



Estimación del porcentaje de grasa corporal del torso humano en varones empleando visión artificial con Transferencia de aprendizaje

Anteproyecto de investigación

Autor:

Santiago Gómez Barbosa
sgomez8@eafit.edu.co

Director:

Lina María Sepúlveda Cano
lmsepulvec@eafit.edu.co
PhD en Ingeniería: línea de automatización

Maestría en Ciencia de los Datos y Analítica
Universidad EAFIT
Medellín
2024

Resumen

La estimación del porcentaje de grasa corporal es una tarea determinante en el ámbito de la salud humana y del deporte toda vez que es necesario medir la grasa corporal para evaluar el riesgo de enfermedades crónicas y diseñar estrategias efectivas de prevención y tratamiento (Nimptsch, Königorski, & Pischon, 2019). Tradicionalmente, esta tarea se ha realizado mediante métodos antropométricos, como inferir el nivel de grasa a partir del índice de masa corporal *IMC* o desde la circunferencia de la cintura o brazos. Sin embargo, el primer método resulta ser impreciso y los otros son lentos al requerir la toma de medidas corporales. En los últimos años, la visión artificial se ha convertido en una herramienta prometedora para la estimación del nivel de grasa corporal. (Fernández, Dórea, & Valente, 2020). Los métodos de visión artificial pueden extraer características del cuerpo humano a partir de imágenes, como el perímetro abdominal, la circunferencia del brazo o la relación cintura-cadera. Estas características pueden luego utilizarse para predecir el nivel de grasa corporal.

En virtud de ello, con este proyecto se propone un método de visión artificial para la estimación del nivel de grasa corporal en varones de manera no invasiva. El método se basa en el uso de redes neuronales convolucionales (CNN - *Convolutional Neural Network*) para la extracción de características; pero no se limita a las CNN clásicas, sino que propone reentrenar capas de redes neuronales de uso público transfiriendo su aprendizaje (*Transfer Learning*), para así aprovechar la potencia paramétrica de redes preentrenadas. El método se evaluó con un conjunto de imágenes de varones con diferentes niveles de grasa corporal. Los resultados se contrastaron con respecto al criterio de expertos que usan medidas antropométricas.

Palabras clave: porcentaje de grasa corporal, visión artificial, Transferencia de aprendizaje, redes convolucionales.

1. PLANTEAMIENTO DEL PROBLEMA

La evaluación precisa del porcentaje de grasa corporal en individuos masculinos representa un desafío significativo en las disciplinas de la medicina, la antropología física y el deporte. (Pineau & Bouslah, 2020). Métodos antropométricos tradicionales, como la bioimpedancia eléctrica y el plicómetro, aunque ampliamente utilizados, adolecen de limitaciones en términos de precisión, reproducibilidad y factibilidad, especialmente en entornos no clínicos (Boughman, Masters, Morgan, Ruden, & Rochelle, 2019). Estas metodologías pueden verse afectadas por variables intrínsecas del sujeto, como la hidratación, la distribución de masa muscular y factores ambientales. (Lubis, 2018) En este contexto, surge la necesidad de explorar técnicas avanzadas que puedan proporcionar estimaciones más precisas y confiables del porcentaje de grasa corporal.

En consecuencia, la Inteligencia Artificial (IA) –específicamente el aprendizaje profundo y la visión artificial– ofrece una perspectiva prometedora para abordar esta problemática. Las CNN, un tipo de arquitectura de aprendizaje profundo, han demostrado su eficacia en el procesamiento de imágenes médicas (Zeng, 2019). Sin embargo, la adaptación de estas tecnologías para estimar con precisión la composición corporal, particularmente el porcentaje de grasa corporal en el torso masculino, aún no se ha explorado en profundidad. Este proyecto propone el desarrollo de un modelo convolucional diseñado para analizar imágenes del torso de varones y estimar su porcentaje de grasa. Este enfoque innovador busca superar las limitaciones de los métodos tradicionales y proporcionar una herramienta no invasiva, precisa y de fácil aplicación para profesionales en los campos de la salud, el deporte y la investigación antropométrica.

Además, la construcción de una base de datos robusta y diversa, que incluya imágenes de torsos masculinos con variados niveles de grasa corporal, es fundamental para el entrenamiento y validación del modelo propuesto. La implementación de este modelo con IA tiene el potencial de revolucionar la forma en que se evalúa la composición corporal, ofreciendo una alternativa viable y eficiente a los métodos convencionales. Este proyecto, por lo tanto, se sitúa en la intersección de la medicina, la antropología y la IA, buscando contribuir significativamente en la precisión y practicidad de la evaluación de la grasa corporal.

2. JUSTIFICACIÓN

La estimación precisa del porcentaje de grasa corporal en el torso humano –particularmente la diferenciación entre grasa visceral y subcutánea– es un desafío presente en múltiples disciplinas, incluyendo la medicina, la antropología física y el deporte. La grasa visceral está vinculada a numerosas enfermedades metabólicas y cardiovasculares, mientras que la grasa subcutánea, aunque menos riesgosa, influye significativamente en el rendimiento atlético y la percepción estética. La capacidad de medir estas variables de forma rápida y confiable, en una base diaria, es necesaria para una gestión efectiva de la salud y el rendimiento físico.

En este contexto, el uso de tecnologías avanzadas de IA ofrece una oportunidad única para superar las limitaciones de las técnicas antropométricas tradicionales toda vez que es una técnica no invasiva. Aun cuando las CNN clásicas no están óptimamente parametrizadas para capturar la complejidad y especificidad de las texturas y relieves propias de la grasa corporal humana; las capas reentrenadas permitirían una focalización más precisa en áreas críticas, como la diferenciación entre grasa visceral y subcutánea, mejorando así la precisión del análisis.

Por otro lado, la Transferencia de Aprendizaje (*Transfer Learning*) proporciona una ayuda para potenciar modelos de IA empíricos. En concreto, al utilizar modelos preentrenados, se puede acelerar significativamente el proceso de entrenamiento y adaptación a la tarea específica de identificar y cuantificar el porcentaje de grasa corporal. Esta estrategia es particularmente beneficiosa en contextos donde la disponibilidad de datos etiquetados es limitada.

En el ámbito deportivo, la relevancia de esta investigación es particularmente prominente. La composición corporal influye el rendimiento atlético, y la capacidad de monitorizar cambios sutiles en la grasa corporal puede ser decisiva en la optimización de regímenes de entrenamiento y nutrición. Además, una evaluación precisa y continua de esta grasa proporciona una herramienta invaluable para la prevención de lesiones, la recuperación y la gestión del peso de los atletas.

En suma, un modelo artificial inteligente que incorpore CNN avanzadas aporta a una necesidad médica; al tiempo que hace parte de la innovación en el campo del deporte. Esta óptica promete un impacto positivo en el manejo eficaz de la salud, la prevención de enfermedades y la mejora del rendimiento deportivo: ofreciendo una metodología no invasiva, precisa y aplicable en una variedad de contextos.

3. OBJETIVOS

3.1. Objetivo general

Desarrollar un modelo de visión artificial para la estimación del porcentaje de grasa corporal en el torso de varones.

3.2. Objetivos específicos

- Construir un conjunto de datos de imágenes del torso de varones que tengan diferentes niveles de grasa corporal.
- A partir del conjunto construido, extraer las características de imagen correspondientes a los niveles de grasa corporal entrenando redes convolucionales con Transferencia de aprendizaje
- Contrastar el rendimiento de las arquitecturas neuronales entrenadas.

4. MARCO TEÓRICO

4.1. Fisiología de la grasa corporal en varones

En principio, la distribución de la grasa corporal entre los géneros humanos ha sido objeto de exhaustivos análisis dentro de la comunidad científica. Según una serie de investigaciones recientes, la distribución de la grasa difiere de manera significativa entre hombres y mujeres (Smith, y otros, 2004). En términos generales, se ha observado que los varones tienden a presentar una mayor acumulación de tejido adiposo en regiones como el tronco, los hombros y la región dorsal, mientras que las mujeres exhiben una proporción más elevada de grasa en áreas como las caderas, los muslos y los glúteos (Oliva, y otros, 2020). Esto es conocido como dimorfismo sexual en la distribución de la grasa corporal y ha sido objeto de diversas investigaciones que buscan comprender las bases biológicas y fisiológicas que subyacen a estas diferencias. Factores como las hormonas sexuales, la genética y el estilo de vida se han identificado como determinantes clave en la distribución diferencial de la grasa entre los géneros (Camacho, Alcalá, & Nieves, 2015). Además, se ha observado que las disparidades en la distribución de la grasa corporal entre diferentes individuos no solo son un fenómeno visible, sino que también pueden tener implicaciones profundas y significativas para la salud general. La forma en que la grasa se acumula en el cuerpo no es un proceso aleatorio, sino que está influenciado por una combinación de factores genéticos, hormonales y ambientales, los cuales varían de una persona a otra. Estos patrones de acumulación de grasa no son meramente estéticos, sino que tienen una relación directa con la predisposición a una serie de condiciones de salud graves.

Particularmente, ciertos patrones de distribución de grasa han sido estrechamente asociados con un mayor riesgo de desarrollar enfermedades metabólicas, como la diabetes tipo 2, así como trastornos cardiovasculares, que son una de las principales causas de mortalidad a nivel global (Travieso, 2016).

En consecuencia, el estudio del dimorfismo sexual en la distribución de la grasa corporal no solo contribuye al entendimiento de las diferencias biológicas entre hombres y mujeres, sino que también puede tener importantes implicaciones clínicas en el ámbito de la salud pública y la medicina preventiva. Este fenómeno de dimorfismo sexual en la distribución de la grasa corporal ha sido ampliamente documentado en la literatura científica (Royo, Bes-Rastrollo, Bosqued, Burgos, & Castello, 2017). Se ha sugerido que estas diferencias pueden estar influenciadas por factores hormonales, genéticos y ambientales. Por ejemplo, se ha demostrado que las hormonas sexuales como la testosterona y el estrógeno desempeñan un papel crucial en la distribución de la grasa en el cuerpo humano (Zhou, 2022). De hecho, múltiples estudios epidemiológicos han encontrado asociaciones entre la distribución de la grasa corporal y el riesgo de desarrollar ciertas enfermedades crónicas, como la diabetes tipo 2 y las enfermedades cardiovasculares (Marcel, García, & Rodríguez, 2016). Por lo tanto, comprender los mecanismos subyacentes al dimorfismo sexual en la distribución de la grasa corporal es de suma importancia para el desarrollo de

estrategias efectivas de prevención y tratamiento de estas enfermedades.

A nivel molecular, se ha demostrado que las diferencias en la distribución de la grasa entre hombres y mujeres pueden estar relacionadas con la expresión de genes específicos involucrados en el metabolismo de los lípidos. (Guo & Zhang, 2017) Estudios de asociación del genoma completo han identificado varios loci genéticos asociados con la distribución de la grasa corporal

en diferentes regiones del cuerpo. Estos hallazgos sugieren que la genética juega un papel importante en la determinación de la distribución de la grasa corporal y que las diferencias observadas entre hombres y mujeres pueden estar influenciadas en parte por variaciones en estos genes (Scher-Nemirovsky, Ruiz, & Mendivil, 2019). Investigaciones recientes sugieren que, además de los determinantes genéticos, los factores ambientales ejercen una influencia significativa en la distribución de la grasa corporal, indica que la dieta y el nivel de actividad física son variables de importancia a considerar. Se ha establecido que una ingesta elevada de grasas saturadas puede propiciar una mayor acumulación de tejido adiposo en la región abdominal. Este fenómeno se ha corroborado en varios estudios clínicos y experimentales (Barceló, Borroto, & Rodríguez, 2002)

Por otra parte, la actividad física regular emerge como un factor clave en la regulación del tejido adiposo. Se evidencia que el ejercicio físico regular conlleva a una reducción de la grasa corporal total, además de favorecer una distribución más favorable de la misma. Este efecto se atribuye a diversos mecanismos fisiológicos, incluyendo el aumento del gasto energético y la estimulación del metabolismo de las grasas (Kolnes, 2021). La grasa corporal tiene importantes funciones fisiológicas, incluyendo:

