

[r e v i s i ó n]

Inteligencia artificial en el manejo de la imagen en nutrición clínica: Un nuevo horizonte lleno de posibilidades

Artificial Intelligence in image management in clinical nutrition: A new horizon full of possibilities

Juan José López Gómez^{1,2} y Daniel A. De Luis Román^{1,2}

¹Servicio de Endocrinología y Nutrición. Hospital Clínico Universitario de Valladolid. España. ²Centro de Investigación Endocrinología y Nutrición. Universidad de Valladolid. España

Cómo citar este trabajo

|| López Gómez JJ y De Luis Román DA. Inteligencia artificial en el manejo de la imagen en nutrición clínica: Un nuevo horizonte lleno de posibilidades. Nutr Clin Med 2025;19(1):19-35

Palabras clave

Inteligencia artificial, composición corporal, desnutrición, obesidad, sarcopenia, radiómica.

>>RESUMEN

Introducción y objetivos: La inteligencia artificial (IA) aplicada a la imagen optimiza la evaluación de la composición corporal facilitando y agilizando la obtención de información, además de plantear la existencia de nuevos biomarcadores. Esta revisión explora su aplicación actual, la evidencia científica existente y futuras líneas de desarrollo en este campo.

Fundamentos teóricos: Las principales técnicas de imagen en composición corporal son la ecografía, la tomografía computarizada (TC), la resonancia magnética (RM) y la absorciometría dual de rayos X (DEXA). En este contexto, la IA a través de herramientas de aprendizaje profundo mediante redes neuronales convolucionales permite extraer características cuantitativas (áreas, volúmenes) y cualitativas (densidad, ecogenicidad) de las imágenes, integrándose con técnicas de radiómica para generar biomarcadores precisos.

Aplicaciones específicas: La IA se utiliza para automatizar la segmentación de imágenes, con el objetivo de delimitar de manera exacta los distintos compartimentos que definen la composición corporal. Por otra parte, potencia el análisis de las características de la imagen para valorar la calidad del músculo o la grasa. Mediante distintos algoritmos se puede obtener información de imágenes de ecografía

Correspondencia

Juan José López Gómez
Email: jjlopez161282@hotmail.com

Obra bajo Licencia Creative Commons Reconocimiento-
NoComercial-CompartirIgual 4.0 Internacional.
Más información:
<http://creativecommons.org/licenses/by-nc-sa/4.0/>



(mediante algoritmos de umbralización múltiple es posible clasificar áreas musculares, de infiltración grasa o fibrosis), TC (el análisis del coeficiente de atenuación ofrece un marcador de calidad muscular), RM (mediante técnicas Dixon o el mapeo T1 se puede discriminar la infiltración grasa) o DEXA (mediante modelado 3D de imágenes 2D), que nos pueden ayudar a realizar un diagnóstico más preciso, un tratamiento personalizado y una monitorización adecuada del tratamiento médico nutricional. *Conclusión:* La integración de la IA en el análisis de imágenes de composición corporal promete transformar el diagnóstico, tratamiento y el seguimiento nutricional, posibilitando intervenciones más personalizadas. Sin embargo, su integración plena en la práctica clínica depende de superar desafíos técnicos, éticos y regulatorios.

Nutr Clin Med 2025; 19 (1): 19-35
DOI: 10.7400/NCM.2025.19.1.0006

Key words

Artificial Intelligence,
Body Composition,
Malnutrition,
Obesity, Sarcopenia,
Radiomics.

<<ABSTRACT

Introduction and aims: Artificial Intelligence (AI) applied to imaging optimize the assessment of body composition by facilitating and accelerating the acquisition of information, while also introducing the possibility of identifying new biomarkers. This review explores its current applications, the existing scientific evidence, and future lines of development of this field.

Theoretical Foundations: The main imaging techniques used in body composition analysis are ultrasound, computed tomography (CT), magnetic resonance imaging (MRI), and dual-energy X-ray absorptiometry (DEXA). In this context, AI, through deep learning tools using convolutional neural networks, enables the extraction of quantitative (areas, volumes) and qualitative (density, echogenicity) features from images. These can be integrated with radiomics techniques to generate precise biomarkers. *Specific Applications:* AI is used to automate image segmentation, aiming to accurately delineate the different compartments that define body composition. Additionally, it enhances the analysis of image features to assess the quality of muscle or fat tissue. Through various algorithms, information can be extracted from ultrasound images (e.g., using multi-thresholding algorithms to classify muscle areas, fat infiltration, or fibrosis), CT (e.g., attenuation coefficient analysis as a marker of muscle quality), MRI (e.g., using Dixon techniques or T1 mapping to detect fat infiltration), or DEXA (e.g., 3D modeling from 2D images). These tools can support more accurate diagnoses, personalized treatments, and appropriate monitoring of medical nutritional therapy.

Conclusion: The integration of AI in the analysis of body composition imaging promises to transform diagnosis, treatment, and nutritional monitoring, enabling more personalized interventions. However, its full integration into clinical practice depends on overcoming technical, ethical, and regulatory challenges.

Nutr Clin Med 2025; 19 (1): 19-35
DOI: 10.7400/NCM.2025.19.1.0006

>>INTRODUCCIÓN

La valoración nutricional o la evaluación clínica de pacientes con enfermedades dentro del ámbito nutricional presenta un nivel considerable de complejidad debido a la variedad de factores que pueden influir en estas patologías y al tipo de herramienta diagnóstica utilizada para identificarlas. Actualmente, la valoración

nutricional trasciende la mera medición del peso corporal, abarcando un análisis detallado de las necesidades energético-proteicas del paciente, así como de su ingesta alimentaria¹. También incluye un examen separado de los diferentes compartimentos del cuerpo, su funcionalidad y la forma en que estas alteraciones se relacionan con su causa primaria, frecuentemente vinculada a mecanismos inflamatorios². Desde una

perspectiva morfofuncional, esta evaluación facilita la identificación de desnutrición, obesidad y sarcopenia, estableciendo las características particulares de cada tipo, teniendo en cuenta que en ocasiones pueden solaparse³⁻⁵.

En este marco conceptual, el análisis de la composición corporal desempeña un papel esencial en la orientación del diagnóstico nutricional, al considerar tanto la proporción de los diversos compartimentos corporales (masa grasa, masa muscular, agua y otros componentes), como la calidad de los mismos. Esta información es fundamental para evaluar el impacto de la enfermedad desencadenante y la funcionalidad de las estructuras afectadas. Además, una determinación precisa de la composición corporal permite guiar de manera efectiva el tratamiento del paciente y supervisar los resultados de dicho tratamiento⁶.

Las principales limitaciones de las técnicas de imagen en la evaluación de la composición corporal se encuentran relacionadas con la necesidad de realización de pruebas específicas que requieren del desplazamiento del paciente e incluso de tener cierto potencial lesivo debido al uso de radiación como la tomografía computarizada (TC) o la absorciometría de rayos X (DEXA); del tiempo necesario para la recuperación de datos a la hora de realizar segmentación, en el caso de las imágenes de las TC oportunistas, y de la falta de validación de nuevas técnicas más sencillas de realizar como la ecografía muscular para la evaluación tanto de la cantidad de masa muscular o grasa, como en la detección y estandarización de características cualitativas en su evaluación basadas en la propia imagen⁷.

La inteligencia artificial (IA) aplicada al ámbito radiológico tiene un impacto crucial en la optimización de la atención al paciente, abordando aspectos como la selección del tipo de prueba más adecuada según la indicación clínica y la configuración del protocolo de adquisición en función del tejido que se desea analizar. Además, permite priorizar la realización de pruebas según la patología subyacente del paciente. En el caso de la evaluación de la composición corporal, la IA desempeña un papel fundamental en la localización e interpretación de imágenes obtenidas mediante diversas técnicas radiológicas, generando una evolución en el análisis de los

resultados obtenidos mediante estas pruebas diagnósticas⁸.

