



SISTEMA DE DETECCIÓN Y MEDICIÓN AUTOMÁTICA DE HERIDAS IMPLEMENTADO EN YOLOV7, PARA APLICACIÓN FUTURA DE CICATRIZADO

AUTOMATIC WOUND DETECTION AND MEASUREMENT SYSTEM IMPLEMENTED IN YOLOV7, FOR FUTURE WOUND HEALING APPLICATION

Juan Alberto Antonio Velázquez^{1*} , Adriana Reyes Nava¹ , Marcos-C González Domínguez¹ , Roberto Alejo Eleuterio² , Marlon David González Ramírez³ , Elizabet García Álcantara¹

¹Tecnológico Nacional de México (TecNM): Tecnológico de Estudios Superiores de Jocotitlán, Carretera Toluca-Atlacomulco KM 44.8 Ejido de San Juan y, San Agustín, 50700 Cdad. de Jocotitlán, Méx.

²Tecnológico Nacional de México (TecNM): Instituto Tecnológico de Toluca, Av Tecnológico 100-s/n, Agrícola, 52149 Metepec, Méx.

³Instituto Politécnico Nacional (IPN), Centro de Innovación y Desarrollo Tecnológico en Cómputo, CIDETEC. Av. Luis Enrique Erro S/N, Unidad Profesional Adolfo López Mateos, Zacatenco, Alcaldía Gustavo A. Madero, C.P. 07738, Ciudad de México

(recibido/received: 23-02-2025; aceptado/accepted: 19-06-2025)

RESUMEN

Las heridas crónicas y superficiales afectan gravemente la calidad de vida de pacientes, especialmente diabéticos y ancianos, y requieren monitoreo constante para evitar complicaciones. Este trabajo propone un método de aprendizaje profundo basado en YOLOv7 para la detección automática de heridas superficiales (cortes, raspones y magulladuras) en imágenes, como primera etapa para un sistema robótico que tendrá un dispositivo basado en un plasma de helio el cual pueda ayudar a cicatrizar la herida detectada. Utilizando un dataset de 266 imágenes de heridas superficiales, el modelo fue entrenado durante 100 épocas, alcanzando una precisión promedio de 93% (mAP@0.5). Los resultados muestran un rendimiento prometedor en la localización de heridas, independiente del fondo, con un F1-score de 0.90. Este enfoque no invasivo tiene el potencial de mejorar la atención médica al proporcionar una detección precisa, sentando las bases para la automatización de tratamientos de cicatrización.

Palabras clave: detección de heridas, YOLOv7, raspones, cortes, magulladuras

ABSTRACT

Chronic and superficial wounds significantly impact the quality of life of patients, particularly those with diabetes and the elderly, requiring constant monitoring to prevent complications. This study proposes a deep learning method based on YOLOv7 for the automatic detection of superficial wounds (cuts, scrapes, and bruises) in images, as the first stage of a robotic system equipped with a helium plasma device to assist in healing the detected wounds. Using a dataset of 266 images of superficial wounds, the model was trained over 100 epochs, achieving an average precision of 93% (mAP@0.5). The results demonstrate promising

* Autor de correspondencia.
Correo: juan.antonio@tesjo.edu.mx

performance in wound localization, regardless of the background, with an F1-score of 0.90. This non-invasive approach has the potential to enhance medical care by enabling fast and accurate detection, laying the groundwork for the automation of wound healing treatments

Keywords: Wound detection, YOLOv7, scrapes, cuts and bruises.

1. INTRODUCCIÓN

Las heridas, tanto crónicas como superficiales, representan un problema de salud significativo que puede afectar gravemente la calidad de vida de los pacientes, especialmente en poblaciones vulnerables como diabéticos y ancianos. Estas heridas, son causadas frecuentemente por accidentes (García-Fernández y otros, 2022), que incluyen cortaduras, desgarres, quemaduras, contusiones, choques eléctricos, quemaduras por frío o calor, y supresión del flujo sanguíneo, que pueden derivar en complicaciones graves si no se tratan adecuadamente (Yazici, 2024).

Estas lesiones pueden originarse por una amplia variedad de causas, incluyendo cortaduras, desgarros, quemaduras, contusiones, choques eléctricos, y alteraciones en el flujo sanguíneo. Su adecuada atención requiere procesos de limpieza, desinfección y uso de antisépticos para evitar infecciones y promover la cicatrización (Falanga y otros, 2022). En heridas de al menos 0.5 cm de profundidad, se considera clínicamente significativa la necesidad de un tratamiento específico para prevenir complicaciones como infecciones o daño a tejidos subyacentes como tendones o nervios e incluso huesos. A pesar de la disponibilidad de técnicas convencionales como la suturación, estas suelen generar cicatrices permanentes cuando no se atienden de forma óptima, lo cual resalta la necesidad de mejorar los métodos actuales de tratamiento. Mientras que las cortaduras de más profundidad las cuales se clasifican como heridas con cavidades significativas que requieren tratamiento quirúrgico especializado para iniciar la cicatrización.

La cicatrización temprana y adecuada de las heridas cutáneas es un desafío común, y los métodos tradicionales, como la suturación, a menudo resultan en cicatrices permanentes debido a procedimientos subóptimos. En los últimos años, se ha intensificado la investigación en nuevas técnicas para la cicatrización eficiente de heridas utilizando tecnologías biomédicas avanzadas. Por ejemplo, (Masri & Fauzi, 2021) y (Bhardwaj y otros, 2017) han documentado métodos modernos para promover la cicatrización temprana, aunque muchos de estos aún presentan limitaciones como el desgaste físico del operador y latencia en los resultados. Entre los desarrollos recientes, destacan los trabajos de (Puri y otros, 2024) y (Martines y otros, 2020), quienes han explorado el uso de plasma de helio y argón aplicado manualmente en heridas, con resultados positivos en modelos animales. No obstante, debido a que este procedimiento debe aplicarse durante períodos prolongados (8 horas), su implementación resulta tediosa tanto para el profesional de salud como para el paciente. Estas limitaciones subrayan la necesidad de automatizar tanto la detección como la aplicación de tratamientos de cicatrización, minimizando la intervención humana y mejorando la eficiencia del proceso.

En este contexto, el objetivo de este trabajo es desarrollar un sistema mediante técnicas de inteligencia artificial no invasiva, empleando el modelo de detección de objetos con YOLOv7, para detectar automáticamente heridas superficiales (cortes, raspones y magulladuras) en imágenes, como primera etapa para un sistema robótico de cicatrización. El objetivo es generar una solución capaz de localizar con precisión las coordenadas de la herida y enviar esta información a un sistema robótico, que posteriormente pueda aplicar el tratamiento con plasma sin intervención humana prolongada. Esta propuesta no solo busca optimizar el proceso de cicatrización sino también reducir el esfuerzo físico del personal médico y mejorar la experiencia del paciente, sentando las bases para una futura implementación clínica de tecnologías robóticas en el tratamiento de heridas.

1.1. Clasificación del reconocimiento de los tipos de heridas mencionadas en la literatura

La medicina moderna ha desarrollado diversos métodos para promover la cicatrización de heridas cutáneas, aprovechando tanto los mecanismos naturales del cuerpo como tecnologías innovadoras. Según (Moholkar y otros, 2021), los nanosistemas biopoliméricos, como aquellos basados en quitina, quitosano, colágeno, alginato, fucoidan, gelatina, fibroína de seda y ácido hialurónico, son agentes prometedores para la curación de heridas. Estos materiales crean un entorno óptimo que acelera el proceso de cicatrización al mejorar la regeneración tisular. El estudio destaca los avances recientes en estos agentes, evaluando su idoneidad para aplicaciones clínicas.

Por otro lado, el monitoreo del proceso de cicatrización es fundamental para evaluar el progreso y ajustar los tratamientos. (Masson-Meyers y otros, 2018), describen diversas técnicas de monitoreo, incluyendo imágenes, evaluaciones biofísicas, histopatología y ensayos bioquímicos, empleadas en modelos clínicos y animales. Estas herramientas permiten un seguimiento preciso de la evolución de las heridas, facilitando intervenciones oportunas.

Además de los avances en materiales y monitoreo, las técnicas de detección y segmentación de imágenes han revolucionado el análisis de heridas cutáneas. Estas metodologías buscan localizar, extraer y delimitar los píxeles correspondientes a una lesión. Por ejemplo, (Chino y otros, 2020), implementaron redes neuronales convolucionales (CNN) para segmentar úlceras cutáneas en pacientes encamados, permitiendo un análisis remoto desde entornos domésticos. De manera similar, (Ramachandram y otros, 2022) desarrollaron AutoTrace, una red de segmentación de tejidos basada en un modelo codificador-decodificador, implementada en una aplicación Android para facilitar su uso clínico.