- Protección de los órganos internos. La grasa corporal actúa como amortiguador mecánico que protege los órganos internos de posibles lesiones. Investigaciones recientes han revelado la importancia de este mecanismo de protección, subrayando su papel en la preservación de la integridad anatómica frente a impactos y traumas externos. Estudios biomecánicos han demostrado que la distribución estratégica de la grasa alrededor de los órganos vitales, como el corazón, los riñones y el hígado, actúa como un escudo dinámico que absorbe y disipa la energía cinética, reduciendo así el riesgo de lesiones contundentes (Sabbatini & Kararigas, 2020).
- Regulación de la temperatura. La grasa corporal desempeña un papel fundamental en la regulación de la temperatura corporal, facilitando la conservación del calor endógeno y la termogénesis adaptativa en respuesta a cambios ambientales. Investigaciones recientes han revelado la complejidad de este proceso, que implica una interacción dinámica entre diversos tejidos y sistemas fisiológicos (Betz & Enerbäck, 2018). Estudios metabólicos han demostrado que la grasa parda, en particular, juega un papel crucial en la termogénesis adaptativa al activar la oxidación de ácidos grasos y la generación de calor en respuesta a estímulos fríos. Además, la grasa subcutánea actúa como un aislante térmico que reduce la pérdida de calor a través de la piel, preservando así la temperatura corporal central en condiciones de exposición al frío.
- Almacenamiento de energía. La grasa corporal sirve como una reserva de energía altamente eficiente, almacenando calorías en forma de lípidos que pueden ser utilizados por el organismo

durante períodos de necesidad metabólica elevada o restricción calórica. Este proceso implica una regulación precisa de la síntesis y la degradación de lípidos en tejidos adiposos y no adiposos. Estudios bioquímicos han identificado mecanismos moleculares clave involucrados en el almacenamiento y la movilización de lípidos, incluyendo la lipólisis, la lipogénesis y la adipogénesis, que coordinan el equilibrio energético del organismo en respuesta a señales nutricionales y metabólicas (Moreno & Martinez, 2002). Además, la grasa visceral ha sido identificada como una reserva de energía especialmente activa, liberando ácidos grasos libres y adipocinas en la circulación sanguínea para su utilización por otros tejidos y órganos

- Producción de hormonas. También, la grasa corporal actúa en la producción y secreción de hormonas que regulan una amplia gama de procesos fisiológicos, incluyendo el metabolismo, el sistema inmune y la reproducción. Investigaciones recientes han identificado una variedad de adipocinas y mediadores metabólicos secretados por los adipocitos y células del estroma adiposo, que actúan como señales endocrinas y paracrinas en el tejido adiposo y en otros órganos y tejidos. Estudios hormonales han demostrado que la grasa visceral, en particular, es una fuente significativa de adipocinas proinflamatorias y factores de crecimiento, que pueden modular la función metabólica y la respuesta inmune del organismo (Ali & Massa, 2021). Además, la grasa subcutánea también secreta una variedad de hormonas y péptidos bioactivos, como la leptina y la adiponectina, que regulan la ingesta de alimentos, el gasto energético y la sensibilidad a la insulina.


En última instancia, a pesar de estas funciones fisiológicas esenciales, el exceso de grasa corporal puede aumentar el riesgo de desarrollar patologías crónicas, como enfermedades cardiovasculares, diabetes e incluso cáncer, como se ha demostrado en numerosos estudios epidemiológicos (Tramunt, y otros, 2020). Estos hallazgos subrayan la importancia de mantener un equilibrio adecuado de grasa corporal para preservar la salud y el bienestar a largo plazo del organismo.

4.1.1. Más allá del IMC

En la **Figura 1** se propone la denominación de "sobregreso" en lugar de "sobrepeso" con el fin de reflejar con mayor precisión la condición metabólica asociada al exceso de grasa en relación con el tejido muscular. Esta epidemia de "sobregresos" plantea desafíos significativos para la salud pública, ya que muchas personas con este perfil no son clasificadas adecuadamente mediante el IMC, que subestima los niveles de adiposidad y no considera el tejido muscular. La prevalencia de "sobregresos" puede ser aún mayor de lo que se estima actualmente, dado que el IMC no refleja adecuadamente la composición corporal, especialmente en términos de calidad, funcionalidad y distribución del tejido adiposo y muscular. Esta subestimación conlleva dificultades en el diagnóstico y tratamiento de enfermedades relacionadas con el exceso de grasa, así como la posible clasificación errónea de personas saludables como obesas o con sobrepeso (Tobias, Pan, Jackson,

Ding, & Willett, 2004).

Figura 1. Clasificación de patologías de peso según el IMC



Fuente: (NetMD, 2024)

Múltiples estudios han demostrado que una proporción significativa de individuos considerados sanos según su IMC muestran problemas metabólicos, mientras que atletas con altos niveles de masa muscular pueden ser erróneamente clasificados como obesos (Álvarez, Sangiao, Brandón, & Cordido, 2011). La disfunción endocrina asociada con el exceso de grasa corporal puede desencadenar una cascada de efectos adversos, incluyendo inflamación y enfermedades crónicas como la diabetes tipo 2, enfermedades cardiovasculares, cáncer y Alzheimer.


Por otro lado, la pérdida de tejido adiposo y sus funciones metabólicas también representa un riesgo para la salud, especialmente en condiciones de desnutrición o lipodistrofia, como la caquexia asociada con diversas enfermedades del siglo XXI. En este sentido, la denominación de "sobregreso" destaca la importancia de considerar no solo la cantidad, sino también la calidad y funcionalidad de los tejidos corporales al abordar problemas de obesidad y sarcobesidad (Frigolet & Gutiérrez, 2020). La grasa corporal en el torso de los varones es, predominantemente, abdominal; la grasa abdominal se divide en dos tipos: grasa visceral y grasa subcutánea. La grasa visceral se encuentra entre los órganos internos del abdomen. Es el tipo de grasa más peligroso, ya que se asocia con un mayor riesgo de enfermedades crónicas y rodea los órganos internos y dificultar su funcionamiento. También, puede liberar sustancias inflamatorias que dañan los tejidos. En contraste, la grasa subcutánea se encuentra debajo de la piel. Es menos peligrosa que la grasa visceral, pero aun así puede aumentar el riesgo de enfermedades crónicas. La grasa subcutánea puede presionar los órganos internos y dificultar su funcionamiento.

4.1.2. Medidas antropométricas varoniles

La **Figura 2** contiene un avatar representativo de las medidas de grasa corporal que se usarán en este proyecto. El avatar representa un sujeto varón sano (sin obesidad ni asimetrías congénitas) con medidas de circunferencia estándar representadas por líneas negras continuas:

- *Cuello*: circunferencia en el punto medio del cuello, sobre la laringe.
- *Pecho*: en los varones, circunferencia en el punto interno de los omóplatos; en las mujeres, se toma en el punto que sobresale más hacia delante por encima de la cintura.
- *Cintura*: perímetro en la parte baja de la espalda, entre la costilla inferior y la parte superior de la cresta ilíaca.
- *Cadera*: perímetro en el punto que sobresale más por debajo de la cintura.
- *Bíceps*: perímetro máximo del brazo entre el hombro y el codo.
- *Miembros anteriores*: perímetro máximo del brazo entre el codo y la muñeca.

Figura 2. Avatar representativo de grasa corporal de un varón sano



Fuente: dispositivo *Fit3D ProScanner 5.5.0*, versión 5.0.6; San Mateo, CA. (Minetto, y otros, 2022)

En contraste, la **Figura 3** (izquierda) corresponde a un escaneo tridimensional de varón con obesidad: índice de masa corporal: 34.2 kg/m^2 con perímetro de cintura aumentado: 123 cm.

Figura 3. Avatar de grasa corporal de un varón con obesidad (izquierda) y asimetría congénita (derecha)



Fuente: (Minetto, y otros, 2022)

A la derecha de la figura se representa a un paciente varón con asimetrías congénitas de la

circunferencia entre extremidades exacerbadas tras una inmovilización unilateral prolongada de las extremidades superiores e inferiores izquierdas: bíceps derecho-izquierdo: 39.3-33.7 cm; antebrazo derecho-izquierdo: 31.7-28.3 cm; muslo derecho-izquierdo: 63.1-57.8 cm; pantorrilla derecha-izquierda: 40.9-36.3 cm.

4.1.3. Grasa visceral en el torso masculino

En los hombres, la grasa corporal se acumula predominantemente en el tronco, los hombros y la espalda, mientras que en las mujeres se concentra más en las caderas, los muslos y los glúteos. Esta diferencia en la distribución tiene implicaciones significativas para la salud y la estética. En particular, la grasa visceral, que rodea los órganos internos en el abdomen, se asocia con un mayor riesgo de desarrollar enfermedades crónicas como la diabetes tipo 2 y enfermedades cardiovasculares debido a su alta actividad metabólica y la liberación de sustancias inflamatorias. Por otro lado, la grasa subcutánea, situada debajo de la piel, aunque menos peligrosa que la visceral, también puede contribuir al riesgo de enfermedades metabólicas y cardiovasculares si se acumula en exceso.

Según Després *et al* (2008), la variación en la distribución de la grasa corporal entre individuos está influenciada por factores como la genética, el estilo de vida y la composición corporal general. Además, la distribución de la grasa es un indicador importante de la función metabólica y el riesgo de enfermedades, independientemente del IMC. Por ejemplo, personas con mayor cantidad de grasa visceral tienen un mayor riesgo de resistencia a la insulina y otras anomalías metabólicas, incluso si su IMC es considerado saludable.

En efecto, la grasa visceral, localizada en la región abdominal y rodeando los órganos internos, secreta sustancias inflamatorias que pueden desencadenar procesos adversos, aumentando así el riesgo de estas enfermedades. En contraste, la grasa subcutánea, aunque tradicionalmente considerada menos perjudicial, también puede tener consecuencias adversas para la salud si se acumula en exceso. Esta grasa, localizada debajo de la piel, puede ejercer presión sobre los órganos internos y comprometer su funcionalidad, lo que subraya la importancia de abordar tanto la cantidad como la distribución de la grasa corporal al evaluar el riesgo de enfermedades crónicas.

4.2. Clasificación de imágenes digitales

4.2.1. Imagen digital


Es inherente al ser humano la utilización de imágenes como herramienta para registrar su historia. Desde tiempos ancestrales, las representaciones visuales de objetos y situaciones han sido cruciales para el avance y la evolución de la sociedad, facilitando el desarrollo de productos, servicios y habilidades. Desde las pinturas en cuevas hasta las imágenes digitalmente procesadas,

este medio ha desempeñado un papel fundamental en la transmisión y preservación del conocimiento humano a lo largo de los milenios (Wilhelm & Fuson, 2014).

En la era contemporánea, se han integrado las innovaciones tecnológicas al tratamiento de imágenes, resultando en la existencia de dos modalidades distintas: las imágenes análogas, percibidas por el sistema visual de los seres vivos, que abarcan desde paisajes naturales hasta composiciones artísticas sobre diferentes sustratos, influenciadas por la luz ambiente; y las imágenes digitales, representadas como archivos electrónicos mediante un modelo matemático binario (Melo, 2009). Estas imágenes digitalizadas se componen de unidades gráficas denominadas píxeles, organizadas en una matriz que define la forma y la gama de colores. Cada píxel encapsula la información necesaria para construir la entidad visual que se desea representar, incluyendo detalles de color e intensidades lumínicas, usualmente imperceptibles para la percepción humana debido a su diminuto tamaño, pero detectables mediante dispositivos electrónicos como pantallas de matrices de LED. (Wilhelm & Fuson, 2014)

El término "píxel" corresponde a un elemento de imagen, y cada uno de estos elementos comparte características similares, aunque contiene información específica dependiendo de los requisitos en cuestión. En la **Figura 4** se expone cómo la disposición espacial de los píxeles se logra a través de coordenadas cartesianas, asignando posiciones en un plano definido por columnas (eje X) y filas (eje Y). La codificación en cada píxel se representa mediante impulsos eléctricos conocidos como bits, los cuales se procesan utilizando el sistema binario, donde el valor 0 indica la ausencia de un impulso eléctrico, mientras que el valor 1 indica su presencia. (Heredia, Martínez, Quintero, Piñeros, & Chuvieco, 2003) (Portiansky, 2013)

Figura 4. Disposición espacial de los píxeles y su valor de intensidad




Fuente: Portiansky (2013)

En el estudio del color de una imagen a nivel de píxeles, se establece una distinción entre los monocromáticos y los policromáticos. Estos últimos, mediante la aplicación de técnicas de polarización de la luz, generan una gama de colores con el fin de hacerla perceptible para el ojo humano (Gibson, Padgett, & Matthew, 2019).