La integración de la IA en las pruebas de imagen dedicadas a la composición corporal (ecografía muscular y grasa en distintas localizaciones, la TC y la resonancia magnética [RM]) ha permitido avances significativos en la segmentación automatizada de las imágenes. A través de técnicas avanzadas como el aprendizaje automático (*machine learning*), el aprendizaje profundo (*deep learning*), incluyendo las redes neuronales, es posible analizar los diferentes componentes corporales (grasa, músculo y otras estructuras) de manera eficiente, obteniendo tanto parámetros cuantitativos como cualitativos. Estas herramientas también aprovechan el reconocimiento de patrones y el análisis de conjuntos de datos a gran escala para procesar imágenes médicas de forma óptima. Además, estas aplicaciones no solo aceleran la extracción de características cuantitativas, sino que también evalúan aspectos cualitativos, convirtiendo las imágenes en datos valiosos que mejoran la toma de decisiones clínicas. Esto se alinea con el concepto innovador de la radiómica, integrando las capacidades analíticas de la IA para facilitar diagnósticos más precisos y tratamientos personalizados en el ámbito de la composición corporal⁹.

El propósito de esta revisión es analizar los fundamentos del empleo de la IA en el estudio de imágenes radiológicas relacionadas con la composición corporal, examinar la evidencia disponible sobre la aplicación de diversas técnicas de IA en este ámbito y, finalmente, proponer posibles rutas para la investigación y el desarrollo futuro de estas herramientas.

>> FUNDAMENTOS TEÓRICOS Y CONCEPTUALES

Tecnologías de imagen en composición corporal

Las técnicas de imagen más comunes para evaluar la composición corporal incluyen la ecografía, la TC, la RM y la DEXA. La ecografía se utiliza para generar imágenes de tejidos a través de ultrasonidos en diferentes localizaciones y permite evaluar el músculo, la grasa subcutánea y la grasa visceral dependiendo de la localización. La TC, por su parte, ofrece imágenes

detalladas de la distribución de grasa y músculo, aunque requiere exposición a radiación. La RM proporciona imágenes de alta calidad sin radiación, lo que la hace ideal para analizar la composición química de los tejidos para diferenciar entre grasa visceral y subcutánea. Por último, la DEXA es el estándar de oro para medir la densidad ósea y la composición corporal, siendo ampliamente empleada en estudios clínicos para evaluar grasa y masa magra⁷.

En el ámbito de la nutrición clínica y la obesidad, estas técnicas son fundamentales para realizar una evaluación nutricional precisa, tanto para el diagnóstico de patologías nutricionales como para la prescripción de un tratamiento médico nutricional adaptado al paciente⁷. Además, son herramientas indispensables para monitorizar los cambios de la composición corporal durante las intervenciones nutricionales o los tratamientos farmacológicos o quirúrgicos en estas patologías¹⁰.

Los principales parámetros evaluados en la composición corporal mediante imagen son el músculo y la grasa. Estas técnicas permiten evaluar tanto la cantidad de esos componentes como las diferencias cualitativas en el tejido que puede tener relación con la enfermedad de base y con las complicaciones relacionadas con estas¹¹.

Músculo

En la determinación de la masa muscular, las pruebas de imagen se basan en la selección de una zona determinada como un parámetro subrogado de la masa muscular total¹². Esto se realiza mediante la determinación de puntos de corte específicos relacionados con determinadas variables pronósticas o diagnósticas de otras patologías relacionadas¹³; o mediante valores fuera de la normalidad en grandes series en las que se marcan los percentiles en función de la edad y el sexo¹⁴. Por otra parte, la validación de estas pruebas se suele realizar con pruebas de correlación con técnicas utilizadas para la evaluación general de la musculatura^{15,16}.

La ecografía muscular evalúa la masa muscular a través del grosor muscular y del área de distintas zonas musculares; cada una de estas zonas tiene una técnica de realización determinada; no obstante, la más generalizada es la ecografía del músculo recto anterior del cuádriceps debido a

su facilidad en la realización, y su implicación en la bipedestación y la deambulación¹⁷. La TC evalúa la masa muscular a través de la determinación de la masa muscular, de manera predominante en cortes abdominales, utilizando músculos paravertebrales y abdominales; se han utilizado distintas zonas para la evaluación de la masa muscular entre T10 y L5¹³, aunque la más generalizada es la determinación de la masa muscular a nivel de L3 con el parámetro masa muscular esquelética o su índice ajustado por la talla al cuadrado¹⁴. La DEXA permite la estimación de masa muscular a partir del tejido magro de las extremidades, aunque su uso rutinario está restringido debido a una menor disponibilidad y coste¹². Por último, la RM ofrece imágenes de alta calidad de la masa muscular de distintas zonas, aunque se reserva principalmente a investigación, dada la dificultad logística y su menor uso habitual¹².

Tejido adiposo

La evaluación del tejido adiposo mediante técnicas de imagen se basa en la localización y cuantificación del tejido adiposo y su caracterización en función del lugar donde se encuentra ubicado⁵. De esta manera, es posible obtener medidas de cantidad de tejido adiposo y utilizarlo como monitorización de determinados tratamientos nutricionales o farmacológicos. El tejido adiposo se puede cuantificar de manera directa en la zona medida o utilizarlo como parámetro subrogado para estimar la grasa corporal total¹⁸.

El tejido adiposo se puede evaluar mediante distintas técnicas de imagen. En el caso de la ecografía, la evaluación del tejido adiposo subcutáneo se puede realizar en cualquier localización, aunque no todas se encuentran estandarizadas para esta medida; en este caso, a la hora de evaluar el tejido adiposo visceral se puede realizar a nivel de la grasa abdominal, dada la facilidad para la localización de la grasa intraperitoneal; otra localización adecuada sería la grasa perirrenal¹⁹. En la TC y en la RM, la cantidad de tejido adiposo se puede estimar a través de la determinación a nivel abdominal, preferentemente a nivel lumbar, donde puede definirse mejor la grasa subcutánea de la visceral sin interferencias¹⁸. El patrón oro para la determinación de la grasa corporal total sería la DEXA pero, como se ha comentado previamente, esta es una técnica no siempre

disponible, ya que requiere del aparataje y *software* adecuados para su determinación⁷.

Por otra parte, la localización de este tejido adiposo puede servir para evaluar otras características del paciente, como el riesgo cardiovascular. De esta manera, el tejido adiposo localizado en zonas subcutáneas se caracteriza como tejido adiposo subcutáneo, y en zonas intraperitoneal, epicárdica o perirrenal²⁰⁻²² se caracteriza como marcador de grasa visceral. La relación entre estos dos compartimentos se puede plantear como un indicador de calidad. Además, indicadores como la infiltración grasa a nivel muscular pueden ayudar a evaluar la calidad muscular²³.

Radiómica

Más allá de la determinación de la cantidad de los compartimentos de la composición corporal (masa muscular, grasa y agua, principalmente), una de las aplicaciones más interesantes de las pruebas de imagen en la evaluación de la composición corporal es la caracterización cualitativa de los componentes analizados. Este análisis de la calidad del músculo y de la grasa permite evaluar biomarcadores funcionales que ayudan a orientar el tratamiento y predecir las complicaciones. Estas características pueden plantearse dentro del concepto de radiómica.

La radiómica es una disciplina emergente en el ámbito de la medicina y la bioinformática que consiste en la extracción cuantitativa de un gran número de características (o *features*) a partir de imágenes médicas (como TC, RM o tomografía por emisión de positrones), con el objetivo de convertir estas imágenes en datos minables que puedan ser analizados mediante métodos estadísticos o de IA. Esta disciplina tiene aplicación en múltiples áreas médicas, pero su mayor impacto se observa en la oncología⁹. En el campo de la composición corporal, la generación de estos nuevos biomarcadores se puede realizar a través de las características observadas en el músculo tanto en la ecografía o la TC como en la RM, y se relaciona con circunstancias relacionadas con la degeneración muscular asociada a la enfermedad o a distintas patologías²⁴. Por otra parte, la radiómica de los compartimentos grasos puede aplicarse a la evaluación del riesgo cardiovascular o el estado inflamatorio²⁴.

La práctica de la radiómica implica diferentes pasos: *a)* adquisición de las imágenes; *b)* identificación de regiones de interés; *c)* segmentación de los volúmenes; *d)* extracción de características cuantitativas y cualitativas; *e)* uso de características para generar una base consultable, y *f)* análisis de los datos para la predicción de resultados⁹. En varios de estos pasos y en su agregación a otros datos clínicos, la IA podría ser muy importante.

