problemática es frecuente en el área geriátrica, donde es común la asistencia de pacientes, los cuales se sospecha que adquirieron sarcopenia que está asociado a caídas, fracturas y muerte prematura. Este síndrome geriátrico puede diagnosticarse mediante dos técnicas principales:

- Absorciometría de rayos X de energía dual (DEXA): Con una precisión del 98 al 99 %, tiene un costo aproximado, sin incluir la interpretación de los resultados, de 2,000 pesos mexicanos. Esta técnica

utiliza rayos X de baja energía para clasificar músculo y grasa respecto a huesos [3].

- **Báscula de bioimpedancia:** Con una precisión del 95 al 97 %, tiene un costo de prueba y análisis del resultado de alrededor de 300 pesos mexicanos. Su funcionamiento se basa en un circuito cerrado, donde el paciente descalzo se sube a una báscula y sostiene unas mancuernas. De éstas se transfiere una corriente eléctrica indolora que se desplaza desde las palmas de las manos hasta los pies. Con base en la resistencia eléctrica e impedancia que genera el cuerpo del paciente se obtiene la cantidad de agua, la densidad ósea y la masa corporal [4].

A pesar de disponer de la tecnología para realizar un diagnóstico clínico certero, la adquisición y mantenimiento de los equipos no son asequibles para la mayoría de los centros de salud ubicados en comunidades rurales de países en desarrollo [5].

Esta problemática fue abordada por Arceo et al. en [6] quienes crearon una aplicación, llamada SARCOPEN-IA que consiste en sistema de cribado mediante medidas antropométricas en personas adultas mayores mexicanas. Mediante aprendizaje automático y árboles de decisión, construyeron tres sistemas de clasificación de sarcopenia que obtuvieron una precisión del 80 % respecto al diagnóstico clínico.

La siguiente etapa de esta aplicación fue identificar la usabilidad de esta herramienta de software en un entorno real. Los resultados reportados por los usuarios que utilizaron esta aplicación fue que, en algunos casos los pacientes o sus cuidadores no disponen de registros de masa muscular y porcentaje de masa muscular, variables que requieren para el diagnóstico primario de sarcopenia, mismos que se obtienen mediante DEXA.

Previamente, esta problemática ha sido abordada mediante la estimación de la masa muscular usando modelos predictivos de regresión lineal, donde la variable predictora fue el perímetro de cintura donde el factor de correlación fue de 0.31 [7]. Al incrementar las variables de entrada el factor de correlación incrementa, por ejemplo, Saavedra en [8] desarrolló una ecuación multifactorial conformada por las variables de perímetro de trícep, pliegue de bícep, abdomen, muslo, altura, peso y sexo para estimar el porcentaje de grasa corporal con un factor de correlación de 0.85.

Si bien estas aproximaciones numéricas ofrecen una aproximación a las variables de interés, estos modelos están limitados a las características de la muestra seleccionada. Por tanto, es de interés disponer de una herramienta computacional capaz de realizar predicciones en tiempo real basadas en modelos entrenados [9].

La categorización o técnica de agrupamiento permite identificar jerárquicamente las características y puntos de

corte para obtener un diagnóstico preciso. De los modelos reportados, los árboles de decisión cumplen el objetivo de segmentar datos complejos en subconjuntos más manejables, facilitando la interpretación y el diagnóstico. La siguiente etapa implica la creación de un bosque de árboles de decisión, conocido como Random Forest, que combina múltiples árboles de decisión para mejorar la precisión y robustez del modelo, reduciendo la varianza y el sobreajuste a los datos de entrenamiento [10].

Recientemente, la técnica de Descenso de gradiente ha ganado prominencia en el ajuste y optimización de modelos predictivos. Esta técnica ajusta iterativamente los parámetros del modelo para minimizar la función de costo, mejorando así la precisión y eficacia del modelo [11].