La percepción de los colores a través de la retina es el resultado de una combinación de frecuencias lumínicas, basadas en los colores primarios o aditivos, como el rojo, el azul y el verde (**Figura 5**). Asimismo, entran en juego los colores secundarios o sustractivos, como el cian, el magenta y el amarillo, en este proceso de síntesis cromática. Estos sistemas de colores primarios y secundarios, conocidos respectivamente como RGB y CMYK, encuentran representación gráfica que facilita su comprensión visual (Acevedo, Serra, & Rendtorff, 2012).

Figura 5. Sistema de colores RGB y CMY



Fuente: (Summersby, 2022)

4.2.2. Procesamiento digital de imagen

En el contexto contemporáneo, el uso de imágenes digitales desempeña un papel fundamental en diversas áreas, desde el entretenimiento hasta aplicaciones en campos tan diversos como la medicina, las finanzas y la seguridad. Sin embargo, para aplicar eficazmente el potencial de las imágenes digitales en cada contexto específico, es necesario someter el archivo de imagen a un proceso de tratamiento que lo adapte a las necesidades particulares de cada aplicación. El procesamiento de imágenes involucra la manipulación de la información contenida en los píxeles de la imagen con el objetivo de mejorarla o extraer información relevante (Concha & Palomino, 2009). En el ámbito del procesamiento de imágenes digitales, se emplean diversas técnicas que no implican la pérdida de píxeles, sino más bien su redistribución o modificación mediante algoritmos específicos diseñados para lograr el efecto deseado. Las etapas fundamentales del procesamiento de imágenes comprenden

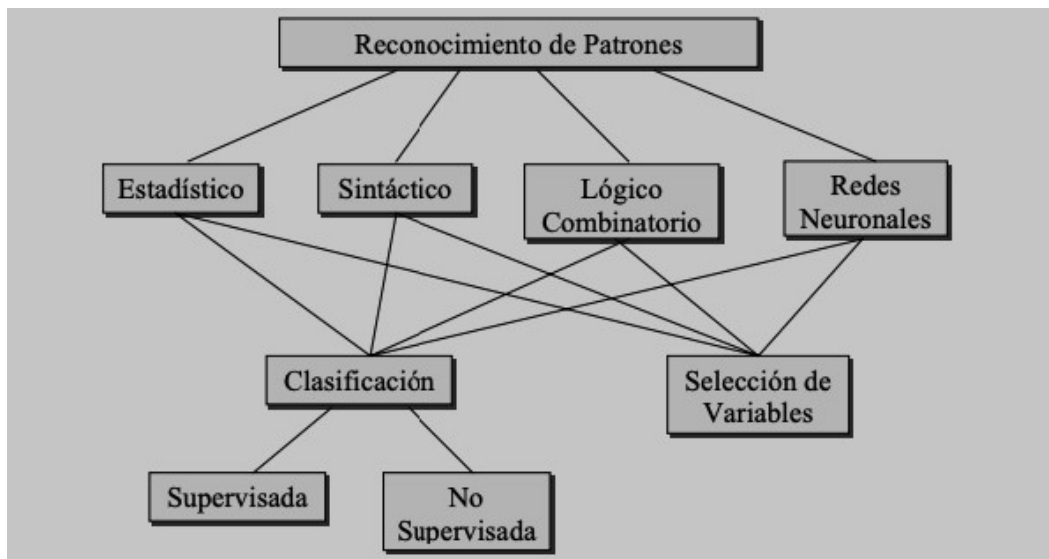
- **Captura:** consiste en la obtención de la imagen digital a través de una variedad de dispositivos, como cámaras fotográficas o sistemas de escaneo.
- **Preprocesamiento:** se refiere a la preparación del archivo digital para eliminar componentes no deseados o redundantes y optimizar la calidad de la imagen.
- **Segmentación:** tiene como objetivo la identificación y extracción de los diferentes elementos presentes en la imagen para su posterior análisis.

- Extracción de características: implica la selección de atributos relevantes que faciliten la identificación de los objetos de interés en la imagen.
- Identificación de objetos: consiste en el análisis para determinar los objetos presentes en la imagen y clasificarlos en categorías específicas.

4.2.3. Reconocimiento de patrones

En el ámbito del análisis de patrones, se lleva a cabo un proceso de interpretación y evaluación de unidades de información conocidas como "objetos", con el objetivo de categorizarlos y organizarlos en grupos específicos. Este campo abarca diversas metodologías, tales como el enfoque estadístico, sintáctico, basado en redes neuronales y lógico (Gawron, González, & Lage, 2014). La clasificación de objetos se realiza a través de dos enfoques principales: supervisado y no supervisado. La clasificación supervisada implica el uso de información previamente etiquetada para guiar el proceso de categorización, mientras que, en la clasificación no supervisada, los objetos se agrupan sin la necesidad de etiquetas predefinidas. En cuanto a la selección de variables, existen estrategias específicas (**Figura 6**). El método *wrapper* se basa en la retroalimentación del clasificador para seleccionar características relevantes, mientras que el método *filter* utiliza criterios independientes del clasificador para la selección de variables (Montiel, Pérez, & Ruiz, 2017)

Figura 6. Esquema del procesamiento del reconocimiento de patrones



Fuente: (Carrasco, 2018)


Los procedimientos para la selección de características pueden llevarse a cabo utilizando diversas técnicas, entre las cuales se incluyen el empleo de tablas de decisiones. Por ejemplo, se puede hacer uso del método ID3, el cual implica la construcción de un árbol de decisión que facilite la selección de conjuntos de variables para clasificar los objetos en diferentes clases. Otra

aproximación es la aplicación de la teoría de testores, la cual se enfoca en la identificación de todos los subconjuntos relevantes para evaluar la importancia de las variables, optando por aquellas de menor relevancia (Aranda & Sotolongo, 2013)

4.2.4. Redes neuronales convolucionales

Una estructura de una CNN se constituye mediante una o múltiples capas convolucionales, pudiendo también incorporar estratos no convolucionales como las capas totalmente conectadas y las capas de agrupamiento. El proceso de aprendizaje profundo de las CNN se encuentra inspirado en la disposición jerárquica del córtex visual del cerebro humano. El córtex primario (área amarilla), como se observa en la **Figura 7**, se especializa en la visión macular, encontrando su equivalente en las CNN en la capa de entrada. Las áreas visuales secundarias, responsables del reconocimiento e identificación de formas, como el área naranja y el área azul, encuentran sus análogos en las capas convolucionales y de agrupamiento de las CNN, respectivamente (Gotarredona, Carrasco, Piñero, & Barranco, 2011)

Figura 7. Cito-arquitectura de la corteza cerebral humana



Fuente: (Mahapattanakul, 2019)

En la fase inicial del procesamiento, las imágenes de los torsos masculinos se convirtieron en tensores (matrices que contienen información de color en el modelo RGB) junto con un vector de etiquetas que indica la clasificación (atlético, normal, con sobrepeso). Luego, las imágenes fueron redimensionadas a una resolución estándar y los valores de los píxeles se normalizaron para oscilar dentro del rango de 0 a 1 antes de ser transmitidos a la siguiente capa del proceso (Pérez, 2009) tal como evidencia la **Tabla 1**.


Tabla 1. Codificación binaria de píxeles en red CNN

1	0.7	0.2	0.3	1	1	0	0	0	1
1	0.4	1	1	1	1	0	1	1	1
0.9	1	1	0.1	0.6	0	0	1	0	0
0.8	1	1	1	0.5	0	1	0	1	0
0.4	0.6	1	0.7	0.9	0	0	1	0	0

Fuente: elaboración propia.

En la capa convolucional, se lleva a cabo una operación de convolución al multiplicar los tensores de la imagen en formato RGB por una matriz de filtro de dimensiones 3×3 . Este proceso, descrito por varios investigadores como (Loncomilla, 2016) tiene como objeto la extracción de características relevantes de la imagen. Mediante la aplicación iterativa de este filtro en diferentes regiones de la imagen, se genera un mapa de características que facilita la tarea de clasificación de la imagen original (**Figura 8**).


Figura 8. Creación del mapa de características



Fuente: (Ratul, Mozaffari, & Lee, 2019)

En la etapa de agrupación, se lleva a cabo una reducción dimensional del mapa manteniendo la esencia de las características fundamentales. Se optó por emplear la técnica de agrupación máxima (*max pooling*), la cual retiene el valor máximo de cada subconjunto (2×2), tal como se ilustra en la **Figura 9**.

Figura 9. Reducción del mapa de características




Fuente: (Deepanshi, 2021)

En la se **Figura 10** expone cómo, algebraicamente, la restricción de una red neuronal

convolucional (CNN) puede formularse de la siguiente manera: se establece que los coeficientes de ponderación que conectan las entradas con los nodos de una única capa convolucional deben ser invariantes para todos los nodos en esa capa. Es decir, si cada nodo (i, j) en una capa convolucional recibe $(i + u, j + v)$ como entrada, donde u y v son constantes pequeñas, entonces existe un coeficiente w asociado con u y v , pero no con i y j (Li, Zhang, Tan, Sun, & Lin, 2019).

Figura 10. Arquitectura de una CNN



Fuente: (Kang & Song, 2018)

4.3. Arquitecturas de *Transfer Learning*

El proceso de *Transfer Learning*, en redes neuronales artificiales, es una técnica que permite utilizar el conocimiento adquirido por un modelo previamente entrenado en una tarea específica para mejorar el rendimiento en otra tarea relacionada. Esta técnica aprovecha las características y patrones aprendidos en grandes conjuntos de datos, facilitando la adaptación del modelo a nuevos problemas con menos datos y menor tiempo de entrenamiento. De esta manera, se logra una mayor eficiencia y precisión en el desarrollo de soluciones de inteligencia artificial, aprovechando al máximo los avances y recursos ya existentes en el campo de las redes neuronales profundas (Arboleda, Molano, & Cortés, 2011).

En el contexto de esta investigación, se seleccionaron las arquitecturas *VGG16*, *ResNet50*, *EfficientNet* y *MobileNet* para la Transferencia de Aprendizaje debido a su probada eficacia en tareas de reconocimiento de patrones en imágenes. Estas arquitecturas han sido diseñadas específicamente para capturar y representar características complejas de las imágenes a través de múltiples capas de convolución y son ampliamente reconocidas por su capacidad para generalizar bien en diversas tareas visuales. Por ejemplo, *VGG16* es conocida por su simplicidad y profundidad moderada, lo que permite un buen equilibrio entre precisión y capacidad computacional (Simonyan, K., & Zisserman, A, 2015). *ResNet50* introduce la idea de conexiones residuales que facilitan el entrenamiento de redes más profundas, mejorando la precisión sin aumentar significativamente el costo computacional (He, K., Zhang, X., Ren, S., & Sun, J, 2016). *EfficientNet* y *MobileNet*, por otro lado, son arquitecturas optimizadas para eficiencia y

rendimiento, permitiendo un procesamiento rápido sin comprometer la precisión, lo que las hace ideales para aplicaciones donde los recursos de computación son limitados (Tan, M., & Le, Q, 2019). A continuación, se detalla la arquitectura de cada una.