Conceptos básicos de inteligencia artificial en análisis de imagen médica

La IA es una rama informática que busca replicar funciones cognitivas humanas, como el aprendizaje y la toma de decisiones, mediante sistemas computacionales. Dentro de la IA se distinguen varios tipos principales: IA simbólica, basada en reglas lógicas definidas; aprendizaje automático (*machine learning*), que permite a los algoritmos, ya predefinidos, mejorar con la experiencia y los datos; y el aprendizaje profundo (*deep learning*), una subcategoría de *machine learning* que utiliza redes neuronales para procesar cantidades de datos complejos, como imágenes médicas. Estas tecnologías pueden emplear enfoques supervisados, no supervisados, semisupervisados o de refuerzo, dependiendo del grado de intervención humana en el proceso de aprendizaje²⁵.

El *machine learning* en el análisis de la imagen suele utilizarse para aplicar algoritmos similares a los utilizados por el personal humano entrenado con mayor rapidez. Mientras un humano entrenado puede utilizar 10-15 minutos por caso, un ordenador puede analizar la imagen en cuestión de segundos^{26,27}. No obstante, a la hora de evaluar parámetros de calidad de la imagen o segmentar en situaciones que se salen de la normalidad, lo más utilizado son herramientas de *deep learning* con redes neuronales²⁵.

El *deep learning* es un subgrupo de *machine learning* que utiliza redes neuronales (*neural networks*) artificiales que simulan el funcionamiento del cerebro humano mediante nodos interconectados que actúan como neuronas. Estas redes, organizadas en capas, son capaces de aprender relaciones complejas entre los datos, no observadas previamente, lo que les hace útiles para tareas avanzadas como el análisis de imágenes. Dentro de este tipo de *deep learning* se encuentran las redes neuronales convolucionales (*convolutional neural network*), que


son una variante de las redes neuronales diseñadas de manera específica para tareas de visión por computadora, como la clasificación de imágenes. Estas redes utilizan operaciones de convolución para analizar las relaciones espaciales de los píxeles, reduciendo la complejidad y los parámetros necesarios en comparación con las redes tradicionales. Su eficacia ha superado en algunos casos al rendimiento humano en la clasificación semántica de las imágenes. Las redes completamente convolucionales son una adaptación de las *convolutional neural network*, diseñadas para tareas de segmentación semántica a nivel de píxel⁹. Estas redes reemplazan las capas completamente conectadas por operaciones de convolución y deconvolución, lo que permite no solo identificar objetos en una imagen, sino también localizar las regiones de interés. Una implementación popular, la arquitectura U-Net, se utiliza ampliamente en segmentación biomédica debido a su capacidad para combinar características espaciales (cantidad) y semánticas (calidad) con alta precisión²⁸.

La IA y el análisis radiómico están revolucionando el campo del análisis de la composición corporal al automatizar la segmentación y análisis de las imágenes, reduciendo el tiempo necesario y aumentando la precisión. Estas tecnologías, además, pueden extraer características cualitativas de las imágenes, como densidad muscular o volumen de grasa, que se correlacionan con la

desnutrición, enfermedades metabólicas y otros trastornos. Esto no solo mejora el diagnóstico, sino que también permite personalizar tratamientos y predecir complicaciones quirúrgicas y médicas.

El desarrollo de algoritmos de aprendizaje profundo para medir la composición corporal presenta retos, como la necesidad de grandes conjuntos de datos y la dificultad de generalizar modelos entre instituciones con protocolos diferentes. Una solución eficiente ha sido el uso de aumentación de datos, que amplía pequeños conjuntos de datos mediante transformaciones aleatorias de las imágenes²⁹ (figura 1). Ello ha permitido entrenar redes neuronales con menor cantidad de datos y alta precisión. Modelos basados en arquitecturas U-Net han demostrado ser altamente efectivos, logrando segmentar tejidos como grasa subcutánea, grasa visceral, músculo y hueso en imágenes de TC³⁰. Gracias a su capacidad de segmentación precisa y a la aceleración que ofrece la aumentación de datos, U-Net permite desarrollar herramientas prácticas para análisis de composición corporal en diversas áreas anatómicas. Esto lo convierte en una pieza clave en aplicaciones biomédicas modernas²⁸.

Las principales limitaciones a la hora de extrapolar los resultados tanto de cantidad como calidad muscular son, por una parte, el tiempo necesario para realizar la localización y segmentación de



los componentes musculares y grasos; y, por otra parte, la variabilidad interobservador al localizar las zonas de masa muscular y grasa y caracterizar cualitativamente sus características. En este sentido, la IA ha venido a ayudar reduciendo el tiempo de procesamiento y el desarrollo de nuevos biomarcadores a partir del análisis de la imagen.

>> APLICACIONES ESPECÍFICAS DE INTELIGENCIA ARTIFICIAL EN EL ANÁLISIS DE IMÁGENES DE COMPOSICIÓN CORPORAL

El uso de la IA en el análisis de imagen de composición corporal tiene múltiples aplicaciones que pueden ayudar al manejo del paciente desde el punto de vista nutricional. En primer lugar, las herramientas de IA ayudan a la automatización de la segmentación de imágenes para la evaluación cuantitativa de la composición corporal; por otra parte, el análisis cualitativo de la imagen permite el conocimiento de las características de los distintos compartimentos y su relación con la fisiopatología de las distintas enfermedades. Estas características integradas posibilitan el desarrollo de biomarcadores que ayudan al diagnóstico temprano de las enfermedades nutricionales, la monitorización de los tratamientos y el desarrollo de nuevas dianas terapéuticas; por último, estas características pueden ayudar a evaluar el pronóstico relacionado con el estado nutricional y metabólico de las distintas patologías de base del paciente.

Automatización y segmentación de imágenes

La automatización en la segmentación de pruebas de imagen para la evaluación de la composición corporal se basa en identificar y delimitar compartimentos anatómicos (como la masa muscular y el tejido adiposo) mediante distintos niveles de intervención: a) Técnicas manuales: el observador delimita a mano cada estructura sin ayuda del *software*; es la técnica utilizada habitualmente por parte de los médicos especialistas en radiología para la evaluación de las imágenes. b) Técnicas semiautomáticas: el programa realiza una detección preliminar de las estructuras y el observador corrige cualquier error o imprecisión; esta técnica se puede realizar mediante algoritmos cerrados basados en las características

de la imagen o mediante la introducción de la IA. c) Técnicas automáticas: Los algoritmos identifican y segmentan las estructuras de forma íntegra sin intervención humana.

El uso de la IA, especialmente a través de *deep learning* y redes neuronales convolucionales, ha permitido mejorar significativamente la calidad y la rapidez de estas segmentaciones. Además de permitir, por ejemplo, algoritmos avanzados, pueden integrar parámetros antropométricos (como peso, altura y edad) para construir modelos 3D flexibles y correlacionarlos con la morfología del paciente³¹. No obstante, existen diferencias en la evolución de la segmentación en función de la técnica de composición corporal utilizada.

En la TC se han implementado modelos que, al segmentar automáticamente tejidos específicos, alcanzan índices de exactitud muy altos en segmentación de músculo esquelético (coeficientes Dice y Jaccard superiores a 0,94); en tejido adiposo subcutáneo y visceral, estos coeficientes también son elevados (por encima de 0,96)³². Estos datos indican valores superiores a los métodos convencionales, dado que en estos métodos la variabilidad interobservador podría mostrar cambios diagnósticos en el 43 % de los casos, mientras que con una IA entrenada se producían resultados idénticos tras dos determinaciones³³. La evaluación de la composición corporal se realiza habitualmente en el abdomen a nivel de L3. Aunque habitualmente se utiliza el protocolo de Alberta para la segmentación, existe una variabilidad considerable en la ubicación del corte de la TC analizado (por ejemplo, utilizar una única medida frente a abarcar el grosor total de la vértebra), lo que puede inducir errores en la extrapolación de los datos³⁴. Además, el grosor del corte podría generar diferencias, especialmente en las técnicas automatizadas, aunque estas variaciones son mínimas en el análisis de tejidos blandos³⁵. La integración de la IA permite procesar tanto cortes aislados como el promedio de varios, gracias a un entrenamiento previo, lo que agiliza y mejora la precisión de la evaluación³⁶.