En el ámbito de la reconstrucción tridimensional, (Filko y otros, 2016) diseñaron un prototipo que utiliza el sensor Kinect v2 para detectar, reconstruir en 3D y segmentar imágenes de heridas crónicas. Este sistema emplea histogramas de color y un enfoque de vecino más cercano para clasificar tejidos, seguido por el algoritmo Marching Cubes para generar una malla de superficie. El resultado es un sistema capaz de ofrecer diagnósticos y tratamientos precisos para heridas crónicas. Por su parte, (Foltynski & Ladyzynski, 2023) propusieron un servicio automático para medir el área de heridas mediante fotografías digitales con marcadores de calibración. Su modelo, basado en CNN y entrenado con 565 imágenes de heridas, logra una precisión del 99.3% en la segmentación y medición, utilizando calibración adaptativa para superficies curvas. Los usuarios pueden enviar imágenes a través de una plataforma en línea para su análisis, lo que facilita el seguimiento remoto de la cicatrización.

En el estudio de (Scebba y otros, Detect-and-segment: A deep learning approach to automate wound image segmentation, 2022), se presenta un enfoque denominado Detect-and-Segment (DS), basado en técnicas de aprendizaje profundo. Este método genera mapas de segmentación de heridas con alta capacidad para detectar su ubicación, aislarlas del entorno y posteriormente segmentarlas con precisión. El modelo fue evaluado utilizando un conjunto de datos de úlceras del pie diabético, comparando su rendimiento con la segmentación de heridas sobre imágenes completas. Los resultados demostraron que el sistema es capaz de segmentar correctamente el 90% de las imágenes analizadas, contribuyendo significativamente a la automatización del análisis de heridas crónicas.

Por su parte (Blanco y otros, 2020), proponen una técnica basada en superpíxeles combinada con modelos de aprendizaje profundo para la segmentación de heridas. El enfoque consiste en parametrizar diversas imágenes y evaluarlas experimentalmente. El método permite tanto la segmentación del tejido como la cuantificación precisa del área lesionada. En total, se realizaron 179,572 evaluaciones empíricas, clasificadas en cuatro categorías. Los resultados obtenidos incluyen un AUC de 0.986, sensibilidad de 0.97 y especificidad de 0.974. Además, superaron los enfoques tradicionales en un 8.2% en cuanto al F1-score.

Las evaluaciones demostraron que el valor del índice QTDU permitió cuantificar con precisión las áreas de tejido lesionado, con un margen de error del 0.089.

1.2. Clasificación de tipos de heridas y formas de catrizar las heridas

En esta sección se describen los distintos tipos de heridas documentados en la literatura, los cuales han sido objeto de análisis mediante herramientas tecnológicas orientadas a su medición y evaluación. Para comprender adecuadamente estos enfoques tecnológicos, es necesario primero identificar los tipos de heridas y sus causas. Una herida abierta puede generarse por diversas causas que provocan una ruptura interna o externa del tejido en cualquier parte del cuerpo. Ejemplos comunes incluyen caídas, accidentes con objetos punzocortantes, entre otros. En casos más graves, las heridas pueden afectar tejidos profundos, provocar hemorragias intensas y requerir atención médica urgente, especialmente si el sangrado no se detiene en un periodo aproximado de 20 minutos. Debido a su gravedad y características clínicas, las heridas abiertas han sido clasificadas por diversos autores. Según (Lindholm & Richard, 2016), estas heridas pueden agruparse en las siguientes categorías descritas en la Tabla 1:

Tabla 1 Clasificación de heridas y causas comunes que los ocasionan.

Tipo de herida	Descripción	Causas Comunes	Referencia
Abrasión	Lesión superficial de la piel causada por fricción o impacto	Caídas, accidentes deportivos, contacto con superficies rugosas	(Shrestha y otros, 2023)
Laceración	Corte profundo o desgarro de la piel y tejidos subyacentes	Objetos punzocortantes, accidentes laborales, traumatismos	(Ishii y otros, 2022)
Punción	Herida profunda causada por un objeto puntiagudo que penetra la piel	Clavos, agujas, mordeduras de animales	(M. Miller & K. Abraham, 2024)
Desgarro	Desgarro parcial o completo de tejido, separando la piel del cuerpo.	Accidentes de tráfico, lesiones deportivas de alta energía	(Raj M.D y otros, 2015)

En lo que se refiere al proceso de curación o cicatrización usados en la actualidad, aún es necesario recurrir generalmente a suturas (puntos) en el caso de que la incisión se haya abierto o comprometa la integridad del tejido. Generalmente, los cortes que superan los 4 mm deben requerir intervención con sutura, mientras que incisiones mayores a 6 mm ameritan evaluación médica especializada. En estos casos, es común utilizar suturas o adhesivos dérmicos para cerrar adecuadamente la herida. Las heridas abiertas que potencialmente requieran sutura deben ser evaluadas lo antes posible; idealmente, dentro de las primeras seis horas posteriores a la lesión, con el fin de reducir el riesgo de infecciones (Lin y otros, 2020). Por otro lado, el estudio de las heridas crónicas representa un campo de gran relevancia, ya que este tipo de lesiones afecta a millones de personas en todo el mundo.

Aunque la observación visual continúa siendo el método más común para el diagnóstico preliminar de heridas crónicas y agudas. Esta evaluación suele apoyarse en escalas estandarizadas como el Bates-Jensen Wound Assessment Tool (BJWAT) (Bates y otros, 2019), la clasificación de úlceras por presión de la NPUAP (Aldughayfiq y otros, 2023), y la escala de Wagner para heridas diabéticas (Jalilian & Shiri, 2022). Sin embargo, estas herramientas no permiten determinar si una herida se encuentra en fase regenerativa o si se trata de una lesión reciente, lo cual resulta crítico, considerando que muchas heridas crónicas detienen su proceso de curación en la fase inflamatoria. Lamentablemente, los métodos actuales de diagnóstico no

pueden predecir de manera confiable la evolución del tratamiento ni la fase de recuperación, lo que convierte el proceso diagnóstico en un acto dependiente de la experiencia del profesional médico (Wang y otros, 2017). Además del examen visual clínico, han surgido herramientas digitales de evaluación de heridas que emplean imágenes bidimensionales y tridimensionales. Estas herramientas permiten una cuantificación precisa de diversos parámetros de la herida, y han demostrado una alta efectividad en la evaluación morfológica sin contacto físico. En consecuencia, los enfoques de imagenología no invasiva mediante cámaras se han vuelto especialmente populares, al ofrecer una alternativa más precisa y menos intrusiva que los métodos tradicionales basados en cintas métricas o sondas de profundidad (Casas y otros, 2015). Entre estas técnicas, destaca la planimetría digital, la cual permite medir el área de las heridas mediante imágenes planas obtenidas de cámaras digitales. Este método puede cuantificar, con alta precisión, el porcentaje de epitelización, tejido necrótico y tejido sano, como se observa en la Figura 1. La planimetría digital ha demostrado ser efectiva para realizar mediciones repetidas sin diferencias estadísticamente significativas en la precisión, y representa una herramienta útil en el seguimiento del proceso de cicatrización (Foltynski P. y otros, 2015). No obstante, a pesar de su eficacia en la cuantificación, ninguna de las técnicas actuales es capaz de predecir el avance completo del proceso de curación.

Comprender las ventajas y limitaciones de los métodos actuales basados en visión artificial y sistemas automáticos o semiautomáticos, en la de detección de heridas, permitirá el desarrollo de técnicas de imagen más precisas y eficientes. Un diagnóstico eficaz contribuye significativamente a mejorar los tratamientos, acelerar la cicatrización y reducir considerablemente los costos asociados a la atención médica. Es por eso que la tecnología se convierte, en este sentido, en una herramienta fundamental para apoyar tanto el diagnóstico como el monitoreo de las heridas durante su proceso de curación (Zahia y otros, 2020) (Zhang y otros, 2022) (Nira & Kumar, 2022). Un resumen comparativo de estos métodos se presenta en la Tabla 2.