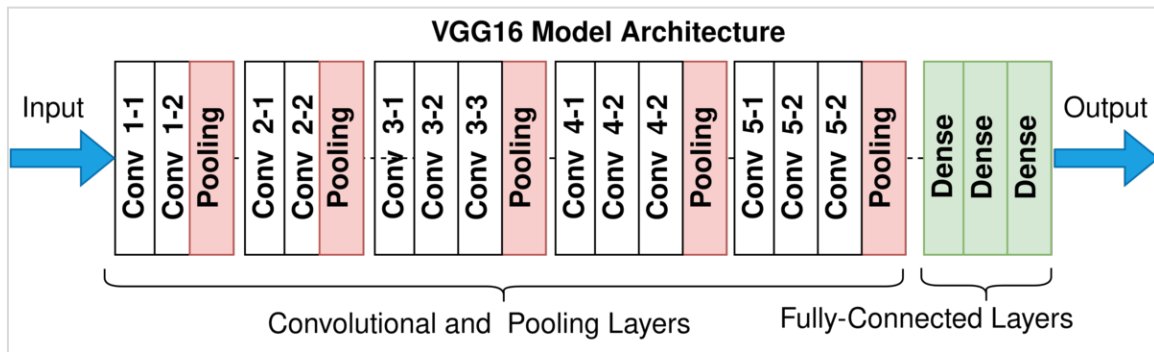
4.3.1. Arquitectura VGG-16

La red neuronal artificial *VGG-16*, concebida por el equipo de Visual Geometry Group (VGG) en 2014, se ha consolidado como una de las estructuras más prominentes en la tarea de clasificación de imágenes profundas. Esta arquitectura, caracterizada por su enfoque en capas convolucionales y completamente conectadas, compuestas por un total de dieciséis estratos, se

distingue por la aplicación de filtros convolucionales de tamaño 3×3 , en contraposición a las dimensiones más amplias utilizadas en modelos anteriores como AlexNet. Esta decisión arquitectónica posibilita una mayor profundización en la red, lo que a su vez mejora significativamente su capacidad para clasificar imágenes (Tammina, 2019)

En relación con la arquitectura en cuestión, el modelo VGG-16 se compone de trece capas convolucionales y tres capas completamente conectadas (**Figura 11**). Todas estas capas han sido previamente entrenadas con el conjunto de datos de ImageNet¹. La función primordial de las capas convolucionales es la extracción de características visuales de las imágenes, mientras que las capas completamente conectadas se utilizan para llevar a cabo la clasificación de las imágenes en diferentes categorías. La decisión de emplear filtros de tamaño 3×3 en lugar de filtros más grandes contribuye a incrementar la profundidad de la red neuronal, lo que a su vez facilita una mejor capacidad de clasificación de las imágenes (Matthew & Fergus, 2013)

Figura 11. Arquitectura de la red VGG-16



Fuente: VGG, 2014

4.3.2. Arquitectura ResNet-50

La arquitectura de red neuronal artificial conocida como ResNet-50 se destaca como una de las más prominentes en la tarea de clasificación de imágenes. Concebida por Microsoft Research en el año 2015, ResNet-50 se distingue por su naturaleza residual, caracterizada por la implementación de conexiones residuales que contrarrestan la disminución del desempeño en redes de gran profundidad. Este enfoque de "saltos de conexión" ha posibilitado la construcción de una red con un total de cincuenta y tres capas, manteniendo una eficacia notable en la tarea mencionada. La estrategia de integrar estos saltos de conexión ha resultado en un aumento de la profundidad de la red sin comprometer su capacidad de clasificación de imágenes, lo que valida su relevancia y utilidad en aplicaciones prácticas de visión por computadora.

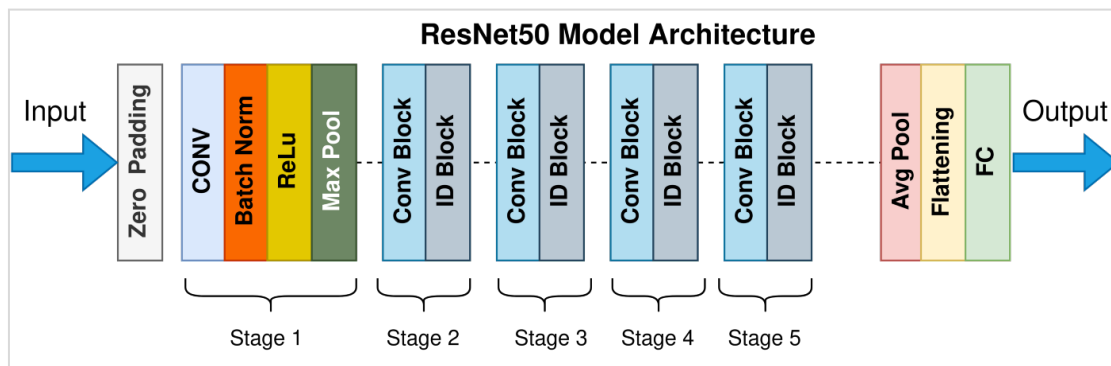
La estructura descrita consta de múltiples bloques compuestos por capas convolucionales seguidas de una capa de identidad, donde la información original se suma al resultado de las

¹ Proyecto ImageNet: <https://www.image-net.org/>

operaciones convolucionales (**Figura 12**). Este tipo de clúster, conocido como redes neuronales convolucionales residuales (ResNet), facilita el flujo de información a través de las capas, previniendo así la disminución del rendimiento en redes profundas debido al desvanecimiento del gradiente. Además de las conexiones residuales, ResNet emplea técnicas como la normalización por lotes y la función de activación ReLU para mejorar la eficacia y velocidad de convergencia durante el entrenamiento (Wen, Li, & Gao, 2020).

ResNet-50, una variante específica de ResNet con 50 capas, destaca por su capacidad para clasificar imágenes con alta precisión y manejar profundidades considerables en la red neuronal. Es ampliamente utilizado como base para la Transferencia de aprendizaje en tareas de clasificación de imágenes y como referencia para la inicialización de pesos en otras arquitecturas de redes neuronales profundas (Dimas & Bin, 2021).

Figura 12. Arquitectura de la red ResNet-50



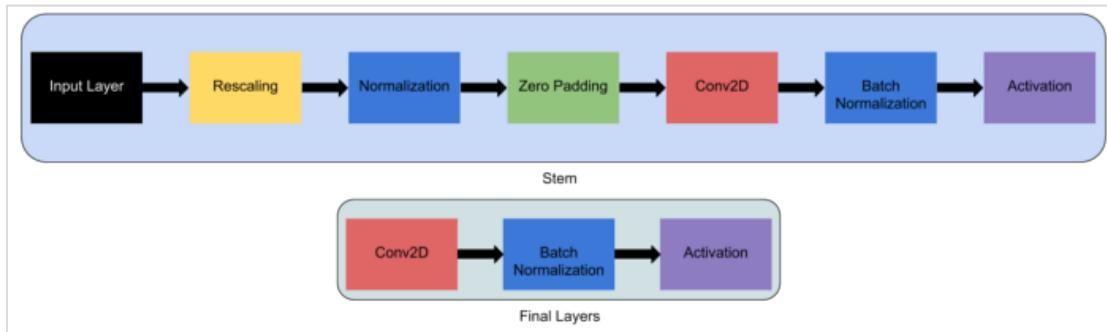
Fuente: Microsoft®, 2024

4.3.3. Arquitectura EfficientNet

Google ha desarrollado EfficientNet, una red neuronal que busca optimizar la eficiencia en términos de precisión y rendimiento. Este enfoque, se caracteriza por su capacidad de ajuste automático de la profundidad, ancho y resolución de la red, lo que permite obtener un rendimiento óptimo. Este método permite a EfficientNet alcanzar altos niveles de precisión en la clasificación de imágenes, manteniendo al mismo tiempo una utilización eficiente de los recursos computacionales (Yousfi, Butora, Fridrich, & Fuji, 2021).

La incorporación de técnicas de regularización como capas de normalización y funciones de activación ReLU es una práctica extendida en redes neuronales, con el propósito de optimizar su desempeño y mitigar el fenómeno de sobreajuste. La normalización de las activaciones en cada capa contribuye a estabilizar el proceso de aprendizaje y a acelerar la convergencia del modelo, al tiempo que las activaciones ReLU introducen no linealidades esenciales para mejorar la capacidad de representación de la red.

Figura 13. Arquitectura EfficientNet



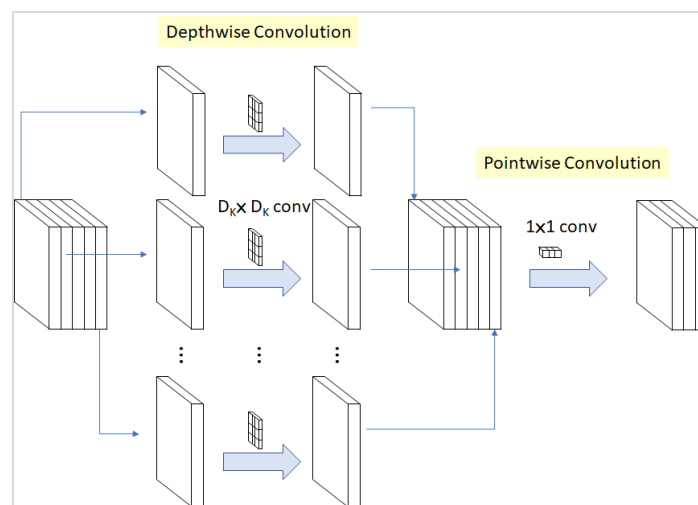
Fuente: Google AI, 2024.

Por otro lado, la arquitectura de *bottleneck* emerge como una estrategia eficaz para reducir la complejidad del modelo y, por ende, el número de parámetros. Esta técnica se basa en la introducción de capas de menor dimensionalidad, conocidas como *bottleneck*, que limitan la cantidad de información que fluye a través de la red. Al reducir la complejidad del modelo, se previene el sobreajuste y se mejora la eficiencia computacional, lo que resulta en un modelo más eficaz y menos propenso a la redundancia de parámetros (Koh, y otros, 2020).

4.3.4. Arquitectura MobileNet

La red neuronal MobileNet, desarrollada por Google en 2017. Se concibió con el propósito de optimizar la utilización de recursos, especialmente en dispositivos móviles. Su arquitectura se fundamenta en la convolución separable en profundidad, la cual permite una notable reducción en la cantidad de parámetros del modelo, resultando en una disminución significativa en el consumo de recursos computacionales y de memoria. Su filosofía se representa en la **Figura 14**.

Figura 14. Arquitectura MobileNet



Fuente: Creada por Google AI®

Esta estrategia busca encontrar un balance entre la precisión del modelo y la eficiencia en

términos de recursos, haciéndola particularmente adecuada para implementaciones en dispositivos móviles con capacidades de procesamiento limitadas (Soto, Sáenz, Rojo, & Ramírez, 2019). La red utiliza una estructura de convolución que se descompone en dos etapas distintas: una subcapa de profundidad (*depthwise*) y una subcapa de punto (*pointwise*). En la primera etapa, se aplican filtros a cada canal de entrada de manera individual, permitiendo a la red aprender características específicas de cada uno. Luego, en la segunda etapa, se utilizan filtros de tamaño reducido para combinar y consolidar las características extraídas en la etapa anterior. Esta estrategia de separación de convolución reduce notablemente la cantidad de parámetros en comparación con las convoluciones estándar, lo que resulta en una utilización más eficiente de los recursos computacionales y de memoria (Qin, Zhang, Chen, Wang, & Peng, 2018).

4.4 Trabajos Relacionados

Un estudio titulado "Estimation of body fat percentage using hybrid machine learning algorithms" plantea la necesidad de métodos prácticos y de bajo costo para determinar el porcentaje de grasa corporal, dado que los dispositivos tradicionales, conocidos como "Dispositivos de Análisis Corporal", son costosos y no accesibles para todos los contextos.

El artículo propone el uso de métodos híbridos de aprendizaje automático para estimar el porcentaje de grasa corporal con alta precisión, utilizando únicamente un conjunto reducido de mediciones antropométricas. Utilizando datos reales de 13 mediciones antropométricas, los investigadores crearon diferentes grupos de características mediante un algoritmo de selección de características. Posteriormente, se desarrollaron 4 modelos híbridos distintos utilizando redes neuronales (MLFFNN), máquinas de soporte vectorial (SVM) y modelos de regresión de árboles de decisión (DT). Los resultados demostraron que es posible estimar el porcentaje de grasa corporal con un alto valor de correlación utilizando solo una medición antropométrica, lo que sugiere que estos sistemas pueden ser utilizados de manera práctica sin necesidad de dispositivos especializados (Muhammed Kürşad, Zeliha Uçar, Fatih Köksal, Nihat Daldal, 2021).

5. METODOLOGÍA

5.1. Enfoque

Este proyecto corresponde a una investigación empírica enmarcada dentro de un enfoque cuantitativo; este enfoque se usó para medir y analizar datos numéricos yendo más allá del análisis descriptivo. En este caso, se midieron las características del cuerpo humano a partir de imágenes y se entrenaron modelos de aprendizaje automático para pronosticar su nivel de grasa corporal asociado.

5.2. Alcance

El alcance de la investigación es exploratorio: el cual se utiliza para indagar en un problema de investigación poco desarrollado. En este caso, se pretende explorar la precisión potencial del modelo neuronal de visión artificial, añadiendo capas de *visual attention*, para estimar el porcentaje de grasa corporal.

5.3. Fuentes de recolección de información

Se recopiló información de fuente primaria mediante trabajo de campo con la toma de imágenes del torso de varones y secundaria a partir de a una colección de imágenes de torsos masculinos proporcionadas por una empresa de asesoramiento físico, la cual prefiere permanecer anónima. Este conjunto de entrenamiento, de la red neuronal, se potenció con técnicas de *augmentation* (aumento visual) para incrementar artificialmente la cantidad de imágenes.