La ecografía es una técnica mucho más fácil de realizar en la práctica clínica habitual; no obstante, la segmentación y generalización es más compleja debido a la dependencia del observador a la hora de realizar dicha segmentación. La

utilización de IA para la segmentación de imágenes en pacientes con desnutrición relacionada con la enfermedad ha demostrado ser, al menos, igual de adecuada que el observador en algunos estudios. García-Herreros *et al.* demostraron que la segmentación automática realizada por una herramienta de IA (PIIXMED™) tenía un coeficiente de correlación intraclase de 0,912 para la grasa subcutánea, 0,96 para el grosor muscular y 0,99 para el área muscular³⁷. Por otra parte, se evaluó la utilización de otra herramienta IA de segmentación (Bat) comparándola con TC, y evaluando la relación con el pronóstico; en este caso, se observó una fuerte correlación entre la TC y la ecografía del recto anterior del cuádriceps ($r = 0,67$; $p < 0,01$) y una mejora de los resultados en relación con la estancia media hospitalaria (área bajo la curva de 0,73; $p = 0,02$)³⁸.

En la RM existen múltiples estudios de evaluación de lesiones en distintas localizaciones (cerebro, abdomen o lesiones musculares) estudiando la posición y las características de las lesiones de cara a dirigir determinados tratamientos, por ejemplo en lesiones hipofisarias³⁹, pancreáticas⁴⁰ o hepáticas^{41,42}. Aunque la extracción de métricas de composición corporal se ha realizado con mayor frecuencia en imágenes de TC debido a su disponibilidad y rapidez, la precisión de la segmentación en RM es comparable. El hecho de que muchos pacientes se sometan a estudios de RM subraya la necesidad de desarrollar herramientas específicas que puedan extraer de forma precisa un conjunto completo de métricas de composición corporal a partir de esta modalidad⁴³. Dentro de los tejidos segmentados, la grasa subcutánea resulta la más sencilla de delimitar debido a su forma geométrica simple. En contraste, la grasa visceral y el músculo esquelético presentan estructuras morfológicamente más complejas, lo que demanda una segmentación más cuidadosa y un mayor entrenamiento de la herramienta. Resulta especialmente importante mejorar la segmentación de la masa muscular esquelética mediante RM, ya que hasta el momento solo se cuenta con estudios aislados que han mostrado un desempeño inferior en comparación con la TC⁴³.

La técnica de imagen en composición corporal menos estudiada probablemente sea la DEXA. No obstante, existen distintos modelos de redes neuronales para reconstrucción 3D a partir de imágenes de DEXA. Shepherd *et al.* utilizaron

técnicas de *machine learning* para generar modelos tridimensionales, validándolo con otros métodos de imagen⁴⁴. En este sentido, Leong *et al.* describen el uso de redes neuronales convolucionales para entrenar un modelo con un conjunto de datos etiquetado, obteniendo una segmentación precisa de los diferentes tejidos y una estimación volumétrica de grasa y masa muscular⁴⁵. Estos estudios se encuentran en fases muy tempranas de desarrollo pero han demostrado una relación de los biomarcadores medidos con el sexo y la raza, además de con el riesgo de mortalidad⁴⁴.

Evaluación de las características de la imagen

La evaluación de la composición corporal se ha beneficiado de la aplicación de la IA y las técnicas de radiómica. Estas metodologías permiten procesar y transformar imágenes obtenidas mediante técnicas no invasivas en datos cuantitativos altamente precisos. Con algoritmos de segmentación automática y modelos de aprendizaje profundo, es posible extraer características de calidad de los tejidos, como la densidad muscular y la distribución de grasa, lo que facilita el diagnóstico y la monitorización de características metabólicas⁹.

El diagnóstico de la calidad muscular o la evaluación de la existencia de datos de atrofia o mioesteatosis es uno de los puntos clave en la caracterización a través de la IA. En esta situación, la IA puede permitir una evaluación más precisa y estandarizada de la infiltración grasa en músculo esquelético a través de distintas herramientas en las distintas pruebas de imagen (TC, ecografía y RM)²³.

Otro de los desafíos en la evaluación cualitativa de la composición corporal es el análisis de la masa grasa y su calidad. Debido a la alta variabilidad del tejido adiposo visceral, el uso de algoritmos de *deep learning* mejora la precisión en su evaluación. Además, al considerar el pronóstico relacionado con el componente graso, la ratio de grasa visceral a grasa subcutánea, ajustado por la superficie corporal, se ha vinculado con una mayor supervivencia libre de enfermedad en ciertos contextos oncológicos⁴⁶.


La ecografía, especialmente a través del análisis de la intensidad de la imagen obtenida por ultra-

sonidos y la elastografía de onda de corte, se postula como una herramienta de evaluación de la calidad muscular en el punto de atención. Aunque la aplicación de la IA en ecografía está aún en fases emergentes, su incorporación promete optimizar la cuantificación de la grasa intramuscular, reduciendo la variabilidad interobservador²³. La evaluación de la mioesteatosis a través de la ecografía muscular se basa en la ecogenicidad del tejido y la evaluación de las distintas escalas de grises para diferenciar el porcentaje de masa muscular y de masa grasa dentro de la región de interés marcada^{47,48}. Estos parámetros ayudan a evaluar la funcionalidad muscular y su evolución durante un tratamiento a través de la evaluación de la imagen (figura 2).

Además de extraer el índice de masa muscular esquelética a través de la TC, la IA en la evaluación muscular permite obtener parámetros adicionales que reflejan la funcionalidad del músculo y que se correlacionan con la patología subyacente, la necesidad de tratamiento y el pronóstico clínico⁴⁹. Estos valores son: densidad muscular esquelética, que se determina calculando el promedio del coeficiente de atenuación de la masa muscular total, excluyendo el tejido adiposo inter e intramuscular; por otra parte,

la determinación de la grasa muscular, que es posible estimar gracias a algoritmos entrenados mediante el porcentaje de grasa estimado dentro del músculo, detectando cambios en la atenuación. La tecnología basada en IA facilita la detección y cuantificación tisular pero también permite el fenotipado integral del paciente correlacionando estas variables con el pronóstico⁵⁰. De hecho, en el estudio desarrollado por Zambrano-Chaves *et al.* en 2024 se relaciona con el SMI (evaluado como *Z-score*) con 268 fenotipos médicos, mientras que la densidad muscular se relacionó con 340 fenotipos⁵¹.

En cuanto a la evaluación de la masa grasa, la TC realizada en la ubicación adecuada permite identificar claramente una región de interés donde se distinguen el tejido adiposo subcutáneo del visceral debido a las diferencias en densidad e intensidad. La segmentación automática basada en IA facilita separar estos compartimentos y generar variables que cuantifiquen su cantidad y relación⁴⁹. Entre las métricas empleadas se encuentran la adiposidad visceral, la subcutánea y la ratio entre ambas; asimismo, se han propuesto indicadores adicionales como la atenuación de la grasa en cada compartimento⁵².



La RM ofrece una excelente resolución de tejidos blandos, y técnicas como la secuencia Dixon, el mapeo T1-T2 y la determinación de la fracción de grasa permiten cuantificar de forma precisa la infiltración grasa en el músculo. La integración de la IA en la RM mejora la segmentación automática de las imágenes y la robustez de las mediciones, lo cual permite una caracterización detallada y reproducible de mioesteatosis²³.

Ejemplos de algoritmos de aprendizaje profundo

Ecografía

Existen distintas herramientas en estudio para la segmentación automática de la ecografía muscular y evaluación de la cantidad y calidad muscular de distintos grupos musculares, principalmente recto anterior del cuádriceps femoral. Estas herramientas se hallan en distintas fases de desarrollo pero se encuentran en su mayor parte en proceso de investigación y validación^{37,38}.