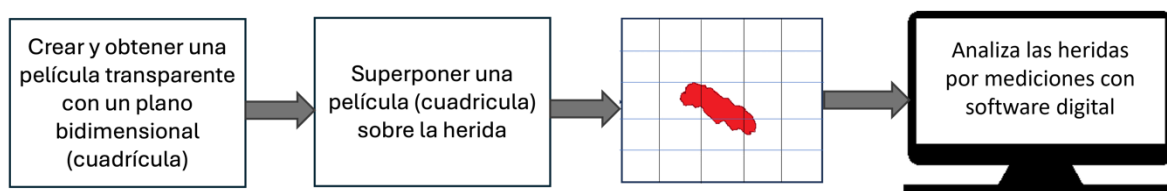


Figura 1. Esquema paso a paso del análisis de heridas usando la técnica de planimetría digital.

Tabla 2. Ventajas y desventajas del uso de las técnicas de medición de heridas.

Método		Ventajas	Desventajas
Imágenes de Heridas	Uso de la fotografía digital para medir y analizar el tamaño y las dimensiones de las heridas.	Medición de contacto no invasivo en la herida. Con predictibilidad de curación a corto plazo.	Carece de previsibilidad a largo plazo del potencial de curación.
Planimetría Digital	Trazar el margen de la herida con películas transparentes (cuadrícula) y, a continuación, contar manualmente el número de casillas de las celdas ocupadas total o parcialmente por las heridas o el área de la herida. El trazado también puede importarse al sistema computacional para calcular el área de la herida mediante un programa informático.	Gran precisión en la medición del tamaño de la herida.	Requiere contacto con la herida (invasivo). Sólo permite la medición bidimensional de la herida.

2. ARQUITECTURA YOLO

El algoritmo YOLO (You Only Look Once) es uno de los enfoques más influyentes en la detección de objetos en tiempo real. A lo largo de su evolución, se han desarrollado más de siete versiones, cada una incorporando mejoras significativas en precisión, velocidad y eficiencia computacional. En sus primeras etapas, los creadores de YOLO redefinieron el problema de detección de objetos como un problema de regresión, en lugar de clasificación, utilizando redes neuronales convolucionales (CNN) para predecir simultáneamente los cuadros delimitadores y las probabilidades de clase de múltiples objetos dentro de una imagen. YOLO se caracteriza por su capacidad para procesar una imagen completa en una sola pasada, lo que permite identificar objetos y determinar sus ubicaciones mediante el uso de cuadros delimitadores (bounding boxes). Las CNN utilizadas en YOLO son altamente efectivas en la extracción jerárquica de características visuales, ya que permiten que la información de bajo nivel fluya eficientemente desde las capas iniciales a las más profundas. Esto resulta crucial al momento de reconocer múltiples objetos dentro de una imagen, así como para predecir con precisión sus ubicaciones.

El enfoque de YOLO divide la imagen en una cuadrícula $S \times S$ (Figura 2). Cada celda de la cuadrícula predice B cuadros delimitadores, incluyendo sus coordenadas centrales (b_x, b_y), dimensiones (b_w, b_h), una puntuación de confianza y probabilidades de clase p_c . Por tanto, el tensor de salida tiene la forma $S \times S \times (B \times 5 + n)$, siendo n el número de clases. Este diseño permite identificar objetos con una única entrada visual, evitando múltiples pasadas.

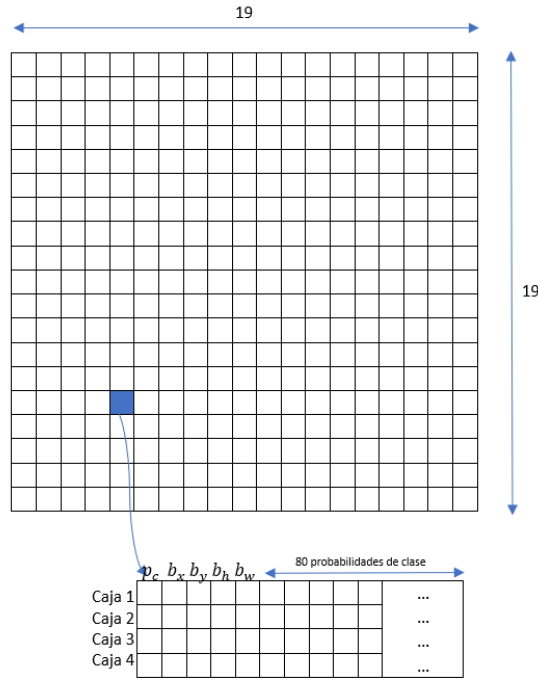


Figura 2. División de la imagen en celdas de cuadrícula y predicciones correspondientes a una celda de cuadrícula (Negussie Tesema & Bourennane, 2021).

Un elemento clave del modelo es la implementación de cuadros de anclaje (anchor boxes), que permiten capturar objetos de distintas formas y tamaños mediante un conjunto estándar de relaciones de aspecto. A pesar de su eficacia, este enfoque puede conducir a predicciones duplicadas del mismo objeto, dado que múltiples celdas adyacentes podrían identificar el mismo centroide. Para mitigar este problema, se aplican técnicas de supresión no máxima (Non-Maximum Suppression, NMS), que filtran los cuadros con baja puntuación de confianza (usualmente con un umbral de 0.5) y descartan aquellos redundantes con IoU bajo.

2.1. Descripción de YOLO-v7.

YOLO-v7 es la séptima generación de los detectores de una sola vista. YOLO-v5 está implementado con Pytorch y puede trabajar computacionalmente con tensores implementados con GPU y TPU. You Only Look Once (YOLO) es un sistema avanzado de detección de objetos en tiempo real. El modelo YOLO versión 7 (YOLOv7) es una variante actualizada de YOLOv6. El objetivo de este trabajo es aplicar YOLOv7 a las tareas de detección y segmentación de imágenes de cualquier tipo de formato como png y jpg. Los datos obtenidos mostraron que YOLOv7 tuvo un mejor rendimiento en velocidad y precisión, con $mAP \geq 0.95$, que otras versiones anteriores de Yolo con lo que se hace 120% más rápido que sus antecesores.

El presente proyecto se realizó en una versión de YOLOv7, a pesar de las versiones más recientes como YOLOv12, YOLOv7 representa un equilibrio ideal entre precisión, velocidad y estabilidad para tareas prácticas de detección de objetos (Figura 3). YOLOv7 fue desarrollado con base a PyTorch, aprovechando las características de procesamiento por GPU y TPU, teniendo un rendimiento con una media de precisión promedio (mAP) superior a 0.95, superando significativamente las versiones previas. Aunque YOLOv12, es más reciente, se encuentra aún en fase experimental y puede presentar complejidad adicional en la implementación, mayor requerimiento computacional y una menor disponibilidad de documentación y soporte. Por ello, se opta por YOLOv7 al ofrecer una relación óptima entre rendimiento y recursos necesarios, facilitando su uso en la detección de heridas. YOLOv7 fue preentrenada en COCO y se utilizan los datos obtenidos desde Kaggle y la recolección de imágenes de una clínica médica. La estructura de la red en YOLOv7 consiste en las primeras 20 capas convolucionales presentes en la Figura 4, que se utilizan para el entrenamiento previo, seguidas de los promedios grupales y las capas completamente conectadas; luego, el modelo resultante se transforma para lograr la detección de objetos.