5.4. Etapas de la investigación

- **Etapa 1: recopilación de datos.** Se recopilaron imágenes de 30 varones con diferentes niveles de grasa corporal. Para ello, se utilizó un muestreo aleatorio simple. Los participantes se

seleccionaron de una población de varones mayores de 18 años que residan en Colombia. Se unieron los datos recopilados y los proporcionados por la empresa para tener un set de datos más grande.

- **Etapa 2: extracción de características.** Aquí, se entrenaron CNN para extraer características del cuerpo humano a partir de las imágenes. Para calcular la medida de entrenamiento se incluyeron el perímetro abdominal, la circunferencia del brazo o la relación cintura-cadera. Ahora bien, una vez entrenada la CNN se reentrenó la última capa de la red transferida.
- **Etapa 3: predicción del nivel de grasa corporal.** En esta etapa, se usaron los modelos de aprendizaje automático, ya entrenados, para predecir el nivel de grasa corporal a partir de las características previamente extraídas.

6. ANÁLISIS DE RESULTADOS

6.1. Configuración del ambiente de entrenamiento

Ahora bien, dado que esta investigación implicaba el procesamiento de cientos de imágenes de alta resolución, se adquirió la versión profesional de los servicios en la nube de Google Colab®. Asimismo, para evitar interrupciones en los ciclos algorítmicos, se contrató un entorno de ejecución con *63 Gigabytes* de RAM y, para el procesamiento del banco de imágenes, se empleó una tarjeta GPU en la nube de modelo NVIDIA SMI 535 con versión CUDA 12.2. En la **Figura 15** se especifican la configuración del *hardware* empleado.

Figura 15. Especificaciones de hardware utilizado para el proceso de aumento y entrenamiento

```

+-----+-----+-----+-----+-----+-----+-----+-----+
| NVIDIA-SMI 535.104.05                Driver Version: 535.104.05   CUDA Version: 12.2   |
+-----+-----+-----+-----+-----+-----+-----+-----+
| GPU  Name          Persistence-M   Bus-Id        Disp.A   Volatile Uncorr. ECC |
| Fan  Temp   Perf          Pwr:Usage/Cap     Memory-Usage  GPU-Util  Compute M. |
|=====+=====+=====+=====+=====+=====+=====+=====+
|  0   NVIDIA L4      Off          00000000:00:03.0 Off   0          0          |
| N/A  43C    P8              12W / 72W           1MiB / 23034MiB     0%        Default |
|=====+=====+=====+=====+=====+=====+=====+=====+
|
| Processes:
| GPU  GI  CI           PID  Type  Process name                        GPU Memory |
| ID   ID  ID                                 Usage   |
|=====+=====+=====+=====+=====+=====+=====+=====+
| No running processes found
+-----+-----+-----+-----+-----+-----+-----+-----+

```

Fuente: elaboración propia

6.2. Definición del Conjunto de datos

Se realiza un balanceo eliminando 56 elementos de las clases con mayor cantidad de datos para obtener el conjunto de datos empleado en esta investigación, el cual consta de 444 fotografías

de torsos masculinos, clasificadas en tres categorías según el porcentaje de grasa corporal: *Atlético*, *Normal* y *Sobrepeso*. En la **Tabla 2** se consigna la clasificación de las imágenes con los respectivos tamaños de los subconjuntos de cada clase.

Tabla 2. Frecuencia de las clases de clasificación

Clase	Porcentaje de grasa corporal	Número de fotografías
Atlético	0% - 20%	148
Normal	20% - 30%	148
Sobrepeso	Más del 30%	148

Fuente: elaboración propia

Todas las imágenes tienen una resolución uniforme de 500 500 píxeles, lo que facilita la alimentación de la capa de entrada de la arquitectura de visión artificial. En concreto, para la subdivisión del conjunto de datos, se destinó un 80% de las imágenes al entrenamiento de la red neuronal, mientras que el 20% restante se utilizó para pruebas y validación (**Tabla 3**).

Tabla 3. Frecuencias de subconjuntos de entrenamiento y prueba

Subconjunto de datos	Porcentaje	Número de fotografías
Entrenamiento	80%	356
Prueba (<i>test</i>)	20%	88

Fuente: elaboración propia

Luego de definirse el conjunto de datos, se realizó un proceso de aumento de matrices de imágenes. El objetivo del proceso de aumento es incrementar, de manera artificial, el tamaño del conjunto de imágenes mediante la generación de copias modificadas de las imágenes originales. Esta práctica se lleva a cabo porque, según estudios estadísticos, los conjuntos aumentados tienden a producir una mayor precisión en las predicciones de las redes neuronales convolucionales en comparación con sus versiones originales (Shorten, C., & Khoshgoftaar, T. M, 2019). A modo de ejemplo, la **Figura 16** contiene una muestra de 40 imágenes de torsos varones con diferentes niveles de grasa; con este tipo de fotografías fue el que se entrenaron las cuatro arquitecturas neuronales anteriormente descritas.

Figura 16. Muestra del conjunto de datos con imágenes torsos de varones



Fuente: elaboración propia con los datos proporcionados por la empresa

6.3. Procedimiento de transferencia

A continuación, se presenta el procedimiento detallado para la definición de la función de transferencia utilizada en esta investigación (**Tabla 4**. Fases de programación de la función de transferencia en Python® **Tabla 4**):

Tabla 4. Fases de programación de la función de transferencia en Python®

Fase	Descripción
Bloquear capas no entrenables	Se bloquearon las capas de la red preentrenada que no serán modificadas durante el entrenamiento, preservando así el conocimiento adquirido previamente por el modelo en estas capas.
Modificar la última capa de la red preentrenada	La última capa, conocida como la capa <i>flatten</i> , se modificó para adaptar el modelo a la nueva tarea de clasificación. Esta capa aplana la salida tridimensional de las capas convolucionales en un vector unidimensional.
Definir la capa de densidad con activación <i>softmax</i>	Se añadió una nueva capa densa con una función de activación <i>softmax</i> , adecuada para problemas de clasificación multi categoría, para clasificar las imágenes en las tres categorías ('Atlético', 'Normal', 'Sobrepeso').
Definir el optimizador del modelo clasificador	Se definió el optimizador del modelo clasificador utilizando Adam, conocido por su eficiencia y bajo requerimiento de memoria. Además, se especificó la función de pérdida como " <i>binary crossentropy</i> ", apropiada para problemas de clasificación.

Fuente: elaboración propia

6.4. Entrenamiento post transferencia

Después del procedimiento de transferencia de aprendizaje, se extrajo el grupo de parámetros entrenables que corresponden a la última capa de cada red transferida. Luego, cada una de las arquitecturas se entrenó durante 10 épocas y cada época se completó en 12 iteraciones de aprendizaje. Los hiperparámetros de los modelos se registran en la **Tabla 5**.

Tabla 5. Hiperparámetros de los modelos neuronales entrenados

Métrica	VGG-16	ResNet-50	EfficienNet-B0	MobileNet
Parámetros totales	14,764,866	23,788,418	3,329,218	4,175,013
Parámetros entrenables	50,178	200,706	100,354	125,442
Algoritmo optimizador	Adam	Adam	Adam	Adam
Función de activación	<i>Softmax</i>	<i>Softmax</i>	<i>Softmax</i>	<i>Softmax</i>
Función de entropía	<i>Categorical cross</i>	<i>Categorical</i>	<i>Categorical</i>	<i>Categorical</i>
Épocas de aprendizaje	10	10	10	10
Iteraciones por época	12	12	12	12
Pérdida final	0.3517	4.1476	0.7621	4.5247
Precisión final	0.8409	0.6023	0.5341	0.8750

Fuente: elaboración propia

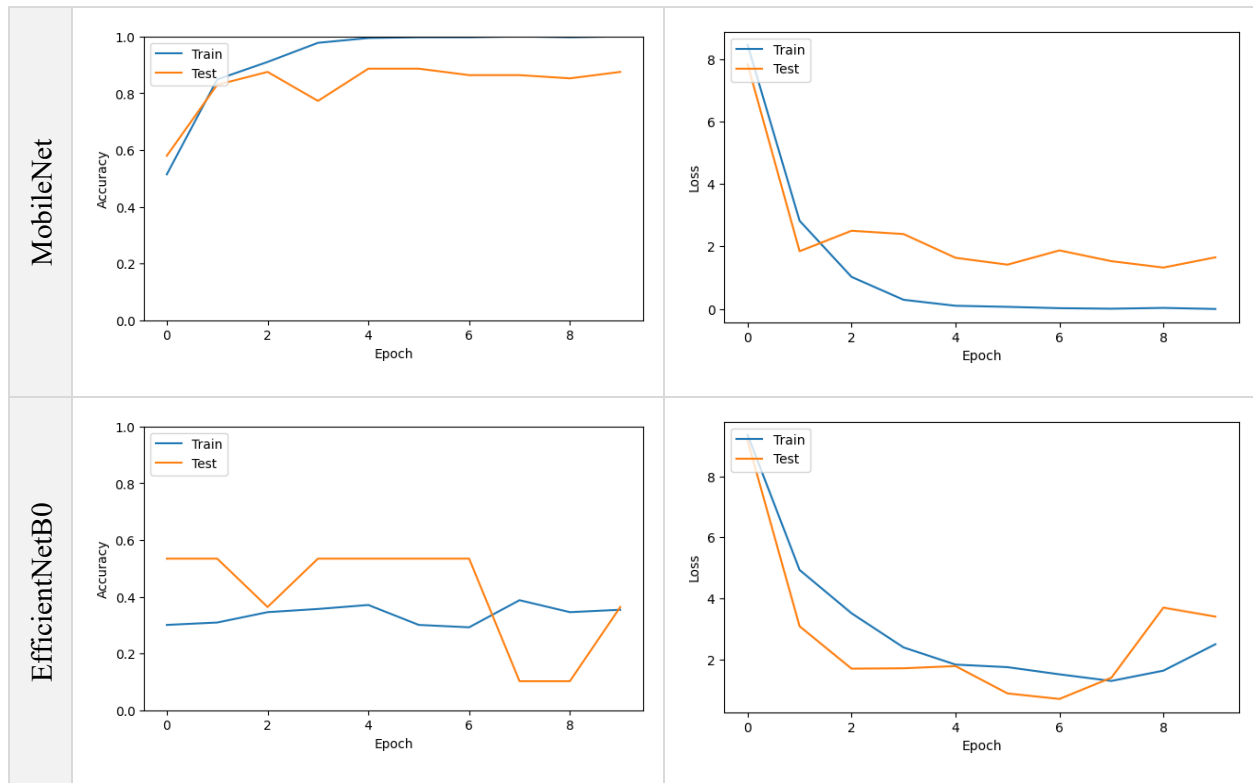
- **Parámetros totales y entrenables.** Al utilizar la transferencia de aprendizaje, un modelo previamente entrenado en un dominio amplio se adapta a una tarea específica, conservando algunos parámetros fijos (no entrenables) y ajustando otros (entrenables) para optimizar el rendimiento en la nueva tarea. Así, se puede aprovechar el conocimiento adquirido previamente, acelerando el entrenamiento y mejorando la eficiencia del modelo. Según Tan *et al* (2018), esta técnica mejora el rendimiento de los modelos en diversas aplicaciones específicas con conjuntos de datos empíricos.
- **Algoritmo optimizador.** El algoritmo de optimización **Adam** es frecuentemente el mejor, o uno de los mejores, para entrenar redes convolucionales de imágenes debido a su capacidad para manejar gradientes en problemas de alta dimensionalidad. Adam combina las ventajas de dos métodos de optimización populares: el *Adagrad*, que maneja bien los gradientes y el *RMSProp*, que ajusta la tasa de aprendizaje basada en la media móvil de los gradientes pasados. Esto le permite adaptarse dinámicamente a diferentes características de los datos y lograr una convergencia más rápida y eficiente en comparación con otros optimizadores (Kingma & Ba, 2015).
- **Función de activación.** La función de activación *softmax* es apropiada en la capa de salida de las redes neuronales para tareas de clasificación multiclase ya que facilita la interpretación probabilística de las salidas. En concreto, esta función convierte las salidas de una red neuronal en probabilidades que suman a uno, permitiendo así interpretar las salidas como distribuciones de probabilidad sobre las diferentes clases. Es particularmente útil en problemas donde se requiere asignar una entrada a una de varias categorías mutuamente excluyentes (Bishop, 2006).
- **Función de pérdida.** La función de pérdida de *categorical cross-entropy* (entropía cruzada categórica) es ampliamente utilizada para problemas de clasificación multiclase en los que cada muestra pertenece a una de varias categorías posibles. Esta función mide la disimilitud entre la distribución de probabilidad predicha por el modelo y la distribución de probabilidad real, permitiendo ajustar los pesos del modelo para que las predicciones se acerquen lo más posible a las etiquetas verdaderas superando la tradicional entropía binaria (Murphy, 2012).
- **Número de épocas.** Se escogieron **10 épocas** para el entrenamiento del modelo porque, después de este número, los porcentajes de precisión **convergen a valores fijos**, indicando que el modelo había alcanzado su máximo rendimiento y que continuar el entrenamiento no resultaría en mejoras significativas en la precisión. Este comportamiento se observa a menudo cuando el modelo ha aprendido las características relevantes de los datos y adicional entrenamiento solo aumentaría el riesgo de sobreajuste sin beneficios adicionales en la