La única herramienta que se encuentra en comercialización bajo licencia es PIIXMED™, de la empresa DAWAKO MedTech⁵³. Esta herramienta facilita la extracción de características a partir de imágenes ecográficas convencionales en modo B

(2D), permitiendo obtener valores concretos de distintos parámetros dentro de una región de interés. Con ella se realiza un análisis detallado de la arquitectura morfológica del músculo y se evalúa su calidad basándose en la ecogenicidad y en biomarcadores de la textura de la imagen. Entre las variables medidas se encuentran: variable de cantidad (área y grosor muscular; grosor de la grasa subcutánea) y variables de calidad muscular (ángulo de penación). Por otra parte, el sistema evalúa la distribución de los niveles de gris de la imagen mediante el análisis de la matriz de no uniformidad en niveles de gris. Valores elevados indican mayor heterogeneidad en la distribución de la intensidad, lo que puede reflejar alteraciones en la calidad del tejido muscular. Otro aspecto fundamental es la aplicación de un algoritmo de umbralizado múltiple basado en el histograma de la ecogenicidad y la intensidad de gris. Este algoritmo clasifica los píxeles de la imagen en tres categorías: músculo, grasa, otras estructuras complejas como colágeno, tejido conectivo y fibrosis. Cada uno de estos índices se expresa en porcentaje proporcionando una medida cuantitativa de la calidad muscular a nivel de tejido⁴⁷. Un ejemplo de informe de esta herramienta se puede observar en la figura 3.

La evaluación mediante esta herramienta permite diferenciar la calidad del músculo entre




Figura 3. Diferencias en la cantidad y calidad muscular evaluada mediante una herramienta de inteligencia artificial aplicada a ecografía de músculo recto anterior del cuádriceps. AF: ángulo de fase; FaTi: fat index; Mi: muscle index; NMNF: no muscle, no fat index.

pacientes con deterioro de la función muscular y aquellos que no⁵⁴. Además, esta herramienta permite evaluar los datos de monitorización de pacientes sometidos a suplementación artificial de diferentes tipos^{47,48}.

Tomografía computarizada

La evaluación de la composición corporal mediante TC puede abordarse de dos maneras: a) TC oportunista en la que se aprovechan de una TC realizada por otra indicación clínica. En estos casos, la limitación principal es la imposibilidad de controlar la localización exacta o el momento de adquisición (por ejemplo, si se trata de imágenes sin o con contraste en fases arteriales o venosas). b) TC de composición corporal optimizada en que se realiza un estudio específico, focalizado en una zona determinada y con parámetros prediseñados para evaluar la composición corporal; esta modalidad requiere menos radiación al estar restringida a una región concreta y permite un mayor control en la adquisición de las imágenes, aunque implica un procedimiento adicional y suele limitarse a entornos de investigación¹⁸.

Para reducir la variabilidad en las mediciones, se utiliza el formato DICOM, el cual ofrece imá-

genes con bajo nivel de ruido y permite determinar con precisión la atenuación en unidades Hounsfield (UH)⁵⁵. Esto facilita diferenciar entre tejido adiposo subcutáneo, grasa visceral, tejido muscular y hueso. Existen diversos programas de segmentación, entre los que destacan Slice-O-Matic, Osirix, Image J, Mimics, CoreSlicer, SarcoMeas, 3D Slicer y Aquarius iNtuition. En un estudio de comparación, siete de estos mostraron resultados muy similares en la medición de la masa muscular y grasa, mientras que Aquarius iNtuition presentó un área ligeramente menor (menos del 5 %). Cabe destacar que en estos estudios la segmentación se llevó a cabo de forma manual o semiautomática por expertos⁵⁵. Debido a que las zonas de transición entre tejidos o la identificación de estructuras poco definidas pueden ocasionar errores, es fundamental emplear protocolos de segmentación validados. En el momento actual, las dos herramientas más utilizadas en nuestro medio son CoreSlicer (de uso gratuito en la nube)⁵⁶ y FocusedON de Artis Development (que requiere de licencia para uso)^{38,57}. En la figura 4 se muestra un ejemplo de segmentación con la herramienta FocusedON y con la herramienta CoreSlicer.

La TC a nivel de L3 es la ubicación más empleada para evaluar la composición corporal, ya que




Figura 4. Ejemplos de segmentación automática con la herramienta FocusedON y CoreSlicer.

ofrece datos precisos tanto de la masa muscular como de la grasa. Sin embargo, dado que muchas TC se realizan de manera oportunista, no siempre se obtiene la zona abdominal adecuada. En las TC torácicas, diversos estudios han analizado localizaciones en vértebras como T4 y T12⁵⁸⁻⁶⁰, mientras que otros han sugerido T5, T8 y T10⁶¹. Estas posiciones permiten evaluar de forma eficaz la musculatura —especialmente la paravertebral— y la grasa subcutánea, aunque tienen limitaciones para medir la grasa visceral, salvo cuando se capturan cortes que incluyen la grasa epicárdica. En la figura 5 se muestran las comparativas entre los distintos cortes analizados con la herramienta FocuseDON.

Resonancia magnética

Existen varias herramientas de evaluación de la composición corporal a través de RM, aunque la más avanzada es MuscleMap⁶², una iniciativa colaborativa de código abierto que reúne a investigadores, clínicos y expertos en tecnología para mejorar la cuantificación global de composición corporal mediante RM. La herramienta se fundamenta en la estandarización de protocolos de adquisición de imágenes, permitiendo la creación

de un conjunto de datos mundial con diferentes edades, sexos y etnias. A partir de este repositorio heterogéneo, MuscleMap desarrolla modelos de *deep learning* y algoritmos de segmentación automática que cuantifican parámetros clave de la masa muscular, tales como el área transversal, la infiltración de grasa y otros biomarcadores morfológicos⁶³.

Absorciometría dual de rayos X

En el momento actual no existen herramientas validadas para la reconstrucción de imágenes 3D según imágenes de DEXA. No obstante, existen planteamientos de fusión de datos clásicos derivados de medición de DEXA con algoritmos de aprendizaje automático. Esta herramienta se encuentra disponible como *software* de código abierto⁶⁴.

Este planteamiento automatiza la segmentación de la imagen y utiliza modelos predictivos para estimar parámetros volumétricos y características anatómicas en 3D. Esto podría superar limitaciones inherentes a los escáneres DEXA tradicionales y mejorar la reproducibilidad de las mediciones^{44,45}.




Figura 5. Diferencias en las características de los compartimentos corporales entre el corte en T11 (arriba) y en L3 (abajo) en el mismo paciente.

>>BENEFICIOS, LIMITACIONES Y DESAFIOS

Ventajas de la aplicación de la inteligencia artificial

La automatización en la segmentación de la composición corporal por imagen no solo acelera el proceso de análisis, sino que también estandariza la obtención de datos de cantidad de tejido, facilitando el uso de estos biomarcadores para el diagnóstico y la monitorización del tratamiento médico nutricional⁹. No obstante, aunque los resultados son muy prometedores, se necesita homogeneizar los protocolos de medida para su correcta integración en la práctica clínica cotidiana. La evaluación de estas técnicas apunta a una integración cada vez mayor de la IA en la segmentación de imágenes médicas, fomentando diagnósticos más rápidos, precisos y reproducibles⁴⁶.

Limitaciones técnicas y prácticas

Muchos modelos de IA en composición corporal, al igual que en otras disciplinas como la ecografía tiroidea, muestran un rendimiento prometedor, aunque normalmente enfrentan desafíos para su adopción generalizada. Casi todos los modelos logran una concepción exitosa y una adecuada validez interna; sin embargo, un pequeño porcentaje (alrededor del 25 %) llegan a la fase de prueba de utilidad (validación externa) y apenas el 5 % es adoptado. Esto se debe a que es necesario superar múltiples obstáculos como el uso de datos no representativos, la dependencia de las imágenes estáticas, las variaciones en la calidad de los datos y la falta de validaciones multicéntricas externas. Por último, estas herramientas deben ser validadas por la autoridad competente y tener cierto apoyo económico para poder ser adoptadas en la práctica clínica habitual⁶⁵.

Desafíos éticos y regulatorios

La implantación de la IA en la imagen de la composición corporal conlleva riesgos importantes, como la reproducción de sesgos y la falta de equidad cuando se utiliza un conjunto de datos poco representativo, la dificultad para comprender y justificar los resultados debido a la naturaleza de “caja negra” de algunos modelos, y la necesidad de mecanismos rigurosos de seguridad y anoni-

mización para proteger la privacidad de datos sensibles contenidos en las imágenes⁶⁶.