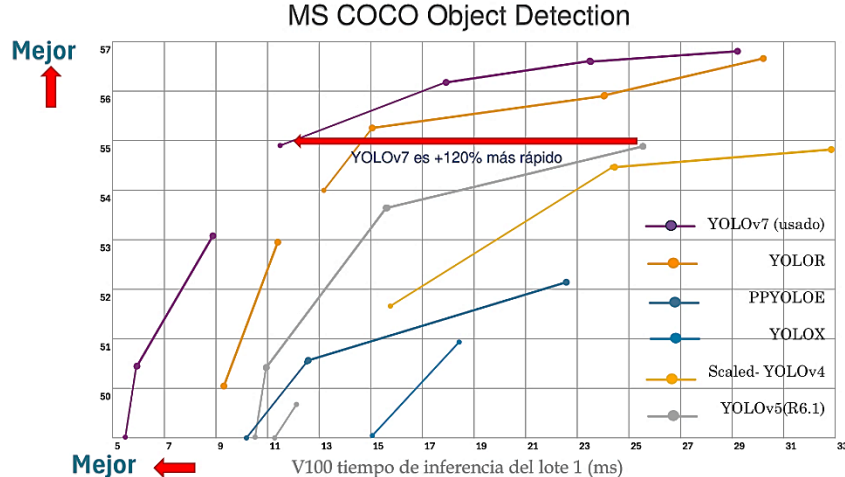


Figura 3. Comparación de YOLOv7 con otros detectores de YOLO en tiempo real, donde se muestran métodos propuestos que alcanzan un mejor rendimiento

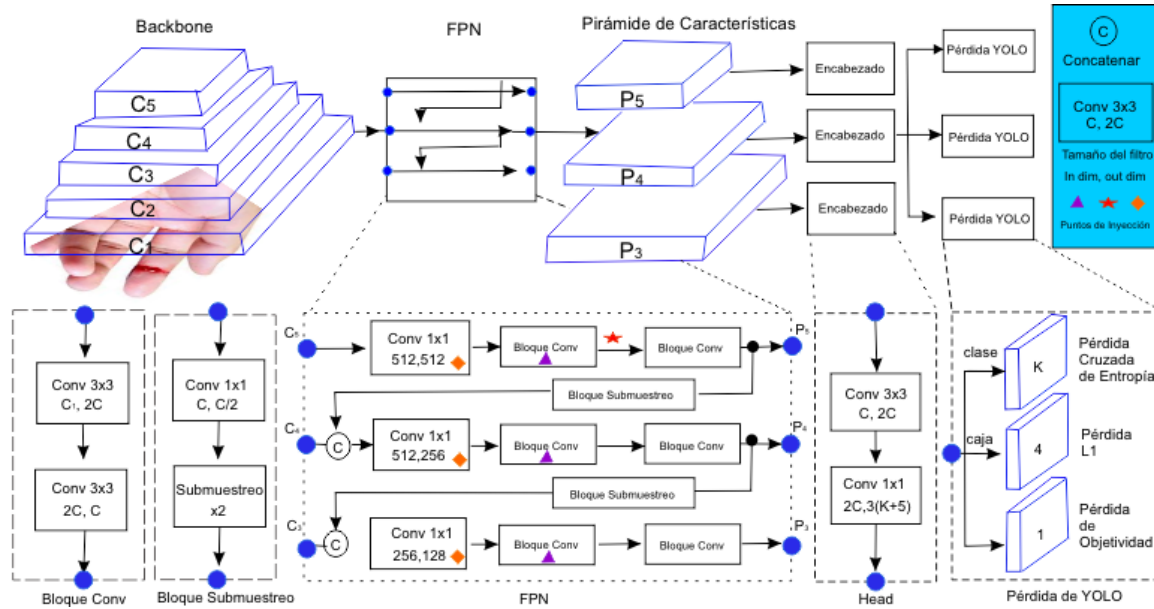


Figura 4. Arquitectura de una red neuronal Yolo con sus capas convolucionales.

Se agregan 4 nuevas capas convolucionales y 2 capas completamente conectadas con pesos inicializados aleatoriamente a la implementación de detección de objetivos. La última capa de la red predice las probabilidades de clase y las coordenadas del cuadro de reconocimiento; Para este paso, la altura y el ancho del cuadro de reconocimiento se normalizan con respecto a los parámetros de la imagen para que sus valores permanezcan entre 0 y 1. En la última capa, se utiliza una función de activación que utiliza la suma de errores al cuadrado para el mejoramiento. La función de activación que utiliza YOLOv7, se llama Leaky ReLU (Leaky Rectified Linear Unit, or Leaky ReLU), es una función de activación basada en ReLU, pero tiene una pendiente pequeña para valores negativos en lugar de una pendiente plana. El coeficiente de pendiente se determina antes del entrenamiento, es decir, no se aprende durante el entrenamiento. Este tipo de función de activación es popular en tareas en las que podemos sufrir gradientes escasos, por ejemplo, entrenar redes generativas adversarias.

2.2. Adquisición de imágenes de heridas para conformar el dataset.

El propósito de esta investigación es realizar una detección de imágenes de heridas de la piel, es por eso que este estudio utiliza un conjunto de datos obtenidos de Kaggle (Jeong y otros, 2025). Aunque en la actualidad no existe ningún conjunto de datos público (Scebba y otros, 2022), lo suficientemente grande como para entrenar modelos basados en aprendizaje profundo para la segmentación de heridas, también se optó por recolectar las imágenes de una clínica colaboradora con consentimiento informado de los pacientes. Para tema de análisis se eligieron como tema de estudio las heridas de tipo cortada y raspones; donde dichas imágenes muestran heridas no tan profundas y además estas heridas no son contusas y muestran sangre en demasía los cuales pueden causar sensibilidad en algunas personas. Como se comentó las desventajas de la búsqueda de estas imágenes radica en que no existen datasets, es por eso que se aplicó aumento de datos como rotaciones y cambios de iluminación para mejorar la generalización del modelo los cuales serán útiles entrenar el sistema y para que en la tercera etapa de la investigación funcione y que al detectar la herida se use un dispositivo robótico que ayudará a la cicatrización mediante emisión de un haz de luz basado en Helio-Argón mencionado por (Garcia-Alcantara y otros, 2013).

En la Figura 5, se muestran algunos ejemplos de heridas con lo cual se entrenó la red en YOLOv8, este tipo de heridas corresponden a raspaduras y cortes no profundos.

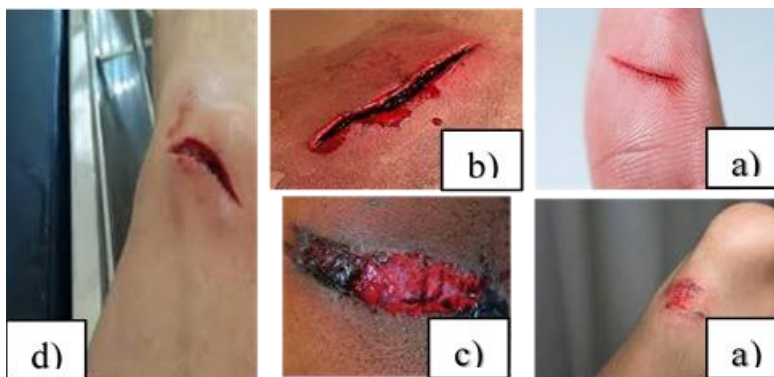


Figura 5. Ejemplo de imágenes que componen el dataset de heridas correspondiente a: a) Laceración, b) Punción, c) Desgarro, d) Abrasión

Durante el entrenamiento, un modelo de aprendizaje profundo aprende de las anotaciones con cuadro delimitadores del conjunto de datos de entrenamiento. Por lo tanto, la calidad de las anotaciones es esencial. Las anotaciones realizadas a todas las imágenes que contienen las heridas por cortada y por raspones se entrenan para aprender cómo un experto humano reconoce la región que tiene la herida. En nuestro conjunto de datos, las imágenes se anotaron manualmente y verificadas con un cuadro delimitador (bounding box) el cual encierra la región de interés (ROI), estas heridas fueron revisadas y verificadas por un médico general de una clínica colaboradora. Inicialmente, sólo se anotaron e incluyeron en el conjunto de datos las imágenes de heridas por cortadas y raspones ocurridos generalmente en piernas, brazos y el rostro ya que suelen ser más pequeñas que otros tipos de heridas crónicas, lo que facilita y reduce el tiempo de anotación manual de las máscaras de segmentación por píxeles.

2.3. Anotación de cuadros delimitadores en cada imagen y entrenamiento.

El software de anotación de cuadros delimitadores usado en esta investigación (Bounding box), es MakeSense el cual se muestra en la Figura 6, sirvió para hacer la anotación de cada imagen seleccionada del dataset (Figura 7), cada anotación de las heridas se almacenó en dos diferentes directorios útiles para el entrenamiento en YOLOv7, estos directorios son TRAIN y VAL.