Por tanto, este trabajo propone el diseño y construcción de un sistema de cribado primario de sarcopenia en personas adultas mayores colimenses basado en parámetros antropométricos que puedan registrarse con equipos asequibles como cintas métricas y plicómetros, con un costo de prueba e interpretación de resultados que oscila entre 50 y 100 pesos mexicanos. Aunado a esto, se proporciona una aplicación móvil que permite ingresar manualmente las mediciones biométricas del paciente o una base de datos de un grupo de adultos mayores y, mediante el sistema predictivo, ofrecer una aproximación de las variables de masa muscular, porcentaje de grasa corporal con opción de diagnóstico primario de sarcopenia.

2. METODOLOGÍA

2.1 Base de datos.

En el año 2023 se realizaron visitas a un centro de convivencia de personas adultas mayores, como parte de las acciones realizadas por el programa de servicio social de la Universidad de Colima. Durante estas visitas se solicitó la participación voluntaria de las personas asistentes en sesiones de medición de parámetros antropométricos para dar seguimiento a su estado de salud (estudio evaluado y aprobado previamente por el Comité de Ética en Investigación de la Universidad de Colima y registrado ante la Comisión Nacional Bioética de México bajo el registro EICANCL08012021-MARCOGP-01).

Uno de los puntos de interés del estudio fue la determinación de la prevalencia de sarcopenia. Se definieron los siguientes criterios de inclusión: el consentimiento informado para el uso de las mediciones antropométricas recolectadas, una edad mínima de 60 años, no contrar con problemas que dificulte a la persona participar en algunas de las pruebas (como la falta de extremidades, artritis severa o enfermedades

cardiovasculares). A las personas que cumplieron los criterios de inclusión, se les realizaron mediciones de variables antropométricas de perímetro de brazo, cadera, cintura y pantorrilla, utilizando una cinta métrica. A continuación, se midió su fuerza de presión palmar con un dinamómetro. Con ayuda de un plicómetro se registró la longitud de pliegue cutáneo del brazo. Adicionalmente, se empleó un cronómetro casero para medir la velocidad de marcha. Cada uno de los registros se transcribió en una hoja de cálculo y se almacenó bajo las extensiones .xlsx y .csv. La muestra final comprendió de 62 participantes, con los cuales se creó una base de datos para el cálculo de los modelos predictivos. Aunque la cantidad de participantes es limitada para establecer un diagnóstico definitivo de sarcopenia, el principal objetivo de este estudio fue desarrollar un prototipo para identificar áreas de mejora en el sistema y evaluar su viabilidad preliminar.

2.2 Estimador del sistema biomédico.

Con la base de datos recolectada, se procedió a la creación de un sistema biomédico computacional que tuviera como objetivo el cálculo de la masa muscular, el porcentaje corporal de grasa y el riesgo de sarcopenia a partir de mediciones antropométricas. Aunado a esto, se estableció que la aplicación resultante debería ser de libre acceso, no deber requerir que el usuario esté familiarizado con la programación y que los modelos y predicciones mostradas mantuvieran la privacidad de las personas que fueron voluntarias en el estudio.

El lenguaje de programación utilizado fue Python 3, debido a que es de libre acceso y cuenta con la librería de scikit-learn, que permite implementar los modelos predictivos basados en árboles de regresión, mientras que la primera versión del código se creó en la plataforma de libre acceso “Google Colab”. En esta primera versión se definieron el proceso de depuración de datos; un estimador en el que calculan modelos de regresión para la masa muscular y el porcentaje de grasa corporal a partir de una o dos las variables antropométricas (también se establecieron algunas métricas para evaluar la bondad del ajuste y el error cuadrático promedio) y un módulo en el que los modelos predictivos resultantes pueden aplicarse de forma automática a una base de datos recolectada por el usuario y obtener estimaciones de las variables de interés y el nivel de riesgo de sarcopenia. La Figura 1 muestra un diagrama de flujo desde la recolección de datos hasta la aplicación de los modelos para el cálculo de la masa muscular y el porcentaje de grasa corporal.