En el ámbito regulatorio, se plantea la imperiosa necesidad de contar con un marco normativo robusto que incluya una validación clínica estricta, sometiendo a las herramientas a ensayos y estudios multicéntricos para demostrar seguridad, eficacia y capacidad de generalización a distintas poblaciones; por otra parte, requiere de estándares de calidad y auditoría, mediante normativas que obliguen a mantener actualizados los modelos, con auditorías continuas que aseguren la calidad de los datos de entrada, la correcta operación y la capacidad de adaptación a nuevos hallazgos; por último, son necesarias normativas de responsabilidad legal que definan las obligaciones y las responsabilidades en caso de que las decisiones asistidas por IA produzcan consecuencias negativas, similar a la regulación de los dispositivos médicos, y la comunicación clara de los límites y alcances de estas tecnologías⁶⁷.

Perspectivas futuras

El futuro del análisis de la composición corporal por imagen a través de la IA plantea múltiples desafíos en el ámbito clínico. En primer lugar, los algoritmos de *deep learning* pueden evolucionar para automatizar de manera aún más precisa la segmentación y la cuantificación de tejidos, no solo midiendo de forma exacta volúmenes de músculo y grasa, sino también evaluando la calidad del tejido. Esto incluye la detección temprana de infiltración grasa, cambios en la ecogenicidad y variaciones en la densidad, lo que permitirá obtener biomarcadores cualitativos más robustos.

Además, la integración con técnicas radiómicas se perfila como un pilar esencial, ya que, al extraer patrones de textura y estadísticas de las imágenes, se podrán construir modelos predictivos que correlacionen estos biomarcadores con riesgos clínicos, pronósticos y respuesta a tratamientos nutricionales. La fusión de distintas modalidades de imagen podría permitir la generación de modelos tridimensionales integrales.

El aprovechamiento de grandes bases de datos (*big data*) y la recopilación de conjuntos de datos multicéntricos potenciarán la robustez de los modelos permitiendo su validación y generalización en

poblaciones diversas. Paralelamente, el desarrollo de *software* intuitivo y de plataformas interconectadas facilitará el análisis en tiempo real.

>>CONCLUSIONES

La IA en el diagnóstico de la composición corporal es el presente y el futuro de la valoración del estado nutricional. El análisis de las imágenes de composición corporal abre un nuevo horizonte en la nutrición clínica, ofreciendo la posibilidad de automatizar y estandarizar la segmentación de tejidos como el músculo y la grasa. Por otra parte, el análisis de las características cualitativas de la imagen e integrarlas con los parámetros cuantitativos obtenidos en la segmentación permitirá generar nuevos biomarcadores radiómicos. Esto contribuirá a diagnosticar de manera más rápida y precisa condiciones como la desnutrición, la obesidad y la sarcopenia, lo que puede repercutir en una toma de decisiones más personalizada y una monitorización más eficaz del tratamiento.

No obstante, para que su impacto potencial se consolide en la práctica clínica habitual es imprescindible superar desafíos técnicos, en el desarrollo y la validación externa de las herramientas, así como afrontar las limitaciones éticas y regulatorias que aseguren la protección de datos, la equidad y la responsabilidad legal en su utilización.

Como en las visiones literarias y cinematográficas de la ciencia-ficción, donde se analiza el papel de la tecnología en la sociedad, resulta imperativo que el desarrollo y la aplicación de estos sistemas se rijan por principios semejantes a los propuestos en las tres leyes de la robótica de Asimov⁶⁸. Estas leyes —que en esencia proponen que una máquina no debe dañar a un ser humano, debe obedecer las órdenes humanas y proteger su propia existencia en función de la seguridad del primero— nos invitan a estructurar la innovación en IA de forma que siempre prevalezca el bienestar y la seguridad del paciente, transformando la promesa de la tecnología en una realidad clínica segura y equitativa.

>>BIBLIOGRAFÍA

1. Jobim Milanez DS, Razzera EL, Da Silveira Knobloch I, Lima J, Bernardes S, Silva FM. A scoping review on the GLIM criteria for malnutrition diagnosis: Understanding how and for which purpose it has been applied in studies on hospital settings. *Clin Nutr*. 2023;42(1):29-44. DOI: 10.1016/j.clnu.2022.10.022.
2. Cederholm T, Jensen GL, Ballesteros-Pomar MD, Blaauw R, Correia MITD, Cuerda C, et al. Guidance for assessment of the inflammation etiologic criterion for the GLIM diagnosis of malnutrition: A modified Delphi approach. *Clin Nutr*. 2024;43(5):1025-32. DOI: 10.1016/j.clnu.2023.11.026.
3. Cederholm T, Jensen GL, Correia MITD, Gonzalez MC, Fukushima R, Higashiguchi T, et al. GLIM criteria for the diagnosis of malnutrition - A consensus report from the global clinical nutrition community. *Clin Nutr Edinb Scotl*. 2019;38(1):1-9. DOI: 10.1016/j.clnu.2018.08.002.
4. Cruz-Jentoft AJ, Bahat G, Bauer J, Boirie Y, Bruyère O, Cederholm T, et al. Sarcopenia: revised European consensus on definition and diagnosis. *Age Ageing*. 2019;48(1):16-31. DOI: 10.1093/ageing/afy169.
5. Rubino F, Cummings DE, Eckel RH, Cohen RV, Wilding JPH, Brown WA, et al. Definition and diagnostic criteria of clinical obesity. *Lancet Diabetes Endocrinol*. 2025;13(3):221-62. DOI: 10.1016/S2213-8587(24)00316-4.
6. Gazzotti S, Sassi R, Aparisi Gómez MP, Guglielmi R, Vasilevska Nikodinovska V, Messina C, et al. Imaging of body composition. *semin musculoskelet radiol*. 2024;28(05):594-609. DOI: 10.1055/s-0044-1788887.
7. García-Almeida JM, García-García C, Ballesteros-Pomar MD, Oliveira G, López-Gómez JJ, Bellido V, et al. Expert Consensus on Morphofunctional Assessment in Disease-Related Malnutrition. Grade Review and Delphi Study. *Nutrients*. 2023;15(3):612. DOI: 10.3390/nu15030612.
8. Gorelik N, Gyftopoulos S. Applications of artificial intelligence in musculoskeletal imaging: from the request to the report. *Can Assoc Radiol J*. 2021;72(1):45-59. DOI: 10.1177/0846537120947148.
9. Attanasio S, Forte SM, Restante G, Gabelloni M, Guglielmi G, Neri E. Artificial intelligence, radiomics and other horizons in body composition assessment. *Quant Imaging Med Surg*. 2020;10(8):1650-60. DOI: 10.21037/qims.2020.03.10.
10. López-Gómez JJ, Gutiérrez-Lora C, Izaola-Jauregui O, Primo-Martín D, Gómez-Hoyos E, Jiménez-Sahagún R, et al. Real world practice study of the effect of a specific oral nutritional supplement for diabetes mellitus on the morphofunctional assessment and protein energy requirements. *Nutrients*. 2022;14(22):4802. DOI: 10.3390/nu14224802.
11. Vieira FT, Cai Y, Gonzalez MC, Goodpaster BH, Prado CM, Haqq AM. Poor muscle quality: A hidden and detrimental health condition in obesity. *Rev Endocr Metab Disord [Internet]*. 21 de enero de 2025 [citado 31 de enero de 2025]. DOI: 10.1007/s11154-025-09941-0.