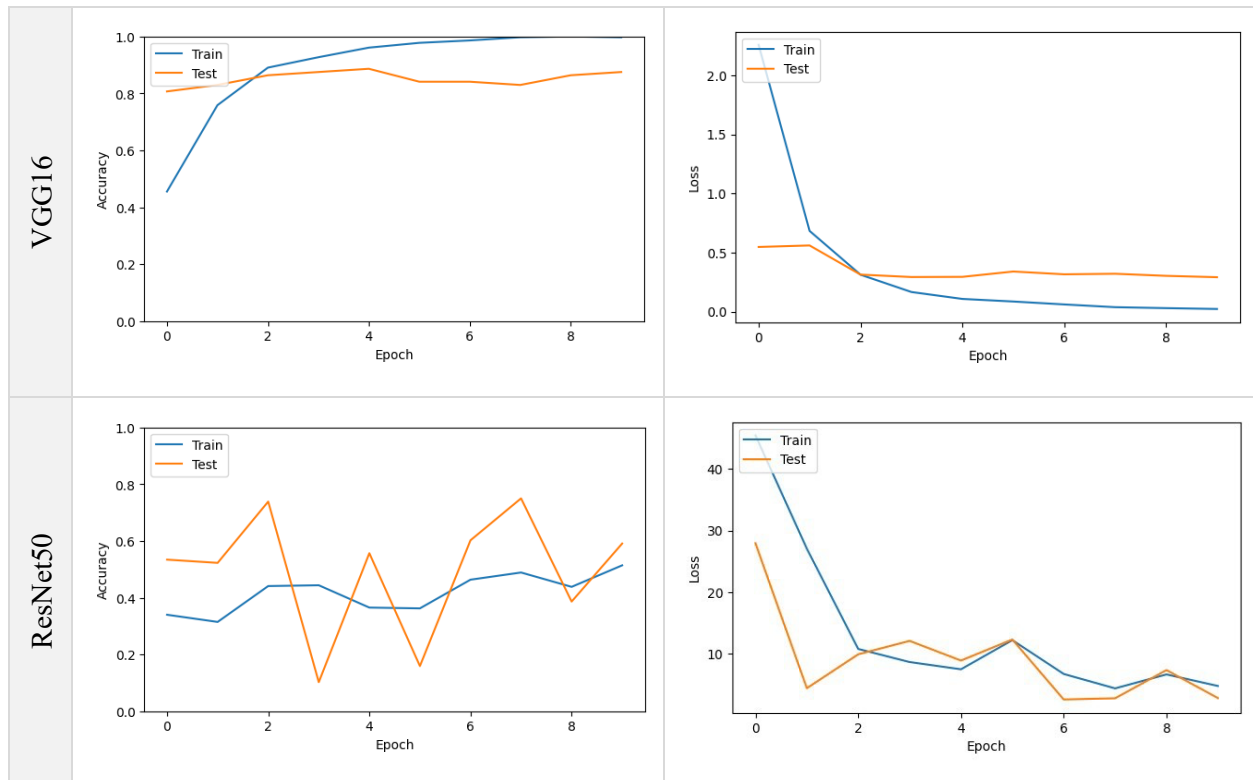
generalización (Goodfellow, Bengio, & Courville, 2016).

- **Número de iteraciones por época.** El número óptimo de iteraciones se calcula considerando la relación entre el tamaño del conjunto de datos, el tamaño del lote (*batch size*) y el número total de épocas. Cada iteración corresponde a una actualización de los parámetros del modelo utilizando un lote de datos. Se eligieron 12 iteraciones porque, en este contexto, permitieron un balance adecuado entre la frecuencia de actualización de los parámetros y el tamaño del lote, asegurando una convergencia estable y eficiente del modelo durante el entrenamiento (Goodfellow, Bengio, & Courville, 2016).

De este modo, el mejor resultado se obtiene con las redes **MobileNet** y **VGG-16**, pues arrojan las precisiones de clasificación máximas con bajos porcentajes de pérdida. En la **Figura 17** se trazaron las curvas de correspondientes para cada arquitectura en función de la época de aprendizaje.

Figura 17. Funciones de precisión y pérdida durante el entrenamiento



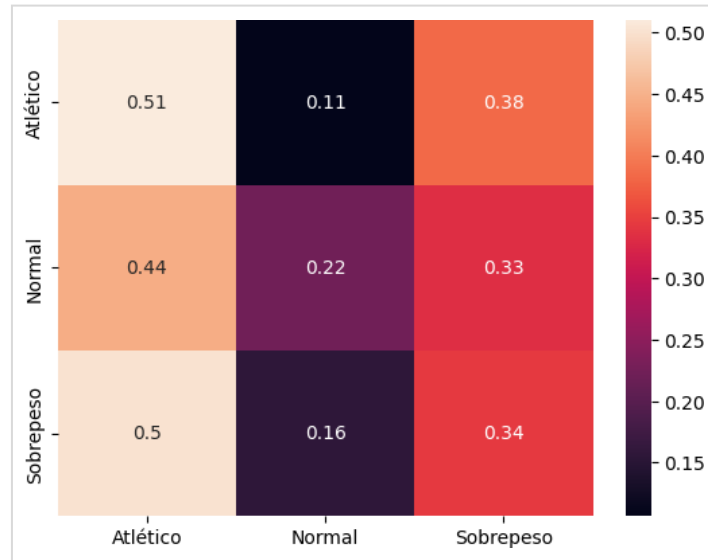


Fuente: elaboración propia

6.5. Resultados de predicción

A continuación, se analizan los resultados de predicción a partir de la matriz de confusión de la **Tabla 6**; en concreto, esta matriz cruza los datos de desempeño del modelo *MobileNet* en la clasificación del porcentaje de grasa corporal según clase anatómica. Para contrastar este tipo de predicciones son familiares los conceptos de "sensibilidad" y "especificidad". A saber, la sensibilidad –también conocida como la tasa de verdaderos positivos– mide la capacidad del modelo para identificar correctamente a los individuos que pertenecen a una clase específica; en contraste, la especificidad, o tasa de verdaderos negativos, evalúa la capacidad del modelo para identificar correctamente a los individuos que no pertenecen a una clase particular.

Tabla 6. Matriz de confusión para la red *MobileNet*



Fuente: elaboración propia

En principio, la matriz revela que la capacidad del modelo para identificar correctamente a los individuos atléticos alcanza la sensibilidad más alta con una tasa de aciertos de **51%**. Esto indica que la red es particularmente eficaz en extraer las características de individuos atléticos toda vez que sus propiedades musculares están claramente definidas, lo cual es consistente con estudios que muestran que los niveles bajos de grasa corporal en atletas son más fáciles de identificar debido a la definición muscular visible. La precisión del modelo en diferenciar entre atléticos y normales es alta, reflejada en la baja tasa de falsos positivos del **11%** entre estas categorías, lo que sugiere una clara distinción en las características extraídas de las imágenes.

Sin embargo, la sensibilidad del modelo para identificar correctamente a los individuos con sobrepeso fue menor: con una tasa de verdaderos positivos de **34%**. Esta capacidad sugiere que la red tiene más dificultades para distinguir entre individuos con sobrepeso y otras categorías, lo cual es evidente en la especificidad del **50%**, donde individuos con sobrepeso son erróneamente clasificados como atléticos. Esto sugiere que las características visuales extraídas pueden aún no ser lo suficientemente distintivas para separar estos dos grupos.

Para la categoría normal, la sensibilidad del modelo para identificar correctamente a los individuos es baja, con una tasa de verdaderos positivos de **22%**. Esta baja precisión sugiere que el modelo enfrenta desafíos significativos en la clasificación correcta de individuos con grasa corporal normal. Además, la baja especificidad, reflejada en la alta tasa de falsos positivos del **44%** (donde individuos normales son clasificados como atléticos), indica una significativa superposición en las características corporales entre estos grupos, lo que presenta una oportunidad para mejorar el modelo. Asimismo, la dificultad del modelo para diferenciar entre normales y sobrepeso es también evidente, con una especificidad moderada, reflejada en una tasa de falsos

positivos del **33%**, indicando que las características de estos dos grupos pueden superponerse y complicar la clasificación precisa.

En síntesis, la matriz de confusión revela que MobileNet tiene la mayor sensibilidad y especificidad para identificar correctamente a los individuos atléticos, pero enfrenta más desafíos en la clasificación precisa de individuos con grasa corporal normal y sobrepeso. Para mejorar el rendimiento del modelo, sería beneficioso ajustar el modelo y aumentar la diversidad y el tamaño del conjunto de datos de entrenamiento, lo que podría ayudar a reducir las tasas de falsos positivos y mejorar las métricas de clasificación en las categorías más desafiantes.

7. CONCLUSIONES

Construcción del conjunto de datos. La creación del conjunto de datos, compuesto por 444 imágenes de torsos masculinos clasificadas en tres categorías según el porcentaje de grasa corporal, ha sido exitosa. Cada clase ('Atlético', 'Normal' y 'Sobrepeso') contiene una distribución equilibrada de 148 imágenes. Este conjunto de datos es fundamental para el entrenamiento y la validación del modelo de visión artificial, asegurando una base sólida y representativa para la estimación precisa del porcentaje de grasa corporal en varones.

Extracción de características de imagen y entrenamiento de modelos neuronales. La extracción de características a través de redes neuronales convolucionales, utilizando Transferencia de aprendizaje, ha permitido identificar y utilizar las características más relevantes de las imágenes del torso masculino. El procedimiento incluyó el bloqueo de capas no entrenables, la modificación de la última capa pre entrenada y la implementación de una capa de densidad con activación *softmax*. Este enfoque ha optimizado el rendimiento del modelo, aprovechando el conocimiento preexistente en redes pre entrenadas y adaptándolo a la tarea específica de clasificación de grasa corporal.

Contraste del rendimiento de las arquitecturas. La evaluación y comparación de las diferentes arquitecturas neuronales entrenadas reveló que la red MobileNet (seguida de VGG16) ofreció la mayor precisión con el menor porcentaje de pérdida durante las pruebas. El uso de la función pérdida de entropía binaria y el optimizador tipo *Adam* garantizó un rendimiento eficiente y preciso de la modelación. Los resultados de la matriz de confusión indican que MobileNet es, particularmente, eficaz para la clasificación de imágenes en las categorías establecidas: proveyendo una herramienta útil para la estimación del porcentaje de grasa corporal.

8. ASPECTOS ÉTICOS CONSIDERADOS

En el marco de la **legislación colombiana**, este proyecto se adhiere estrictamente a los requisitos legales y éticos del país en cuanto al manejo de datos personales, la protección de la

privacidad y la seguridad de la información, garantizando un tratamiento responsable y ético de los datos en el contexto de la investigación científica.

8.1. Uso de los datos

Los datos recabados, consistentes en imágenes fotográficas de torsos masculinos, se emplearán exclusivamente para el desarrollo y validación de un modelo de Inteligencia Artificial (IA) con atención visual, orientado a la estimación precisa del porcentaje de grasa corporal. Este uso está alineado con los principios establecidos en la **Ley Estatutaria 1581 de 2012** de Protección de Datos Personales en Colombia, que regula la recolección y tratamiento de datos personales. (Valderrama, 2018)

8.2. Beneficios y beneficiarios

Este proyecto apunta a mejorar las técnicas de estimación de la grasa corporal, con aplicaciones en la salud y la medicina deportiva. Los beneficiarios incluyen el sector médico, investigadores y el público general, a través de una mejor gestión de la salud y el bienestar físico, en consonancia con los objetivos de salud pública promovidos por el Ministerio de Salud y Protección Social de Colombia.