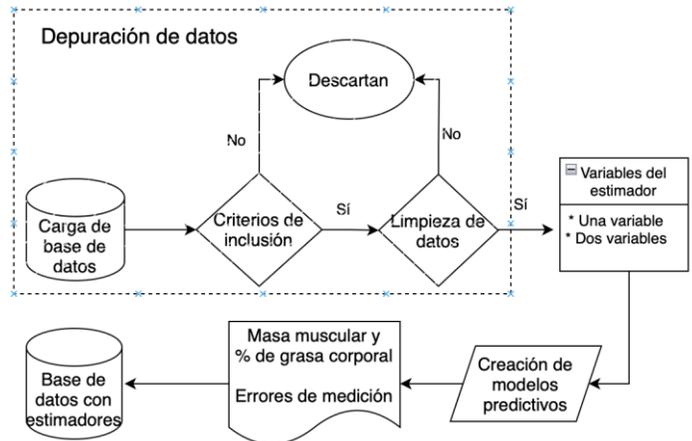


Figura 1. Diagrama de flujo del estimador.

2.3 Selección de las variables del estimador.

La librería scikit-learn ofrece una amplia gama de modelos predictivos, de manera gratuita y accesible. Los algoritmos seleccionados para la creación de los modelos predictivos fueron los de árbol de regresión simple, Random Forest y Descenso de gradiente. Seleccionamos estos modelos debido a su efectividad en la predicción de fenómenos no lineales y a la simplicidad con la que las reglas de decisión resultantes pueden aplicarse. Gracias a los modelos de árbol de regresión es posible obtener predicciones precisas a partir de pocas variables, facilitando su implementación en entornos en los existan limitantes en los equipos de medición disponibles.

Para cada tipo de modelo (modelos que emplean una sola variable o dos para el cálculo de las variables de interés), se definieron dos escenarios: en el primer escenario las variables predictoras están fijas y corresponden a aquellas que se han reportado en trabajos previos [12]. En el segundo escenario, las variables predictoras se dejan libres y por lo tanto los modelos resultantes pueden adaptarse de acuerdo a las limitaciones que se le presenten al personal clínico de atención primaria. En el caso de los modelos de dos variables se definieron el perímetro de pantorrilla y la fuerza de presión palmar, como estimadores de la masa muscular [13] y el perímetro de brazo y el pliegue cutáneo de brazo para el porcentaje de grasa corporal [14].

La Figura 2 muestra el proceso para calcular la masa muscular o el porcentaje de grasa corporal a partir de las variables disponibles. Si el usuario selecciona el módulo de “calcular con una sola variable”, en la primera parte se muestran los modelos en los que se calcula la masa muscular a partir del perímetro de pantorrilla y el porcentaje de grasa corporal a partir del perímetro de brazo. Si el usuario selecciona el módulo “calcular con dos variables”, los modelos se calcularán a partir

deperímetro de brazo y la fuerza de presión palmar, en el caso de la masa muscular y del perímetro y el pliegue cutáneo de brazo, en el caso del porcentaje de grasa corporal. En cada caso también se pueden introducir valores de la variable predictora y obtener una estimación de la variable a calcular. Los valores resultantes para ambos parámetros se compararon con las mediciones obtenidas a partir de una balanza de bioimpedancia (un equipo que da estimaciones adecuadas para ambos parámetros pero que no es un instrumento frecuente en las clínicas de atención primaria para adultos mayores). En todos los casos, junto a cada modelo se presenta el coeficiente de bondad del ajuste R^2 y el error cuadrático medio, respecto a las mediciones obtenidas utilizando la balanza de bioimpedancia.