12. Barazzoni R, Jensen GL, Correia MITD, Gonzalez MC, Higashiguchi T, Shi HP, et al. Guidance for assessment of the muscle mass phenotypic criterion for the Global Leadership Initiative on Malnutrition (GLIM) diagnosis of malnutrition. *Clin Nutr Edinb Scotl*. 2022;41(6):1425-33. DOI: 10.1016/j.clnu.2022.02.001.
13. Derstine BA, Holcombe SA, Ross BE, Wang NC, Su GL, Wang SC. Skeletal muscle cutoff values for sarcopenia diagnosis using T10 to L5 measurements in a healthy US population. *Sci Rep*. 2018;8(1):11369. DOI: 10.1038/s41598-018-29825-5.
14. Van Der Werf A, Langius JAE, De Van Der Schueren MAE, Nurmohamed SA, Van Der Pant KAMI, Blauwhoff-Buskermolen S, et al. Percentiles for skeletal muscle index, area and radiation attenuation based on computed tomography imaging in a healthy Caucasian population. *Eur J Clin Nutr*. 2018;72(2):288-96. DOI: 10.1038/s41430-017-0034-5.
15. López-Gómez JJ, García-Benítez D, Jiménez-Sahagún R, Izaola-Jauregui O, Primo-Martín D, Ramos-Bachiller B, et al. Nutritional ultrasonography, a method to evaluate muscle mass and quality in morphofunctional assessment of disease related malnutrition. *Nutrients*. 2023;15(18):3923. DOI: 10.3390/nu15183923.
16. De Luis Román D, García Almeida JM, Bellido Guerrero D, Guzmán Rolo G, Martín A, Primo Martín D, et al. Ultrasound cut-off values for rectus femoris for detecting sarcopenia in patients with nutritional risk. *Nutrients*. 2024;16(11):1552. DOI: 10.3390/nu16111552.
17. García-Almeida JM, García-García C, Vegas-Aguilar IM, Ballesteros Pomar MD, Cornejo-Pareja IM, Fernández Medina B, et al. Nutritional ultrasound@: Conceptualisation, technical considerations and standardisation. *Endocrinol Diabetes Nutr*. 2023;70:74-84. DOI: 10.1016/j.endien.2022.11.010.
18. Palmas F, Ciudin A, Guerra R, Eiroa D, Espinet C, Roson N, et al. Comparison of computed tomography and dual-energy X-ray absorptiometry in the evaluation of body composition in patients with obesity. *Front Endocrinol*. 2023;14:1161116. DOI: 10.3389/fendo.2023.1161116.
19. Neagu M, Neagu A. A decade of progress in ultrasound assessments of subcutaneous and total body fat: a scoping review. *Life*. 2025;15(2):236. DOI: 10.3390/life15020236.
20. De Lucia Rolfe E, Sleigh A, Finucane FM, Brage S, Stolk RP, Cooper C, et al. Ultrasound measurements of visceral and subcutaneous abdominal thickness to predict abdominal adiposity among older men and women. *Obes Silver Spring Md*. 2010;18(3):625-31. DOI: 10.1038/oby.2009.309.
21. Greco F, Salgado R, Van Hecke W, Del Buono R, Parizel PM, Mallio CA. Epicardial and pericardial fat analysis on CT images and artificial intelligence: a literature review. *Quant Imaging Med Surg*. 2022;12(3):2075-89. DOI: 10.21037/qims-21-945.
22. Baumann VJA, Banati R, Clarke JL. Ultrasound measurement of perirenal adipose tissue indicates cardiovascular disease, but standardisation is needed: A systematic review. *Australas J Ultrasound Med*. 2025;28(1):e12407. DOI: 10.1002/ajum.12407.
23. García-Díez AI, Porta-Vilaro M, Isern-Kebschull J, Naude N, Guggenberger R, Brugnara L, et al. Myosteatorsis: diagnostic significance and assessment by imaging approaches. *Quant Imaging Med Surg*. 2024;14(11):7937-57. DOI: 10.21037/qims-24-365.
24. Alikhani R, Horbal SR, Rothberg AE, Pai MP. Radiomic-based biomarkers: Transforming age and body composition metrics into personalized age-informed indices. *Clin Transl Sci*. 2024;17(12):e70062. DOI: 10.1111/cts.70062.
25. Higgins MI, Marquardt JP, Master VA, Fintelman FJ, Psutka SP. Machine learning in body composition analysis. *Eur Urol Focus*. 2021;7(4):713-6. DOI: 10.1016/j.euf.2021.03.013.
26. Takahashi N, Sugimoto M, Psutka SP, Chen B, Moynagh MR, Carter RE. Validation study of a new semi-automated software program for CT body composition analysis. *Abdom Radiol*. 2017;42(9):2369-75. DOI: 10.1007/s00261-017-1123-6.
27. Higgins MI, Martini DJ, Patil DH, Steele S, Evans S, Petrinc BP, et al. Quantification of body composition in renal cell carcinoma patients: Comparing computed tomography and magnetic resonance imaging measurements. *Eur J Radiol*. 2020;132:109307. DOI: 10.1016/j.ejrad.2020.109307.
28. Wang B, Torriani M. Artificial Intelligence in the Evaluation of Body Composition. *Semin Musculoskelet Radiol*. 2020;24(01):030-7. DOI: 10.1055/s-0039-3400267.
29. Perez L, Wang J. The effectiveness of data augmentation in image classification using deep learning [Internet]. arXiv; 2017 [citado 25 de marzo de 2025]. Disponible en: <https://arxiv.org/abs/1712.04621>
30. Ronneberger O, Fischer P, Brox T. U-Net: Convolutional networks for biomedical image segmentation. En: Navab N, Hornegger J, Wells WM, Frangi AF, editores. Medical image computing and computer-assisted intervention – MICCAI 2015 [Internet]. Cham: Springer International Publishing; 2015 [citado 25 de marzo de 2025]. p. 234-41. (Lecture Notes in Computer Science; vol. 9351). Disponible en: http://link.springer.com/10.1007/978-3-319-24574-4_28
31. Santhanam P, Nath T, Peng C, Bai H, Zhang H, Ahima RS, et al. Artificial intelligence and body composition. *Diabetes Metab Syndr*. 2023;17(3):102732. DOI: 10.1016/j.dsx.2023.102732.
32. Bedrikovetski S, Seow W, Kroon HM, Traeger L, Moore JW, Sammour T. Artificial intelligence for body composition and sarcopenia evaluation on computed tomography: A systematic review and meta-analysis. *Eur J Radiol* [Internet]. 1 de abril de 2022 [citado 8 de febrero de 2025];149. Disponible en: [https://www.ejradiology.com/article/S0720-048X\(22\)00068-7/fulltext](https://www.ejradiology.com/article/S0720-048X(22)00068-7/fulltext)