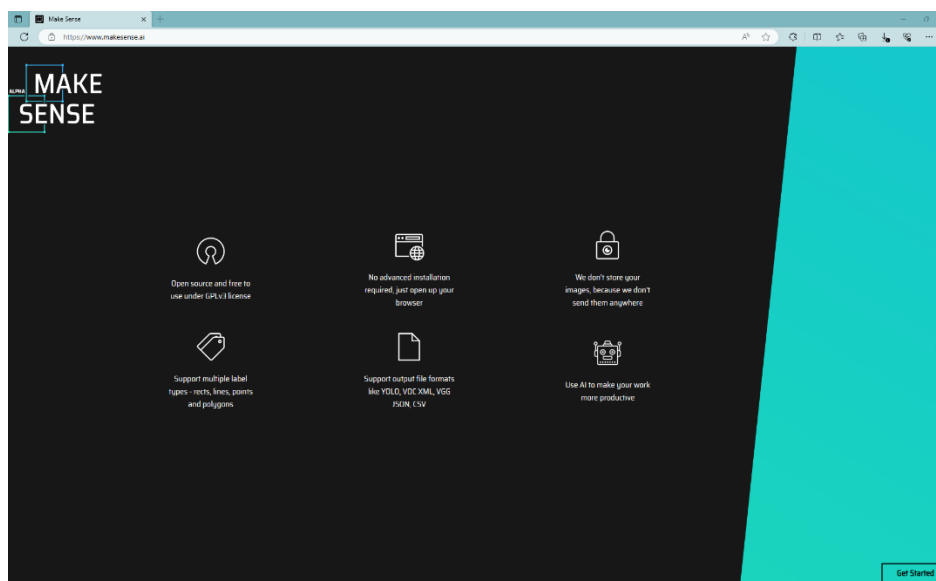


Figura 6. Software basado en web para la anotación de imágenes con Make sense (Skalski, 2019)

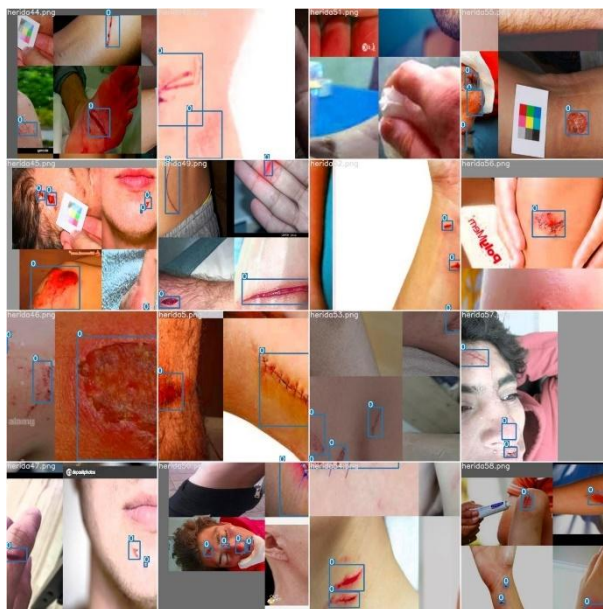


Figura 7. Ejemplos de imágenes con anotaciones de cuadros delimitadores, realizado con make-sense.

3. METODOLOGÍA EMPLEADA EN LA DETECCIÓN AUTOMÁTICA DE HERIDAS

Este capítulo detalla el desarrollo de un sistema automatizado para detectar heridas superficiales en imágenes mediante el modelo YOLOv7. El proceso inició con la recolección de 266 fotografías obtenidas de bases de datos públicas (Kaggle) y entornos hospitalarios, las cuales fueron meticulosamente anotadas, usando la herramienta MakeSense. Estas imágenes se dividieron en dos conjuntos: 186 para entrenamiento y 80 para validación.

El entrenamiento del modelo se configuró con 100 épocas y un batch size de 10, optimizado bajo el framework PyTorch en Google Colab con aceleración por TPUs. Centrado en una única clase ("herida"), el sistema fue evaluado con métricas robustas como precisión, recall, F1, IoU y mAP, asegurando su fiabilidad. Los resultados evidenciaron un modelo eficiente y escalable, con potencial para integrarse en entornos clínicos y sistemas de telemedicina, donde la detección precisa de heridas puede optimizar diagnósticos y seguimientos. En las siguientes subsecciones se profundiza en cada etapa metodológica y se analizan los resultados obtenidos.

3.1. Diagrama de etapas utilizado en este proyecto.

A continuación, se muestran las etapas, con las que funciona el sistema propuesto (Figura 8), útil para que pueda reconocer imágenes de heridas superficiales del cuerpo.

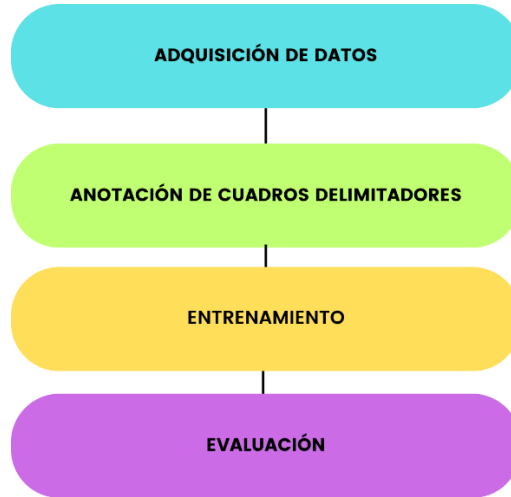


Figura 8. Diagrama de etapas que muestra el flujo de procesamiento usada en la detección automática de heridas

Explicación de las etapas para la detección de heridas:

- Adquisición de datos de imágenes de heridas, desde Kaggle u obtenidas de pacientes.
- Anotación manual de cada imagen de herida para conformar el cuadro delimitador con MakeSense
- Entrenamiento del conjunto de imágenes con YOLOv7
- Evaluación de imágenes de heridas (redimensionadas 640x640 píxeles) que no se encuentran en el conjunto de entrenamiento y mediante métricas de rendimiento.

4. RESULTADOS Y DISCUSIÓN

Para entrenar las imágenes de las heridas fue necesario entrenar 266 imágenes de las características mencionadas en la sección 1, y los cuales fueron divididos en 186 para entrenamiento y 80 para validación, utilizamos YOLOv7 como nuestro modelo de localización de heridas. Este modelo se elige por su popularidad, confiabilidad y gestión del tiempo para la detección de objetos. Usamos una sola etiqueta de clase, llamada "herida" para nuestro entrenamiento de modelo. Este modelo está entrenado para 100 épocas con un tamaño batch size de 10. Todos los modelos se escribieron en el lenguaje de programación Python utilizando el marco de aprendizaje profundo Pytorch y se entrenaron en una plataforma TPU (Tensor Processing Units) utilizando un notebook de Google Colab.

4.1. Métricas de rendimiento.

Para este proyecto se han propuesto las métricas de evaluación más comunes para validar el resultado de detección de heridas usando: precisión, recuperación, puntuación F1, intersección sobre unión (IoU) y precisión promedio media (mAP) como métricas de evaluación para evaluar el rendimiento de la localización. A continuación, se ofrece una breve descripción de estas métricas:

1) Intersección sobre Unión (IoU)

La intersección sobre la unión mide la superposición entre el cuadro de verdad fundamental (enrollado manualmente localizado con labelImg) y el cuadro previsto (resultado del modelo), sobre su unión. El IoU se calcula con la ecuación (1).

$$IoU = \frac{GroundTruthBox \cap PredictBox}{GroundTruthBox \cup PredictBox} \quad (1)$$

2) Precisión, recuperación y puntuación F1

Para definir las puntuaciones de Precisión, Recuperación y F1, establecemos un umbral de IoU en 0,5. Si $\text{IoU} > 0.5$, se dice que el resultado es verdadero positivo. Si $\text{IoU} < 0.5$, el resultado es falso positivo. Si $\text{IoU} > 0.5$ y la herida se clasifica incorrectamente, entonces el resultado es falso negativo. Precisión y recuperación muestran la exactitud de la localización. Se seleccionó un umbral de $\text{IoU}=0.5$, estándar en tareas de detección de objetos, para equilibrar precisión y sensibilidad

$$\text{Precision} = \frac{\text{True positive}}{\text{TruePositive} + \text{FalsePositive}} \quad (2)$$

$$\text{Recall} = \frac{\text{True positive}}{\text{TruePositive} + \text{FalseNegative}} \quad (3)$$

$$\text{F1} = 2 \times \frac{\text{precision} \times \text{recall}}{\text{Precision} + \text{Recall}} \quad (4)$$

La precisión mide el porcentaje de imágenes correctamente detectadas en la localización de la herida, mientras que Recall mide el porcentaje de imágenes correctamente localizadas en la realidad del groundtruth. La puntuación F1 es el promedio ponderado de precisión y recuperación. Una puntuación F1 más alta indica un mejor rendimiento. Las ecuaciones (2), (3) y (4) muestran las definiciones de las métricas de puntuación Precisión, Recuperación y F1 respectivamente. y (4) muestran las definiciones de las métricas de puntuación de precisión, recuperación y F1, respectivamente.