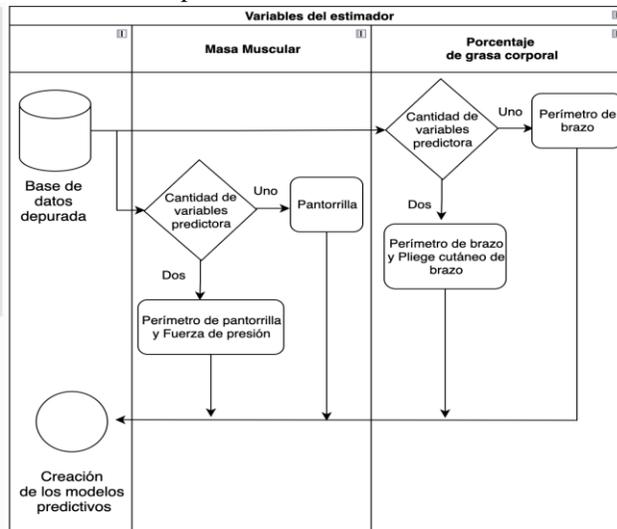


Figura 2. Diseño del estimador para crear un modelo predictivo con una o dos variables.

2.4 Diagnóstico primario de sarcopenia.

Con las variables estimadas, es posible continuar con el estudio del cribado primario de sarcopenia desarrollado por Arceo et al en [6]. La Figura 3 muestra la conexión de los módulos del sistema biomédico y de la aplicación SARCOPEN-IA disponible en <https://acortar.link/MfIN1t/>

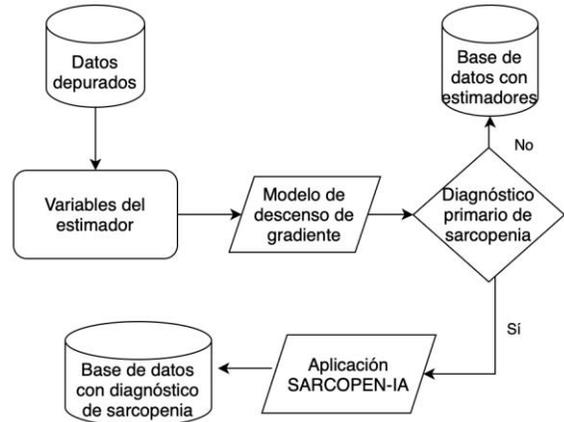


Figura 3. Acoplamiento de módulos de estimador de variables y el diagnóstico primario de sarcopenia.

En la Figura 3 se observa que, inicia con los datos que fueron previamente depurados para disponer de una base de datos homogénea y con las variables completas. Estos registros son alimentados a la etapa de selección de las variables del estimador los cuales serán manipulados por el modelo de Descenso de gradiente como herramienta para estimar masa muscular y porcentaje de grasa corporal debido a que esta técnica ha mostrado mayor fiabilidad respecto a otras técnicas cuando se introducen nuevos registros, así como la baja demanda computacional respecto a Random Forest [15]. A continuación, se ofrece al usuario la alternativa de realizar el diagnóstico primario de sarcopenia. Si el usuario desea solo extraer las variables de interés, se generará una nueva base de datos con los estimadores. Si el usuario desea conocer el riesgo de sarcopenia, el algoritmo de la aplicación SARC-OPEN-IA, el cual mostrará en pantalla los tres sistemas de clasificación de esta enfermedad geriátrica.

Una vez definidos los modelos, se programó un script que permite calcular automáticamente la masa muscular, el porcentaje de grasa corporal y el riesgo de sarcopenia para cada uno de los participantes voluntarios.