8.3. Usuarios de los datos

Los datos serán utilizados por el equipo investigador de la Universidad EAFIT, conformado por académicos y estudiantes. Además, los resultados podrían difundirse a la comunidad científica, siguiendo las directrices de la **Ley 1712 de 2014** sobre Transparencia y del Derecho de Acceso a la Información Pública Nacional. (Presidencia de la República, 2015)

8.4. Obtención de consentimiento:

Se asegurará el consentimiento informado de todos los participantes, conforme a lo estipulado en la **Resolución 8430 de 1993 del Ministerio de Salud**, que establece las normas científicas, técnicas y administrativas para la investigación en salud. Este consentimiento abarcará información detallada sobre el uso y propósito del estudio (Mateus, y otros, 2019).

8.5. Anonimización de la información

Se implementarán estrategias de anonimización o pseudo anonimización para proteger la privacidad, acordes con lo establecido en la **Ley 1581 de 2012**. Esto garantizará que la identidad de los individuos no pueda ser directamente discernida a partir de los datos recopilados.

8.6. Seguridad de la información:

Se adoptarán medidas de seguridad robustas para la protección de los datos, en línea con lo requerido por el **Decreto 1377 de 2013**, que reglamenta parcialmente la Ley 1581 de 2012 en lo referente a las medidas de seguridad de la información (Corredin & Mahecha, 2018).

8.7 Trabajo Futuro

En este estudio, se utilizaron imágenes exclusivamente del torso de varones para la estimación del porcentaje de grasa corporal. Aunque este enfoque ha permitido un análisis focalizado en la región torácica, como trabajo futuro se propone la ampliación del conjunto de datos para incluir imágenes de cuerpo completo. Esto bajo la hipótesis de que permitirá una estimación más precisa del porcentaje de grasa corporal y reducirá la posibilidad de errores en la clasificación.

8.8 Reproducibilidad

Por motivos de confidencialidad el set de datos empleado en este trabajo no es público pero todo el código desarrollado durante el trabajo es de libre acceso y se encuentra disponible en el siguiente repositorio de github.

https://github.com/sgomezb/body_fat

9. REFERENCIAS

- Acevedo, F., Serra, M., & Rendtorff, N. (2012). Una herramienta sencilla de medición del color en un esmalte cerámico y sus posibilidades. *In VI Jornadas de Investigación en Disciplinas Artísticas y Proyectuales*. Obtenido de https://sedici.unlp.edu.ar/bitstream/handle/10915/40555/Documento_completo.pdf?sequence=1&isAllowed=
- Ali, S., & Massa, M. (2021). The Effects of Sex Hormones on Food Intake, Body Weight, and Fat Composition: A Cross-Species Analysis. *Journal of Student Research*, 10(3). doi:<https://doi.org/10.47611/jsr.v10i3.1337>
- Álvarez, P., Sangiao, S., Brandón, I., & Córdido, F. (2011). Función endocrina en la obesidad. *Endocrinología y nutrición*, 58(8), 422-432. Obtenido de <https://www.sciencedirect.com/science/article/abs/pii/S1575092211002361>
- Aranda, Y., & Sotolongo, A. (2013). Integración de los algoritmos de minería de datos 1R, PRISM e ID3 a PostgreSQL. *ISTEM-Journal of Information Systems and Technology Management*, 10, 389-406. Obtenido de <https://www.scielo.br/j/jistm/a/qyyfcSgfjKGDxnvjCPvjtWx/?format=pdf&lang=es>
- Arboleda, I. F., Molano, J., & Cortés, C. M. (2011). Monetary compensation, training and transfer of learning: Evidence of accelerated learning. Recuperado el 17 de 6 de 2024, de <http://scielo.org.co/pdf/psdc/n27/n27a04.pdf>
- Barceló, M., Borroto, G., & Rodríguez, H. (2002). Insulinorresistencia: correlación con la distribución de la grasa en el obeso. *Revista Cubana de Investigaciones Biomédicas*, 21(4), 228-234. Obtenido de http://scielo.sld.cu/scielo.php?pid=S0864-03002002000400002&script=sci_arttext&tlng=en
- Batra, A., & Siegmund, B. (2012). The Role of Visceral Fat. *Enfermedades Digestivas*, 30(1), 70-74. doi:<https://doi.org/10.1159/000335722>
- Betz, M., & Enerbäck, S. (2018). Targeting thermogenesis in brown fat and muscle to treat obesity and metabolic disease. *Nature Reviews Endocrinology*.
- Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer. Obtenido de <https://link.springer.com/book/10.1007/978-0-387-45528-0>
- Blakeman, S., & Mareschal, D. (2020). Selective Particle Attention: Visual Feature-Based Attention in Deep Reinforcement Learning. Centre for Brain and Cognitive Development of University of London. doi:<https://doi.org/10.48550/arXiv.2008.11491>
- Boughman, J., Masters, M., Morgan, C., Ruden, T., & Rochelle, S. (2019). Assessing the validity of bioelectrical impedance and skinfold calipers for measuring body composition in NOLS backcountry hikers. *Wilderness & Environmental Medicine*.
- Camacho, M., Alcalá, V., & Nieves, S. (2015). Diferencias de género en pacientes con obesidad mórbida tributarios de cirugía bariátrica. *Revista de Psicopatología y Psicología Clínica*, 20(3), 189-198. doi:<https://doi.org/10.5944/rppc.vol.20.num.3.2015.15892>

- Carrasco, J. (2018). Reconocimiento de patrones. México D.F.: Instituto Nacional de Astrofísica Óptica y Electrónica.
- Concha, U., & Palomino, N. (2009). Técnicas de segmentación en procesamiento digital de imágenes. *Revista de investigación de Sistemas e Informática*, 6(2), 9-16. Obtenido de <https://revistasinvestigacion.unmsm.edu.pe/index.php/sistem/article/view/3299/2749>
- Corredin, E. L., & Mahecha, Y. A. (2018). Metodología dirigida a compañías distribuidoras de tecnología para el manejo y protección de los datos personales de terceros de acuerdo a la ley estatutaria 1581 del 2012 y el decreto 1377 de 2013. Recuperado el 17 de 11 de 2023, de <http://repository.poligran.edu.co/handle/10823/1226>
- Deepanshi. (14 de Agosto de 2021). Obtenido de *Beginners Guide to Convolutional Neural Network with Implementation in Python*: <https://www.analyticsvidhya.com/blog/2021/08/beginners-guide-to-convolutional-neural-network-with-implementation-in-python/>
- Simonyan, K., & Zisserman, A. (2015). Very deep convolutional networks for large-scale image recognition. *International Conference on Learning Representations (ICLR)*.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 770-778.
- Tan, M., & Le, Q. (2019). EfficientNet: Rethinking model scaling for convolutional neural networks. *Proceedings of the International Conference on Machine Learning (ICML)*, 6105-6114.
- Després, J., Lemieux, I., & Bergeron, J. (2008). Abdominal obesity and the metabolic syndrome: contribution to global cardiometabolic risk. *Arteriosclerosis, Thrombosis, and Vascular Biology*, 28(6), 1039-1049. doi:DOI: 10.1161/ATVBAHA.107.159228
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of Big Data*, 6(1), 1-48.
- Dimas, L., & Bin, L. (2021). Facial expression recognition via ResNet-50. *International Journal of Cognitive Computing in Engineering*, 2, 57-64. Obtenido de <https://pdf.sciencedirectassets.com/776632/1-s2.0-S2666307420X00039/1-s2.0-S2666307421000073/main.pdf?X-Amz-Security-Token=IQoJb3JpZ2luX2VjEjEwLWVhc3QtMSJHMEUCIEOnr1IqL3dQ371LEVfYivoy0wJD3aNYdphC%2BoGQIR0%2BAiEAgGsEs5EU>
- Fernández, A., Dórea, J., & Valente, B. (2020). Comparison of data analytics strategies in computer vision systems to predict pig body composition traits from 3D images. *Journal of Animal Science*.
- Fox, C., Massaro, J., Hoffmann, U., Pou, K., Maurovich-Horvat, P., Chun-Yu, L., . . . Murabito, J. (2007). Abdominal visceral and subcutaneous adipose tissue compartments: association with metabolic risk factors in the Framingham Heart Study. *Multicenter Study*

- Circulation, 116(1), 39-48. doi:DOI: 10.1161/CIRCULATIONAHA.106.675355
- Frigolet, M., & Gutiérrez, R. (2020). Los colores del tejido adiposo. *Gaceta médica de México*, 156(2), 143-150. doi:<https://doi.org/10.24875/gmm.20005541>
- Gawron, O., González, N., & Lage, F. (2014). Análisis de métodos para el reconocimiento de patrones en ECG. *Memórias Do WTA*, 42-45. Obtenido de https://www.researchgate.net/profile/Nahuel-Gonzalez/publication/334495515_Analisis_de_metodos_para_el_reconocimiento_de_patrones_en_ECG/links/5d2e555c92851cf4408a731c/Analisis-de-metodos-para-el-reconocimiento-de-patrones-en-ECG.pdf
- Gibson, M., Padgett, M., & Matthew, E. (2019). Principles and prospects for single-pixel imaging. *Nature photonics*, 13(1), 13-30. Obtenido de <https://www.nature.com/articles/s41566-018-0300-7>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press. Obtenido de <https://www.deeplearningbook.org/>
- Gotarredona, M., Carrasco, J., Piñero, B., & Barranco, B. (2011). Red neuronal convolucional rápida sin fotogramas para reconocimientos de dígitos. In XXVI Simposio de la URSI. Unión Científica Internacional de Radio, 1-4. Obtenido de <https://idus.us.es/bitstream/handle/11441/79308/RED%20NEURONAL.pdf?sequence=1&isAllowed=y>
- Guo, H., & Zhang, L. (2017). A Single Nucleotide Polymorphism in the FADS1 Gene is Associated with Plasma Fatty Acid and Lipid Profiles and Might Explain Gender Difference in Body Fat Distribution. *Lipids in Health and Disease*.
- Heredia, A., Martínez, S., Quintero, E., Piñeros, W., & Chuvieco, E. (2003). Comparación de distintas técnicas de análisis digital para la cartografía de áreas quemadas con imágenes LANDSAT ETM+. *GeoFocus. International Review of Geographical Information Science and Technology* 216-234. Obtenido de <https://geofocus.org/index.php/geofocus/article/view/31/199>
- Iglésias, D. (2004). La gestión de la imagen digital. hipertext. Obtenido de http://eprints.rclis.org/9004/1/La_gesti%C3%B3n_de_la_imagen_digital.pdf
- Kang, X., & Song, B. (2018). Vehicle-Type Detection Based on Compressed Sensing and Deep Learning in Vehicular Networks. *Sensors*.
- Kingma, D., & Ba, J. (2015). Adam: A Method for Stochastic Optimization. *International Conference on Learning Representations*. doi:<https://arxiv.org/abs/1412.6980>
- Koh, P., Nguyen, T., Tang, Y., Mussmann, Pierson, E., Kim, B., & Liang, P. (2020). Concept bottleneck models. In *International conference on machine learning*, 5338-5348. Obtenido de <https://proceedings.mlr.press/v119/koh20a/koh20a.pdf>
- Kolnes, K. (2021). Effect of Exercise Training on Fat Loss—Energetic Perspectives and the Role of Improved Adipose Tissue Function and Body Fat Distribution. *Frontiers in Physiology*.