4.2. Resultados obtenidos.

Las pruebas realizadas fueron aplicadas a una prueba de 80 imágenes que contienen heridas superficiales, como se había comentado anteriormente que se trata de heridas de corte y heridas ocasionadas por raspones. A continuación, se muestran los resultados de detección en las heridas, para lo cual se le aplicaron las métricas de rendimiento. En la Figura 9 se pueden ver los resultados de detección de las heridas ocasionadas por corte, como se puede ver el porcentaje de detección alcanza un aproximado del 90%, salvo en la imagen etiquetada como herida22 con el que se obtuvo un porcentaje del 70%.



Figura 9. Imágenes de heridas ocasionadas por corte en las imágenes 21, 22 y 60, donde se pueden ver resultados del 70% y 90%.

En la Figura 10, se muestran las imágenes de las heridas ocasionadas por raspaduras en las cuales se alcanzan los resultados del 90% en la imagen con la etiqueta herida56, en la imagen etiquetada como herida69 se muestra un porcentaje cercano al 80%, sin embargo, en la imagen con la etiqueta herida71, contiene 3 heridas por raspones en una sola parte del cuerpo del cual se obtienen 3 resultados del 40%, 80% y 90%.

La Tabla 3 muestra la evolución de las métricas de pérdida y mAP durante el entrenamiento, destacando una mejora constante hasta alcanzar $\text{mAP}@0.5 = 0.615$ en la época 50.



Figura 10. Imágenes de heridas ocasionadas por raspones en las imágenes 56, 69 y 71, donde se pueden ver resultados desde el 40%, 80% y 90%

Tabla 3. desempeño del modelo por época, incluyendo las métricas de pérdida, precisión y mAP en el entrenamiento y validación

Epoch	Train Box Loss	Train Cls Loss	Train DFL Loss	mAP50(B)	mAP50-95(B)
1	1.9566	3.3419	1.8337	0.20812	0.07421
10	2.0997	2.258	1.9839	0.00018	0.00008
20	1.8772	1.8515	1.8046	0.38359	0.16092
30	1.7846	1.6719	1.7454	0.44305	0.19423
40	1.7012	1.4614	1.6673	0.47993	0.20279
50	1.6665	1.3012	1.6289	0.61545	0.2915

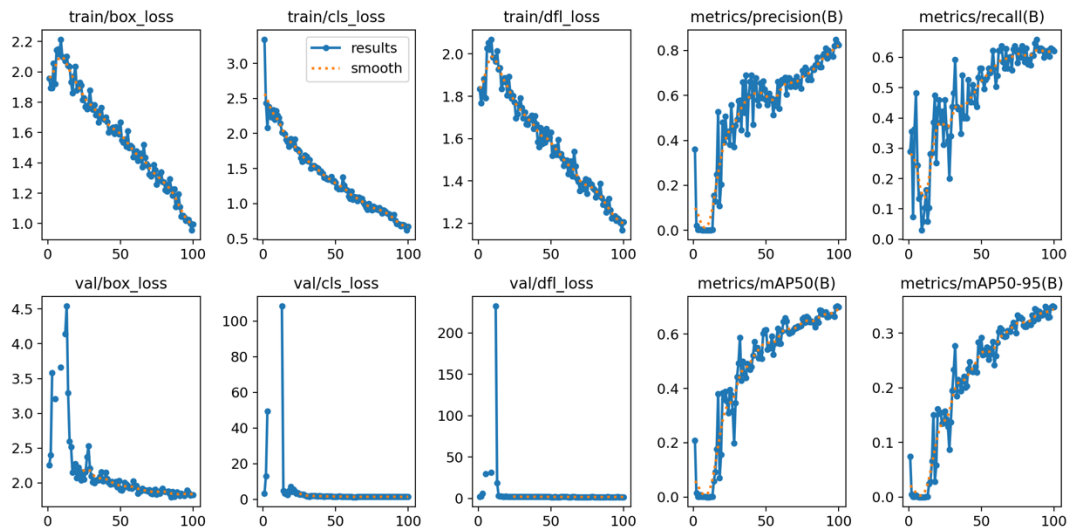


Figura 11. Gráficas que muestran los resultados obtenidos en la aplicación de 100 epochs en el entrenamiento de las imágenes que contienen heridas

El resultado que muestra la matriz de confusión 2x2 (Figura 12), la celda TP (verdaderos positivos) es la celda izquierda se obtuvo un resultado de 93%, para la celda derecha FP (Falsos positivos), se obtiene un resultado del 43% y para la celda inferior izquierda FN (Falsos negativos) se obtiene un resultado del 42% y para el caso de la celda inferior derecha TN (Falsos negativos) el resultado es 0 ya que es el background (Fondo).

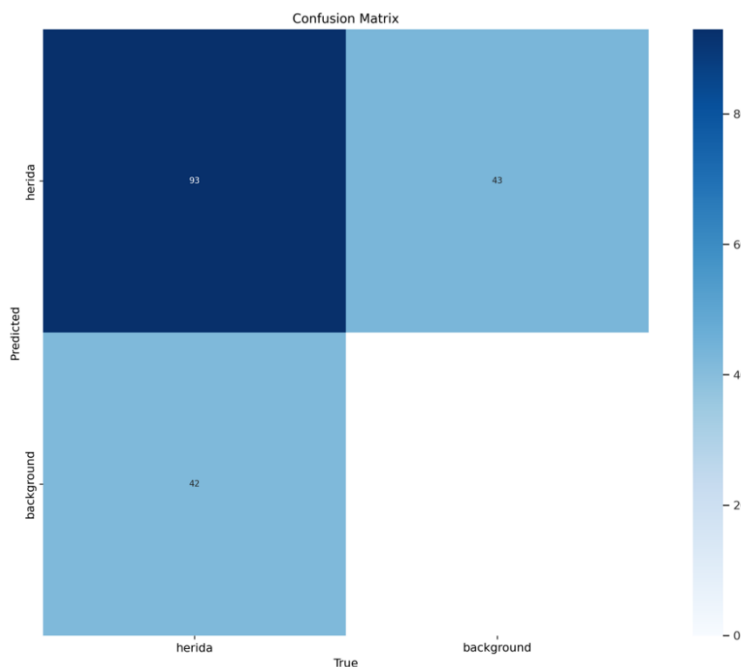


Figura 12. Matriz de confusión que muestra los resultados obtenidos en la detección de heridas

La evaluación de un modelo de detección de las imágenes que tienen heridas nos proporciona información valiosa sobre el rendimiento del modelo en varios valores de confianza. Del mismo modo, la puntuación F1 es especialmente útil para determinar la confianza óptima que equilibra los valores de precisión y recuperación para ese modo dado; sin embargo, el valor abarca un dominio de valores de confianza de 0 a 1 (Figura 13). Las gráficas muestran la puntuación de precisión (Figura 14), de clase única para el modelo de detección de heridas propuesto usando YOLOv7.

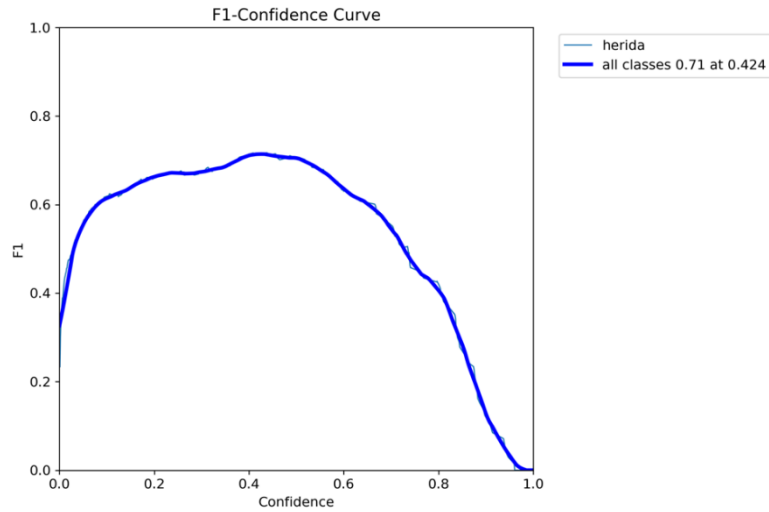


Figura 13. Gráfica del resultado al aplicar la formula del cálculo de F1 para el modelo de detección

La Figura 15, se observa que el modelo alcanza un valor de recuperación máximo de 0.84 para la clase herida cuando el umbral de confianza es cercano a 0. Esta curva permite analizar el comportamiento del modelo conforme aumenta el nivel de confianza en las predicciones.