2.5 Implementación de aplicación móvil.

Si bien colab provee de una plataforma de libre acceso para la creación del sistema biomédico de predicción de masa muscular y grasa corporal, su uso requiere que el usuario esté familiarizado con el lenguaje Python, algo que no es común en el personal médico de atención primaria. Para eliminar esta dificultad todos los módulos descritos fueron transferidos a la plataforma web de streamlit, una biblioteca de código abierto en Python que permite a los desarrolladores crear rápidamente aplicaciones web interactivas para la visualización de

datos y el aprendizaje automático. La aplicación solo requiere que el usuario la manipule mediante cajas para el llenado de información, deslizadores y/o botones para el control de variables y la visualización de los modelos. Además, puede accederse a ella a través de internet mediante un enlace y funciona tanto en equipos de escritorio, portátiles o dispositivos móviles, como teléfonos inteligentes o tabletas.

3. RESULTADOS

La aplicación implementada en streamlit, nombrada como ANTROPO-FIT disponible en: <https://acortar.link/UESd0y> está compuesta de cinco módulos: la presentación, en donde se detallan las motivaciones del proyecto; dos módulos para el cálculo de modelos predictivos con una o dos variables; un módulo para el diagnóstico de sarcopenia y uno para el ingreso de datos en tiempo real.

El primer módulo se divide en dos partes, en la primera se emplean las mediciones del perímetro de pantorrilla para la predicción de la masa muscular y las del perímetro de brazo para el porcentaje de grasa corporal. A manera de ejemplo, la Figura 4 muestra los modelos predictivos para la masa muscular (así como el valor de los coeficientes de bondad del ajuste). En cada figura, los puntos corresponden a los datos, la línea recta al modelo de regresión lineal y las trayectorias de color azul, verde y púrpura a los modelos de árbol de regresión, Random Forest y Descenso de gradiente.

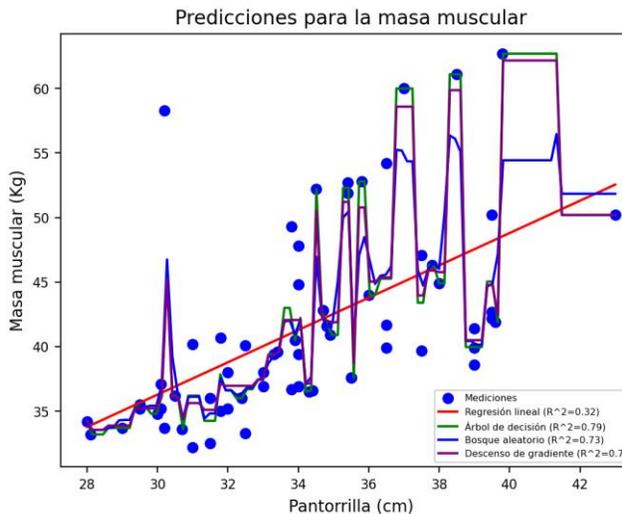


Figura 4. Modelos predictivos de una variable para la masa muscular medida en kilogramos, a partir del perímetro de la pantorrilla.

Los modelos se crean de forma automática a partir de los datos y establecen un conjunto de reglas de decisión que

predicen el valor de la masa muscular a partir de un valor específico para el perímetro de la pantorrilla. El usuario no interactúa directamente con los modelos sino que introduce dicho valor específico en una calculadora y de manera automática esta calculadora le regresa al usuario la predicción de la masa muscular de acuerdo a cada modelo considerado (Figura 5).

Calculadora de masa muscular

A continuación puede teclear un valor de perímetro de pantorrilla (medido en centímetros) y al presionar Enter se muestra la estimación de masa muscular de acuerdo con cada modelo (en kilogramos).

Introduzca un valor para el perímetro de pantorrilla (cm)

Predicción usando Regresión Lineal: 33.78 kg
 Predicción usando Árbol de Decisión: 34.20 kg
 Predicción usando Bosque aleatorio: 33.98 kg
 Predicción usando Descenso de gradiente: 34.26 kg

Figura 5. Calculadora de masa muscular a partir de un valor específico para el perímetro de la pantorrilla.