- Kolnes, K., & J., P. (2021). Effect of Exercise Training on Fat Loss—Energetic Perspectives and the Role of Improved Adipose Tissue Function and Body Fat Distribution. *Frontiers in Physiology*.
- Kolnes, K., & J., P. M. (2021). Effect of Exercise Training on Fat Loss—Energetic Perspectives and the Role of Improved Adipose Tissue Function and Body Fat Distribution. *Frontiers in Physiology*.
- Ladeiras, R., Sampaio, F., Bettencourt, N., Fontes-Carvalho, R., Ferreira, N., Leite-Moreira, A., & Gama, V. (2017). The ratio between visceral and subcutaneous abdominal fat assessed by computed tomography is an independent predictor of mortality and cardiac events. *Revista Española de Cardiología*, 70(5), 331-337. Obtenido de <https://www.sciencedirect.com/science/article/abs/pii/S1885585716302729>
- Li, Y., Zhang, X., Tan, X., Sun, J., & Lin, Y. (2019). Training Convolutional Neural Networks. *IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Obtenido de <https://ieeexplore.ieee.org/document/9222510>
- Loncomilla, P. (2016). Deep learning: Redes convolucionales. Inaop. Obtenido de <https://ccc.inaop.mx/~pgomez/deep/presentations/2016Loncomilla.pdf>
- Lubis, L. (2018). Differentiation of body fat composition between skinfold caliper and bioelectrical impedance analysis methods among professors. *Journal of the Medical Sciences*, 50.
- Mahapattanakul, P. (2019). From Human Vision to Computer Vision. *Artificial Intelligence Magazine*. Obtenido de <https://becominghuman.ai/from-human-vision-to-computer-vision-how-far-off-are-we-part1-3-b35d37a196a4>
- Marcel, E., García, A., & Rodríguez, Y. (2016). Obesidad visceral: predictor de diabetes mellitus tipo 2 y enfermedades cardiovasculares. *Revista Mexicana de Patología Clínica y Medicina de Laboratorio*, 63(2), 67-75. Obtenido de <https://www.medigraphic.com/pdfs/patol/pt-2016/pt162b.pdf>
- Mateus, J. C., Varela, M. T., Caicedo, D. M., Arias, N. L., Jaramillo, C. D., Morales, L. C., & Palma, G. I. (2019). Resolución 8430 de 1993: ¿Responde a las necesidades actuales de la ética en investigación en salud con seres humanos en Colombia? *Biomedica*, 39(4). Recuperado el 17 de 11 de 2023, de <https://revistabiomedica.org/index.php/biomedica/article/view/4333>
- Matthew, D., & Fergus, R. (2013). *Visualizing and Understanding Convolutional Networks*. New York University. Obtenido de <https://arxiv.org/abs/1311.2901>
- Melo, S. (2009). Transformaciones geométricas sobre imágenes digitales. Facultad de Ciencias-Carrera de Matemáticas. Universidad Distrital Francisco José de Caldas. Obtenido de <https://www.alammi.info/2congreso/memorias/Documentos/martes/TRANSFORMGEO METRICAS.pdf>
- Minetto, M., Pietrobelli, A., Busso, C., Bennett, J., Ferraris, A., Shepherd, J., & Heymsfield, S. (2022). Digital Anthropometry for Body Circumference Measurements: European

Phenotypic Variations throughout the Decades. *Journal of Personalized Medicine*, 12(6).
doi:<https://doi.org/10.3390/jpm12060906>

- Montiel, L., Pérez, C., & Ruiz, J. (2017). Selección y clasificación de genes cancerígenos utilizando un método híbrido filtro/wrapper. *Advances in Social Informatics and its Applications*. Obtenido de https://rcs.cic.ipn.mx/2017_136/Seleccion%20y%20clasificacion%20de%20genes%20cancerigenos%20utilizando%20un%20metodo%20hibrido%20filtronwrapper.pdf
- Moreno, M., & Martinez, J. (2002). El tejido adiposo: órgano de almacenamiento y órgano secretor. *An Sist Sanit Navar*, 29-39. Obtenido de <https://dadun.unav.edu/handle/10171/18785>
- Murphy, K. (2012). *Machine Learning: A Probabilistic Perspective*. MIT Press. Obtenido de <https://mitpress.mit.edu/9780262018029/>
- Neeland, I., Poirier, P., & Després, J. (2018). Cardiovascular and Metabolic Heterogeneity of Obesity: Clinical Challenges and Implications for Management. *Circulation*, 137(13), 1391-1406. doi:DOI: 10.1161/CIRCULATIONAHA.117.029617
- NetMD. (2024). Complicaciones metabólicas en pacientes de peso normal. Obtenido de <https://netmd.org/nutricion/nutricion-articulos/complicaciones-metabolicas-en-pacientes-de-peso-normal>
- Nimptsch, K., Königorski, S., & Pischon, T. (2019). Diagnosis of obesity and use of obesity biomarkers in science and clinical medicine. *Metabolism: Clinical and Experimental*.
- Oliva, M., Muñoz, M., Kim-Hellmuth, S., Wucher, V., Gewirtz, A., & Cotter, D. (2020). El impacto del sexo en la expresión genética en los tejidos humanos. *Ciencia*, 369. Obtenido de <https://www.science.org/doi/full/10.1126/science.aba3066>
- Pérez, M. (2009). Espacios de Color RGB, HSI y sus Generalizaciones a n-Dimensiones. INAOE, Tonantzintla. Obtenido de <https://inaoe.repositorioinstitucional.mx/jspui/bitstream/1009/362/1/AlonsoPeMA.pdf>
- Pertusa, J. (2011). *Técnicas de análisis de imagen (2a ed.)*. Valencia: Publicacions de la Universitat de València.
- Pineau, J., & Bouslah, M. (2020). Prediction of body fat in male athletes from ultrasound and anthropometric measurements versus DXA. *The Journal of Sports Medicine and Physical Fitness*.
- Portiansky, E. L. (2013). *Análisis multidimensional de imágenes digitales*. La Plata: Universidad Nacional de La Plata.
- Presidencia de la República. (2015). Decreto 103 de 2015. Recuperado el 17 de 11 de 2023, de Presidencia de la República de Colombia: <http://bibliotecadigital.ccb.org.co/handle/11520/13607>

- Muhammed Kürşad, Zeliha Uçar, Fatih Köksal, Nihat Daldal. (2021). Estimation of body fat percentage using hybrid machine learning algorithms.
- Qin, Z., Zhang, Z., Chen, X., Wang, C., & Peng, Y. (2018). d-mobilenet: Improved mobilenet with a fast downsampling strategy. *International Conference on Image Processing*, 1363-1367. Obtenido de <https://ieeexplore.ieee.org/abstract/document/8451355>
- Ratul, M., Mozaffari, M., & Lee, W. (2019). Skin lesions classification using deep learning based on dilated convolution. *BioRxiv*.
- Royo, M., Bes-Rastrollo, M., Bosqued, E., Burgos, C., & Castello, A. (2017). Nutrición en salud pública. *Escuela Nacional de Sanidad*. Obtenido de https://repisalud.isciii.es/bitstream/handle/20.500.12105/5780/Nutrici%c3%b3nenSaludP%c3%bablica_2017.pdf?sequence=1&isAllowed=y
- Sabbatini, A., & Kararigas, G. (2020). Estrogen-related mechanisms in sex differences of hypertension and target organ damage. *Biology of sex differences*, 11(1), 31. Obtenido de <https://link.springer.com/article/10.1186/s13293-020-00306-7>
- Scher-Nemirovsky, E., Ruiz, D., & Mendivil, C. (2019). Impacto del ejercicio sobre el metabolismo de los lípidos y la dislipidemia. *Revista de Nutrición Clínica y Metabolismo*. doi:<https://doi.org/10.35454/rncm.v2n2.004>
- Serre, P., Wolf, L., & Poggio, T. (2000). Object recognition with convolutional networks (Reconocimiento de objetos con redes convolucionales). *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 22(2), 221-237. Obtenido de Enlace: <https://ieeexplore.ieee.org/document/8650517>
- Smith, G., Lawlor, D., Ebrahim, S., Whincup, P., Sterne, J., Papacosta, O., & Wannamethee, G. (2004). Sex differences in body fat distribution and carotid intima media thickness: cross sectional survey using data from the British regional heart study. *Journal of Epidemiology & Community Health*, 58(8), 700-704. doi:<https://doi.org/10.1136/jech.2003.014001>
- Solana, A. M. (2005). Estimación del contenido de materia grasa en el alperujo mediante visión artificial. Recuperado el 17 de 11 de 2023, de <https://dialnet.unirioja.es/servlet/tesis?codigo=20045>
- Soto, O., Sáenz, A., Rojo, C., & Ramírez, J. (2019). Análisis del desempeño de redes neuronales profundas para segmentación semántica en hardware limitado. *ReCIBE. Revista electrónica de Computación, Informática, Biomédica y Electrónica*, 8(2). Obtenido de <https://www.redalyc.org/journal/5122/512261374010/512261374010.pdf>
- Soydaner, D. (2022). Attention Mechanism in Neural Networks: Where it Comes and Where it Goes. *Cornell University*, 12. doi:<https://ar5iv.labs.arxiv.org/html/2204.13154>
- Summersby, A. (2022). RGB, CMYK e impresión fotográfica. Obtenido de *Fotografía y vídeo profesional*: <https://www.canon.es/pro/infobank/rgb-and-cmyk/>
- Tammima, S. (2019). Transfiera el aprendizaje utilizando vgg-16 con una red neuronal convolucional profunda para clasificar imágenes. *Revista Internacional de Publicaciones*

- Científicas y de Investigación, 9(10), 143-150. Obtenido de https://www.researchgate.net/profile/Srikanth-Tamma/publication/337105858_Transfer_learning_using_VGG16_with_Deep_Convolutional_Neural_Network_for_Classifying_Images/links/5dc94c3ca6fdcc57503e6ad9/Transfer-learning-using-VGG-16-with-Deep-Convolutional-
- Tan, M., Chen, B., Pang, R., Vasudevan, V., Sandler, M., Howard, A., & Le, Q. (2018). Platform-Aware Neural Architecture Search for Mobile. *EEE Conference on Computer Vision and Pattern Recognition*. Obtenido de <https://arxiv.org/abs/1807.11626>
- Tchernof, A., & Després, J. (2013). Pathophysiology of Human Visceral Obesity: An Update. *Physiological Reviews*, 93(1), 359-404. doi:DOI: 10.1152/physrev.00033.2011
- Tobias, D., Pan, A., Jackson, C., Ding, E., & Willett, W. (2004). Body-mass index and mortality among adults with incident type 2 diabetes. *New England Journal of Medicine*, 370(3), 233-244. Obtenido de <https://www.nejm.org/doi/full/10.1056/nejmoa1304501>
- Tramunt, B., Smati, S., Grandgeorge, N., Lenfant, F., ArnaL, J., Montagner, A., & Gourdy, P. (2020). Diferencias de sexo en la regulación metabólica y la susceptibilidad a la diabetes. *Diabetología*, 63, 453-461. Obtenido de <https://link.springer.com/article/10.1007/s00125-019-05040-3>
- Travieso, J. (2016). Síndrome metabólico y riesgo cardiovascular. *Revista CENIC. Ciencias Biológicas*, 47(2), 106-119. Obtenido de <https://www.redalyc.org/pdf/1812/181245821006.pdf>
- Valderrama, N. B. (2018). Diseño del Sistema Integrado de Gestión NTC-ISO/IEC 27001:2013 e ISO 31000:2018, aplicado a la Ley Estatutaria 1581 De 2012 “Por la cual se dictan disposiciones generales para la protección de datos personales”, para la empresa Pavimentaciones Morales S.L. Sucursal en Colombia. Recuperado el 17 de 11 de 2023, de https://repositorio.escuelaing.edu.co/bitstream/001/801/1/brijaldo_valderrama_natalia_2018.pdf
- Wainschenker, R. (2017). *Procesamiento digital de imágenes*. Buenos Aires: Universidad Nacional del Centro de la Provincia de Buenos Aires.
- Wen, L., Li, X., & Gao, L. (2020). A transfer convolutional neural network for fault diagnosis based on ResNet-50. *Neural Computing and Applications*, 32(10), 6111-6124. Obtenido de <https://link.springer.com/article/10.1007/s00521-019-04097-w>
- Wilhelm, H., & Fuson, H. (2014). *Personal and Family Archives: A Simplified Approach to Collecting, Organizing, and Preserving Analog and Digital Photographs, Movies, Videos, Letters, and Other Documents*. doi:http://dx.doi.org/10.3989/mc.2004.v54.i273.223
- Yan, Y., Kawahara, J., & Hamarneh, G. (2019). Melanoma recognition via visual attention. *International Conference on Information Processing in Medical Imaging*, 793-804.
- Yarbus, A. (1967). *Eye Movements and Vision*. New York: Plenum Press.
- Yousfi, Y., Butora, J., Fridrich, J., & Fuji, C. (2021). Mejora de EfficientNet para esteganálisis

JPEG. Taller sobre ocultación de información y seguridad multimedia, 149-157. Obtenido de <https://dl.acm.org/doi/abs/10.1145/3437880.3460397>

Zeng, G. (2019). Holistic decomposition convolution for effective semantic segmentation of medical volume images. *Medical Image Analysis*.

Zhou, Y. (2022). Association of Sex Hormones and Fat Distribution in Men with Different Obese and Metabolic Statuses. *International Journal of General Medicine*.