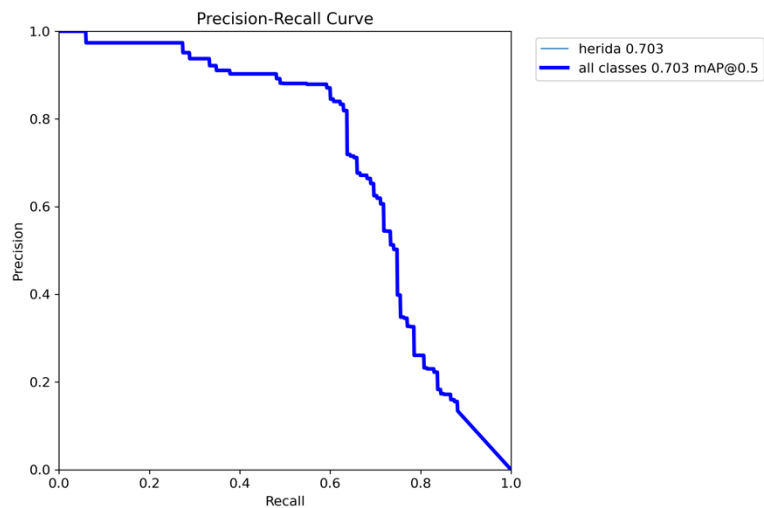


Figura 14. Resultado del cálculo de la curva de precisión para el modelo de detección de heridas usando YOLOv7

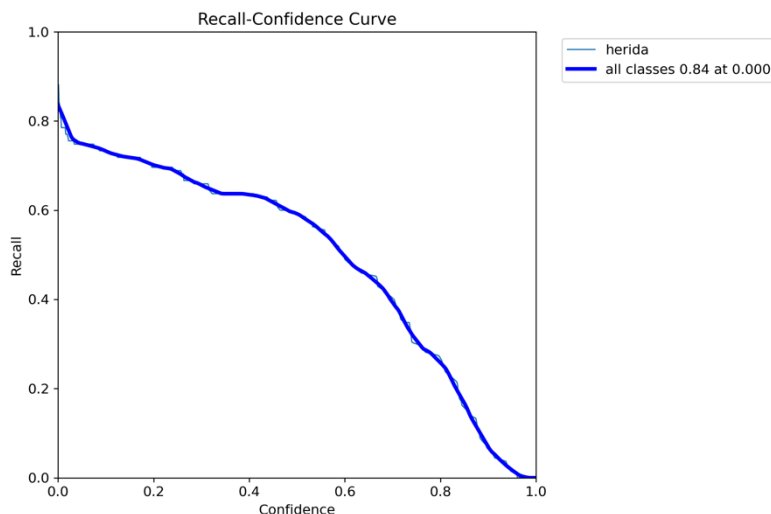


Figura 15. Curva de Recuperación en función de la Confianza (Recall-Confidence Curve) del modelo YOLOv7 para la detección de heridas superficiales.

5. CONCLUSIONES

El desarrollo de un sistema automatizado para la detección de heridas superficiales utilizando el modelo YOLOv7 representa un avance tecnológico relevante en el campo de la visión computacional médica, al integrar precisión, velocidad y adaptabilidad en contextos clínicos reales. A lo largo de este proyecto, se llevó a cabo un proceso técnico riguroso que incluyó la recolección y anotación colaborativa de imágenes clínicas, el entrenamiento del modelo en entornos computacionales acelerados con TPUs, y la validación del desempeño en escenarios estáticos y dinámicos. El sistema basado en YOLOv7, fue seleccionado por su equilibrio entre eficiencia computacional y alta precisión, el cual es una arquitectura especialmente adecuada para tareas médicas de detección en tiempo real. Sus mejoras sobre versiones anteriores, como una mejor organización de capas, anclajes dinámicos y mayor velocidad de inferencia, lo convierten en una herramienta robusta frente a modelos más pesados o menos optimizados computacionalmente. En este estudio, la detección de una única clase etiquetada como "herida", permitió alcanzar un recall de hasta 0.84, una precisión promedio del 93%, y valores consistentes de IoU y F1-score, lo que garantiza un rendimiento confiable incluso en condiciones visuales complejas.

Este sistema no solo valida la aplicabilidad de modelos avanzados como YOLOv7 en medicina, sino que también establece una base sólida para su integración en plataformas de telemedicina, sistemas de monitoreo remoto y dispositivos robóticos terapéuticos, ampliando sus posibilidades hacia tratamientos automatizados y personalizados. La combinación con tecnologías emergentes como el plasma de helio-argón para la cicatrización acelerada fortalece aún más su utilidad práctica.

Además, la experiencia obtenida en esta investigación puede escalar hacia otras aplicaciones médicas como la detección de úlceras por presión, quemaduras, lesiones dermatológicas, o incluso anomalías en imágenes radiológicas, ampliando el horizonte clínico de esta tecnología.

En términos sociales, este desarrollo ofrece una solución tangible para mejorar la accesibilidad a la atención médica especializada en comunidades remotas o con recursos limitados, disminuyendo la carga sobre el personal clínico y optimizando la eficiencia del diagnóstico. En un contexto global donde la rapidez diagnóstica, la precisión y la inclusión médica son imperativos, este proyecto marca un paso firme hacia una medicina más automatizada, equitativa y tecnológicamente integrada.

6. DISCUSIÓN

La implementación de un sistema de detección automática de heridas superficiales basado en YOLOv7 marca un hito prometedor en la intersección entre la visión artificial y la medicina clínica, con un potencial en la cicatrización de heridas superficiales. Este estudio aborda una necesidad crítica: optimizar la detección y tratamiento de heridas mediante la integración de inteligencia artificial y tecnologías robóticas (implantadas en otra etapa de la investigación), específicamente en combinación con dispositivos de plasma de helio-argón, los cuales han demostrado resultados satisfactorios en la cicatrización de heridas. Sin embargo, la aplicación manual de este plasma resulta físicamente demandante y poco práctica, lo que motiva el desarrollo de un sistema robótico automatizado que, apoyado en la detección precisa de heridas, pueda administrar el tratamiento de manera eficiente y autónoma.

El desarrollo de este sistema enfrentó un desafío inicial significativo: la escasez de datos de imágenes de heridas en repositorios públicos como Kaggle. Para superar esta limitación, se estableció una colaboración con una clínica local, cuyo personal médico proporcionó un conjunto valioso de imágenes clínicas. Estas imágenes, combinadas con técnicas de aumento de datos, permitieron entrenar un modelo YOLOv7 robusto, optimizado para detectar heridas con una sola clase titulada "herida". Los resultados obtenidos son alentadores: el modelo alcanzó un recall máximo de 0.84 y una precisión promedio del 93%, métricas que destacan su capacidad para identificar heridas con alta fiabilidad, un factor crucial en entornos clínicos donde los falsos negativos pueden tener consecuencias graves.

Además, el modelo demostró una notable precisión en la delimitación espacial de las heridas, reflejada en valores competitivos de Intersection over Union (IoU) y F1-score. Esta capacidad es fundamental para habilitar etapas posteriores, como la segmentación precisa de las heridas o la cuantificación de sus características, pasos esenciales para guiar un sistema robótico en la aplicación del plasma de helio-argón. La elección de YOLOv7 como arquitectura base se fundamenta en su equilibrio entre velocidad y precisión, especialmente al entrenarse en entornos optimizados con unidades de procesamiento tensorial (TPUs). Esta eficiencia computacional posiciona al sistema como un candidato ideal para su integración en dispositivos embebidos o plataformas de telemedicina, donde los recursos y el tiempo son limitados.

A pesar de estos avances, el sistema actual presenta limitaciones que abren oportunidades para investigaciones futuras. Por ejemplo, el modelo se centra exclusivamente en la detección de heridas superficiales sin clasificar su tipo, gravedad o características específicas (como infecciones o tejido necrótico). Ampliar el modelo para incluir tareas de clasificación múltiple o segmentación semántica podría enriquecer su utilidad clínica, permitiendo un diagnóstico más detallado y personalizado. Asimismo, la integración con un sistema robótico automatizado representa el próximo gran paso. Este sistema no solo detectaría y delimitaría las heridas, sino que también calcularía trayectorias óptimas para aplicar el plasma de manera precisa, reduciendo la carga sobre el personal médico y mejorando la consistencia del tratamiento.