En la segunda parte de este módulo, así como del módulo para modelos predictivos de dos variables, el usuario puede crear modelos predictivos a partir de cualquiera de las variables antropométricas disponibles (peso, altura, perímetro de cintura o cadera, pliegue cutáneo de brazo, o fuerza de presión palmar). Una vez definida la variable predictora, la aplicación devuelve el gráfico de ajuste y la predicción para valores específicos que se introduzcan en la calculadora.

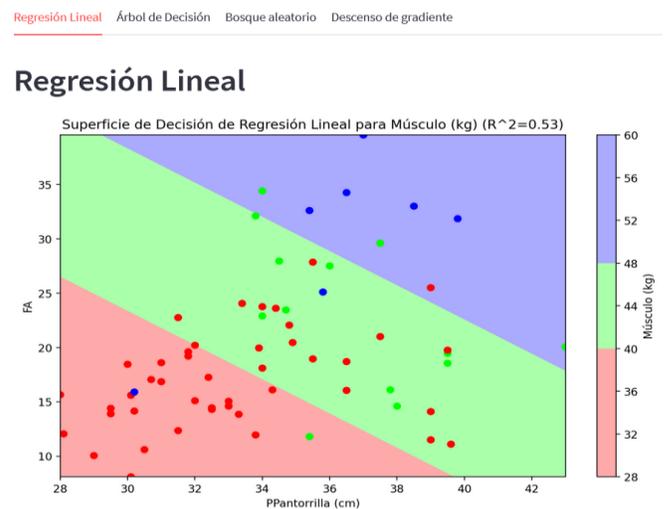


Figura 6. Superficie de decisión para las predicciones de un modelo de regresión lineal sobre la masa muscular a partir de las mediciones de perímetro de pantorrilla y fuerza de presión palmar.

El módulo de “modelos de dos variables” también se divide en dos partes: en la primera parte, se crean modelos en los que las variables predictoras están fijas: la masa muscular se calcula a partir del perímetro de pantorrilla y la fuerza de presión palmar, mientras que el porcentaje de grasa corporal se calcula a partir del perímetro de brazo y el pliegue cutáneo. En la segunda parte es posible que el usuario defina un par de variables predictoras y la aplicación calculará los modelos correspondientes y habilitará la calculadora para que el usuario obtenga un valor para la variable de interés. Las Figuras 6 y 7 muestran un gráfico de superficie de decisión, con las mediciones de la base de datos y las predicciones de los modelos. En la figura 6 se muestra la superficie para el modelo de regresión lineal y en la 7 para el de Descenso de gradiente. El color de cada punto corresponde al rango de masa muscular al que corresponde dicho punto. En cuanto a los modelos, las zonas de cada color que corresponden a los rangos que predicen. Se considera que el modelo es acertado en la predicción de masa muscular siempre que el color de la zona coincide con las de los puntos que están en ella.

Regresión Lineal Árbol de Decisión Bosque aleatorio **Descenso de gradiente**

Descenso de gradiente

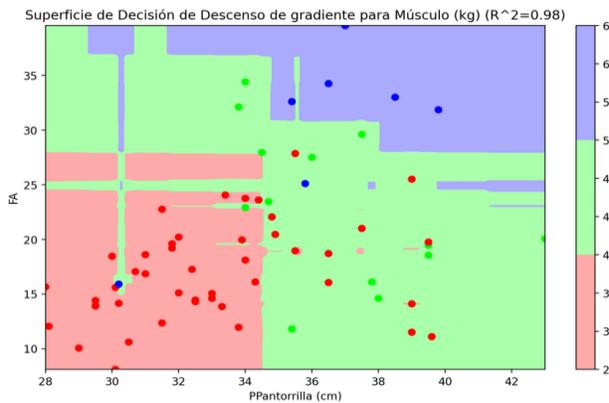


Figura 7. Superficie de decisión para las predicciones de un modelo de regresión de Descenso de gradiente sobre la masa muscular a partir de las mediciones de perímetro de pantorrilla y fuerza de presión palmar.