33. Onishi S, Kuwahara T, Tajika M, Tanaka T, Yamada K, Shimizu M, et al. Artificial intelligence for body composition assessment focusing on sarcopenia. *Sci Rep*. 2025;15(1):1324. DOI: 10.1038/s41598-024-83401-8.
34. TomoVision. sliceOmatic Alberta Protocol User's Manual Version 5.0 [Internet]. 11/02/20217. Disponible en: https://www.tomovision.com/Sarcopenia_Help/index.htm?id=step_1
35. Lee MH, Liu D, Garrett JW, Perez A, Zea R, Summers RM, et al. Comparing fully automated AI body composition measures derived from thin and thick slice CT image data. *Abdom Radiol N Y*. 2024;49(3):985-96. DOI: 10.1007/s00261-023-04135-1.
36. Cao K, Yeung J, Arafat Y, Wei MYK, Yeung JMC, Baird PN. Identification of differences in body composition measures using 3d-derived artificial intelligence from multiple CT scans across the L3 vertebra compared to a single mid-point L3 CT scan. *Radiol Res Pract*. 2023;2023:1047314. DOI: 10.1155/2023/1047314.
37. García-Herreros S, López Gómez JJ, Cebria A, Izaola O, Salvador Coloma P, Nozal S, et al. Validation of an artificial intelligence-based ultrasound imaging system for quantifying muscle architecture parameters of the rectus femoris in Disease-Related Malnutrition (DRM). *Nutrients*. 2024;16(12):1806. DOI: 10.3390/nu16121806.
38. Palmas F, Mucarz F, Ricart M, Lluch A, Zabalegui A, Melian J, et al. Body composition assessment with ultrasound muscle measurement: optimization through the use of semi-automated tools in colorectal cancer. *Front Nutr*. 2024;11:1372816. DOI: 10.3389/fnut.2024.1372816.
39. Zilka T, Benesova W. Radiomics of pituitary adenoma using computer vision: a review. *Med Biol Eng Comput*. 2024;62(12):3581-97. DOI: 10.1007/s11517-024-03163-3.
40. Podinã N, Gheorghe EC, Constantin A, Cazacu I, Croitoru V, Gheorghe C, et al. Artificial intelligence in pancreatic imaging: A systematic review. *United Eur Gastroenterol J*. 2025;13(1):55-77. DOI: 10.1002/ueg2.12723.
41. Decharatanachart P, Chaiteerakij R, Tiyyarattanachai T, Treeprasertsuk S. Application of artificial intelligence in chronic liver diseases: a systematic review and meta-analysis. *BMC Gastroenterol*. 2021;21(1):10. DOI: 10.1186/s12876-020-01585-5.
42. Zhao Q, Lan Y, Yin X, Wang K. Image-based AI diagnostic performance for fatty liver: a systematic review and meta-analysis. *BMC Med Imaging*. 2023;23(1):208. DOI: 10.1186/s12880-023-01172-6.
43. Winder C, Clark M, Frood R, Smith L, Bulpitt A, Cook G, et al. Automated extraction of body composition metrics from abdominal CT or MR imaging: A scoping review. *Eur J Radiol*. 2024;181:111764. DOI: 10.1016/j.ejrad.2024.111764.
44. Shepherd JA, Ng BK, Fan B, Schwartz AV, Cawthon P, Cummings SR, et al. Modeling the shape and composition of the human body using dual energy X-ray absorptiometry images. *PloS One*. 2017;12(4):e0175857. DOI: 10.1371/journal.pone.0175857.
45. Leong L, Wong M, Liu YE, Kelly NN, Piazza M, Garry S, et al. Creating accurate representations of DXA scans from 3D optical body surface scans for arbitrary regional body composition analysis. En: *Proceedings of 3DBODYTECH 2021 - 12th International Conference and Exhibition on 3D Body Scanning and Processing Technologies*, Lugano, Switzerland, 19-20 October 2021 [Internet]. Lugano, Switzerland: Hometrica Consulting - Dr. Nicola D'Apuzzo; 2021 [citado 6 de abril de 2025]. Disponible en: <https://proc.3dbody.tech/abstracts/2021/2135leong.html>
46. Greco F, Mallio CA. Artificial intelligence and abdominal adipose tissue analysis: a literature review. *Quant Imaging Med Surg*. 2021;11(10):4461-74. DOI: 10.21037/qims-21-370.
47. López-Gómez JJ, Primo-Martín D, Cebria A, Izaola-Jauregui O, Godoy EJ, Pérez-López P, et al. Effectiveness of high-protein energy-dense oral supplements on patients with malnutrition using morphofunctional assessment with ai-assisted muscle ultrasonography: A real-world one-arm study. *Nutrients*. 2024;16(18):3136. DOI: 10.3390/nu16183136.
48. De Luis D, Cebria A, Primo D, Nozal S, Izaola O, Godoy EJ, et al. Impact of hydroxy-methyl-butyrates supplementation on malnourished patients assessed using ai-enhanced ultrasound imaging. *J Cachexia Sarcopenia Muscle*. 2025;16(1):e13700. DOI: 10.1002/jcsm.13700.
49. Elhakim T, Trinh K, Mansur A, Bridge C, Daye D. Role of machine learning-based CT body composition in risk prediction and prognostication: Current state and future directions. *Diagnostics*. 2023;13(5):968. DOI: 10.3390/diagnostics13050968.
50. Nachit M, Horsmans Y, Summers RM, Leclercq IA, Pickhardt PJ. AI-based CT body composition identifies myosteatosis as key mortality predictor in asymptomatic adults. *Radiology*. 2023;307(5):e222008. DOI: 10.1148/radiol.222008.
51. Zambrano Chaves JM, Lenchik L, Gallegos IO, Blankemeier L, Rubin DL, Willis MH, et al. Abdominal CT metrics in 17,646 patients reveal associations between myopenia, myosteatosis, and medical phenotypes: a phenome-wide association study. *eBioMedicine*. 2024;103:105116. DOI: 10.1016/j.ebiom.2024.105116.
52. Bates DDB, Pickhardt PJ. CT-Derived body composition assessment as a prognostic tool in oncologic patients: From opportunistic research to artificial intelligence-based clinical implementation. *Am J Roentgenol*. 2022;219(4):671-80. DOI: 10.2214/AJR.22.27749.
53. Dawako Medtech [Internet]. [citado 6 de abril de 2025]. Disponible en: https://dawako.es/es/tecnologia/piixmed_es
54. González Gutiérrez J, López Gómez JJ, Izaola Jauregui O, Pérez López P, Primo Martín D, Jiménez Sahagún R, et al. Papel de la ecografía muscular asistida por inteligencia artificial en la valoración de la calidad muscular en pacientes en riesgo de desnutrición. *Salamanca*; 2024.

55. Viddeleer AR, Vedder IR, Dob R, Bokkers RPH. Objective comparison of commonly used computed tomography body composition analysis software. *Nutr Burbank Los Angel Cty Calif*. 2024;123:112421. DOI: 10.1016/j.nut.2024.112421.
56. Mullie L, Afilalo J. CoreSlicer: a web toolkit for analytic morphomics. *BMC Med Imaging*. 2019;19(1):15. DOI: 10.1186/s12880-019-0316-6.
57. De Luis Román D, López Gómez JJ, Muñoz M, Primo D, Izaola O, Sánchez I. Evaluation of muscle mass and malnutrition in patients with colorectal cancer using the global leadership initiative on malnutrition criteria and comparing bioelectrical impedance analysis and computed tomography measurements. *Nutrients*. 2024;16(17):3035. DOI: 10.3390/nu16173035.
58. Hata A, Muraguchi Y, Nakatsugawa M, Wang X, Song J, Wada N, et al. Automated chest CT three-dimensional quantification of body composition: adipose tissue and paravertebral muscle. *Sci Rep*. 2024;14(1):32117. DOI: 10.1038/s41598-024-83897-0.
59. Ying T, Borrelli P, Edenbrandt L, Enqvist O, Kaboteh R, Trägårdh E, et al. AI-based fully automatic image analysis: Optimal abdominal and thoracic segmentation volumes for estimating total muscle volume on computed tomography scans. *Osteoporos Sarcopenia*. 2024;10(2):78-83. DOI: 10.1016/j.afos.2024.04.001.
60. Fernández-Jiménez R, Sanmartín-Sánchez A, Cabrera-César E, Espíldora-Hernández F, Vegas-Aguilar I, Amaya-Campos MDM, et al. IA-body composition CT at T12 in idiopathic pulmonary fibrosis: Diagnosing sarcopenia and correlating with other morphofunctional assessment techniques. *Nutrients*. 2024;16(17):2885. DOI: 10.3390/nu16172885.
61. Bridge CP, Best TD, Wrobel MM, Marquardt JP, Magudia K, Javidan C, et al. A Fully automated deep learning pipeline for multi-vertebral level quantification and characterization of muscle and adipose tissue on chest CT Scans. *Radiol Artif Intell*. 2022;4(1):e210080. DOI: 10.1148/ryai.210080.
62. Weber K. Muscle map [Internet]. 2025. Disponible en: <https://github.com/MuscleMap/MuscleMap>
63. McKay MJ, Weber KA, Wesselink EO, Smith ZA, Abbott R, Anderson DB, et al. MuscleMap: An open-source, community-supported consortium for whole-body quantitative MRI of muscle. *J Imaging*. 2024;10(11):262. DOI: 10.3390/jimaging10110262.
64. Leong L, Shepherd JA. Pseudo-DXA: Generative medical imaging model producing real DXA scans from 3D body surface scan inputs [Internet]. Disponible en: <https://github.com/LambertLeong/Pseudo-DXA>
65. Toro-Tobon D, Llor-Torres R, Duran M, Fan JW, Singh Ospina N, Wu Y, et al. Artificial intelligence in thyroidology: A narrative review of the current applications, associated challenges, and future directions. *Thyroid®*. 2023;33(8):903-17. DOI: 10.1089/thy.2023.0132.
66. Sumner C, Kietzman A, Kadom N, Frigini A, Makary MS, Martin A, et al. Medical malpractice and diagnostic radiology: Challenges and opportunities. *Acad Radiol*. 2024;31(1):233-41. DOI: 10.1016/j.acra.2023.08.015.
67. Elendu C, Amaechi DC, Elendu TC, Jingwa KA, Okoye OK, John Okah M, et al. Ethical implications of AI and robotics in healthcare: A review. *Medicine (Baltimore)*. 2023;102(50):e36671. DOI: 10.1097/MD.00000000000036671.
68. Asimov I. *I, Robot*. Nueva York: Gnome Press; 1950.