El último módulo consiste en el registro de datos en tiempo real. Este le permite al especialista clínico introducir los datos de las mediciones antropométricas a través de su dispositivo móvil. A cada registro que se introduzca se le agregan el cálculo de la masa muscular y el porcentaje de grasa corporal, a partir de las estimaciones del modelo de regresión de Descenso de gradiente (el cual reportó el mejor grado de ajuste, sin el riesgo de sobreajuste del modelo de árbol de regresión

simple). Además se incluye la estimación de nivel de riesgo de sarcopenia a partir de algoritmo de clustering jerárquico descrito en [6]. Los grupos encontrados a partir de la muestra utilizada en este trabajo fueron: “sin riesgo”, “obesidad”, “riesgo de sarcopenia” y “riesgo de obesidad sarcopenica”. Las Figuras 8 y 9 muestran el formulario de ingreso de datos en tiempo real y la tabla con los datos de cada paciente, más las estimaciones de masa muscular, grasa corporal y nivel de riesgo de sarcopenia.

Ingreso manual de datos de pacientes

En el siguiente espacio puede ingresar los datos de una persona bajo observación. Cada una de las cajas permite teclear los resultados de las mediciones. Si no conoce los valores para la masa muscular o el porcentaje de grasa corporal deje estos campos en 0.0 y los modelos predictivos los calcularán.

Nombre del Paciente

Edad (años)

Peso (kg)

Altura (cm)

Grasa (%)

Músculo (kg)

Figura 8. Parte del formulario para el ingreso de datos en tiempo real.

DataFrame Resultante

Folio	Edad (años)	Peso (kg)	Altura (cm)	Grasa (%)	Músculo (kg)	PBrazo (cm)	PPantorrilla (cm)	FA (kg)	Marcha (ms-1)	Clasificación	
0	AM-01	65	88	165	38.7726	47.3885	35	40	17.99	0.7	Obesidad
1	AM-02	65	64.99	170	25.1847	36.6432	28	30	15	0.9	Riesgo de sarcopenia

Descargar Datos

Haga clic en el enlace a continuación para descargar los datos en formato Excel.

[Descargar Excel](#)

Figura 9. Formulario descargable con predicciones de masa muscular, grasa corporal y nivel de riesgo de sarcopenia.

4. CONCLUSIONES

La aplicación desarrollada provee de modelos que pueden adaptarse a las variables antropométricas disponibles en las clínicas de atención primaria y permiten calcular la masa muscular, el porcentaje de grasa corporal con un coeficiente de bondad de ajuste entre dos y tres veces mayor que el de un modelo lineal (dependiendo de las variables predictoras). Si además se cuenta con

mediciones de la fuerza de presión y velocidad de marcha, se pueden usar las cuatro variables para predecir el riesgo de sarcopenia en pacientes geriátricos. En trabajos posteriores se trabajará en mejorar la robustez de los modelos al incrementar la muestra. Como trabajo futuro, se tiene previsto ampliar el tamaño de la muestra para mejorar la robustez de los modelos predictivos y obtener resultados más generalizables empleando bases de datos de libre acceso disponibles en la plataforma www.datos.gob.mx.

Referencias

- [1] L. Leija, *Métodos de procesamiento avanzado e inteligencia artificial en sistemas sensores y biosensores*, Reverté, 2021.
- [2] K. Sansam, V. Neumann, R. J. O'Connor, and B. Bhakta, "Predicting walking ability following lower limb amputation: a systematic review of the literature," *Journal of Rehabilitation Medicine*, vol. 41, no. 8, pp. 593-603, 2009.
- [3] K. Y. K. Cheng, S. K. H. Chow, V. W. Y. Hung, C. H. W. Wong, R. M. Y. Wong, C. S. L. Tsang, ... and W. H. Cheung, "Diagnosis of sarcopenia by evaluating skeletal muscle mass by adjusted bioimpedance analysis validated with dual-energy X-ray absorptiometry," *Journal of Cachexia, Sarcopenia and Muscle*, vol. 12, no. 6, pp. 2163-2173, 2021.
- [4] H. Wang, S. Hai, L. Cao, J. Zhou, P. Liu, and B. R. Dong, "Estimation of prevalence of sarcopenia by using a new bioelectrical impedance analysis in Chinese community-dwelling elderly people," *BMC Geriatrics*, vol. 16, pp. 1-9, 2016.
- [5] K. Day, A. Kwok, A. Evans, F. Mata, A. Verdejo-Garcia, K. Hart, ... and H. Truby, "Comparison of a bioelectrical impedance device against the reference method dual energy X-ray absorptiometry and anthropometry for the evaluation of body composition in adults," *Nutrients*, vol. 10, no. 10, p. 1469, 2018.
- [6] S. Arceo, E. E. Bricio, X. A. R. Trujillo, J. R. González, J. A. Bricio, M. Rios, and M. Huerta, "Sistema de Cribado Primario para la Sarcopenia en Personas Adultas Mayores Basado en Inteligencia Artificial," *Revista Mexicana de Ingeniería Biomédica*, vol. 44, no. 4, pp. 53-69, 2023.
- [7] C. C. Guillot, L. E. Neri, and I. S. Aguilar, "Predicción de probabilidad de índice de masa corporal a partir de la circunferencia de cintura," *Revista Cubana de Investigaciones Biomédicas*, vol. 43, 2024.
- [8] X. Saavedra Bernal, "Validez de las fórmulas antropométricas para determinar el porcentaje graso en deportistas con amputación unilateral de miembros inferiores," 2024.
- [9] J. A. Sidey-Gibbons and C. J. Sidey-Gibbons, "Machine learning in medicine: a practical introduction," *BMC Medical Research Methodology*, vol. 19, pp. 1-18, 2019.
- [10] M. G. Jurado Camacho, "Composición corporal bicompartimental en pacientes adultos de 25 a 59 años de edad hospitalizados en el Departamento de Medicina Interna del Instituto de Gastroenterología Boliviano Japonés-IGBJ de la ciudad de La Paz-Bolivia, segundo semestre del 2022," Doctoral dissertation, 2022.
- [11] S. Asif, W. Yue, S. Rehman, Q. Ain, K. Amjad, Y. Yueyang, ... and M. Awais, "Advancements and Prospects of Machine Learning in Medical Diagnostics: Unveiling the Future of Diagnostic Precision," *Archives of Computational Methods in Engineering*, pp. 1-31, 2024.
- [12] Wijnhoven, H. A., van Bokhorst-de van der Schueren, M. A., Heymans, M. W., de Vet, H. C., Kruizenga, H. M., Twisk, J. W., & Visser, M. (2010). Low mid-upper arm circumference, calf circumference, and body mass index and mortality in older persons. *Journals of Gerontology Series A: Biomedical Sciences and Medical Sciences*, 65(10), 1107-1114.
- [13] J. P. Montoya Vega and J. J. García Flórez, "Variables de la condición física, predictores de los niveles de fragilidad en adultos mayores entre 60 y 64 años. Sabaneta Antioquia," 2022.
- [14] É. F. Pereira, C. S. Teixeira, A. F. Borgatto, and L. S. E. Daronco, "Association between different anthropometric indicators and body image perceptions in active elderly," *Archives of Clinical Psychiatry*, vol. 36, no. 2, pp. 54-59, 2009.
- [15] M. Ebrahimi, M. Mohammadi-Dehcheshmeh, E. Ebrahimie, and K. R. Petrovski, "Comprehensive analysis of machine learning models for prediction of sub-clinical mastitis: Deep Learning and Gradient-Boosted Trees outperform other models," *Computers in Biology and Medicine*, vol. 114, p. 103456, 2019.