La visión a largo plazo de este proyecto es revolucionar el tratamiento de heridas mediante la sinergia entre inteligencia artificial, robótica y tecnologías de plasma. Al combinar la detección automática de heridas con un sistema robótico guiado por visión artificial, se abre la puerta a soluciones médicas autónomas que podrían implementarse en entornos de atención primaria, hospitales o incluso en escenarios de telemedicina en regiones remotas. Este avance no solo optimizaría los procesos clínicos, sino que también democratizaría el acceso a tratamientos avanzados de cicatrización, marcando un paso significativo hacia un futuro donde la inteligencia artificial y la robótica se conviertan en aliados indispensables en la atención médica.

En conclusión, los resultados obtenidos con YOLOv7 sientan una base sólida para el desarrollo de un sistema robótico automatizado que integre detección y tratamiento de heridas. Este enfoque interdisciplinario no solo demuestra el potencial de la visión artificial en la medicina, sino que también subraya la importancia de colaboraciones entre instituciones clínicas y tecnológicas para superar las barreras

de datos y acelerar la innovación. Con futuras mejoras, este sistema podría transformar la práctica clínica, ofreciendo una solución escalable, precisa y accesible para el tratamiento de heridas a nivel global.

CONTRIBUCIÓN DE AUTORÍA CRediT

Los roles de autoría serán identificados en el orden siguiente, incluyendo a cada autor en el rol que le corresponde y omitiendo los roles que no procedan en cada caso:

1. Juan Alberto Antonio Velázquez, autor principal
2. Adriana Reyes Nava, co-autor
3. Marcos-C González Domínguez, co-autor
4. Roberto Alejo Eleuterio, co-autor
5. Marlon David González Ramírez, co-autor
6. Elizabet García Álcantara, co-autor

Conceptualización: La idea principal de la investigación surgió de la necesidad de detectar automáticamente heridas superficiales humanas a través de visión artificial, como parte de un sistema que en un futuro permita asistir a médicos o pacientes. La formulación de los objetivos generales consistió en aplicar un modelo de detección de objetos eficiente como YOLOv7, debido a su balance entre precisión y velocidad de inferencia, así como preparar un sistema que facilite su integración con un sistema robótico médico.

Metodología: La metodología del trabajo incluyó:

- Desarrollo del modelo de detección: Uso de YOLOv7 entrenado con un conjunto de imágenes reales de heridas superficiales.
- Entrenamiento del modelo: Anotación manual de imágenes utilizando herramientas como Makesense para generar los archivos necesarios para usarlos en YOLOv7.
- Evaluación del rendimiento: Aplicación de métricas como precisión, recall, F1-score e IoU para validar la efectividad del modelo.
- Despliegue local y prueba: Uso de entornos de procesamiento con GPU/TPU (por ejemplo, Google Colab) para entrenar el modelo, y posterior implementación local en Python para pruebas individuales.

Software: El desarrollo de software incluyó:

- Codificación de los scripts de entrenamiento y detección usando PyTorch, basándose en el repositorio oficial de YOLOv7.
- Integración del dataset con el modelo para realizar pruebas.
- Visualización de resultados sobre imágenes de prueba mediante generación de bounding boxes.

Validación: El modelo fue validado mediante el uso de imágenes nuevas no vistas durante el entrenamiento. Se compararon los resultados con anotaciones humanas para verificar la fiabilidad del sistema. Se alcanzaron valores de F1-score superiores al 80%, lo cual indica una alta concordancia entre el sistema automático y los juicios expertos.

Análisis formal: Se aplicaron herramientas matemáticas y computacionales para:

- Calcular métricas de rendimiento (precisión, recall, IoU).
- Analizar los falsos positivos y negativos, determinando el grado de confiabilidad del modelo.
- Comparar con otros enfoques más simples para justificar el uso de YOLOv7.

Investigación: Se realizó la recopilación de imágenes públicas obtenidas de Kaggle e imágenes de heridas superficiales proporcionadas por un médico. Se llevaron a cabo varias iteraciones experimentales probando

diferentes tamaños de imágenes, formatos de anotación y parámetros del modelo para mejorar la generalización.

Recursos: El proyecto requirió:

- Una computadora con procesador intel i7 y 8 Gbytes de memoria RAM.
- Todos los modelos se escribieron en el lenguaje de programación Python utilizando el marco de aprendizaje profundo Pytorch y se entrenaron en una plataforma TPU (Tensor Processing Units) utilizando un notebook de Google Colab.

Curación de datos: Actividades de gestión para anotar (producir metadatos), depurar datos y mantener los datos de la investigación (incluido el código de software, cuando sea necesario para interpretar los propios datos) para su uso inicial y su posterior reutilización.

Redacción - El documento fue redactado por los integrantes del equipo, quienes escribieron las secciones de introducción, metodología, resultados y discusión técnica.

Revisión y Edición: La redacción fue revisada para mejorar la coherencia técnica, corregir errores de redacción y asegurar claridad en la exposición de resultados y conclusiones.

Supervisión: La supervisión del proyecto incluyó la planificación de las actividades de investigación, la guía técnica para el desarrollo del software y la evaluación de resultados.

Administración del proyecto: Se gestionó el cronograma, los recursos y las actividades necesarias para garantizar el cumplimiento de los objetivos del proyecto

Adquisición de fondos: El proyecto no contó con apoyo financiero, sino que fueron con recursos propios.

DECLARATORIA DE USO DE INTELIGENCIA ARTIFICIAL EN ESTE DOCUMENTO

Los autores del artículo SISTEMA DE DETECCIÓN Y MEDICIÓN AUTOMÁTICA DE HERIDAS IMPLEMENTADO EN YOLOV7, PARA APLICACIÓN FUTURA DE CICATRIZADO, declaran haber utilizado la Inteligencia Artificial (IA) para mejorar los siguientes criterios de este:

Se improvisó la redacción en estilo, para reducir la redundancia de ideas y la repetición de palabra clave.

Especialmente se aplicó el uso de esta herramienta para estructurar la sección INTRODUCCIÓN, en los términos médico-clínicos dado a que, se tiene conocimiento del tema, no somos especialistas en ello, por ende, la IA fue una herramienta funcional para el entendimiento y redacción de ideas.

En la sección 2 ARQUITECTURA YOLO, fue requerida la IA para dar formalidad a la redacción que, en su desarrollo se consideró clarificar.

Por último, las secciones de CONCLUSIONES y DISCUSIÓN, fue útil para estructurar las ideas y aportaciones de los autores que, al ser variadas y de diversa índole, se consideró oportuno para la integración y convergencia de ideas.

Los autores declaran tal y como se redactó en la sección de DECLARATORIA DE USO DE IA en el documento, se acepta el uso de IA para mejorar redacción y comprensión del texto, mismo que fue revisado por los autores antes del envío del trabajo.

Por favor, siéntase en la libertad de contactarme si es necesaria información detallada acerca del artículo antes mencionado.

DECLARACIÓN DE INTERESES CONTRAPUESTOS

Los autores declaran que no existen intereses financieros, comerciales, personales ni académicos en conflicto que pudieran haber influido de manera inapropiada en la realización, interpretación o presentación de este trabajo. Asimismo, no mantienen relaciones personales o institucionales que representen un conflicto de intereses con respecto al contenido del artículo.

DISPONIBILIDAD DE DATOS

Los conjuntos de datos generados y/o analizados durante el estudio actual están disponibles por el autor correspondiente a solicitud razonable.

AGRADECIMIENTOS

Este proyecto no recibió ninguna subvención específica de ninguna agencia de financiación del sector público, comercial o sin fines de lucro.

REFERENCIAS

- La Gaceta. Diario Oficial. (2013). *Decreto 01-2013. Reglamento de la Ley No. 822, Ley de Concertación Tributaria*. Managua: La Gaceta.
- Casas, L., Treuillet, S., Valencia, B., Llanos, A., & Castañeda Jr, B. (2015). Low-cost uncalibrated video-based tool for tridimensional reconstruction oriented to assessment of chronic wounds. *Proceedings Volume 9287, 10th International Symposium on Medical Information Processing and Analysis*, 9287(928711).
- Lin, C., Phan, X., Thien, P., Anthony Meng Huat, T., Hung Leng, K., Jiajun, L., Muneaki, M. (2020). Sewing up the wound : a robotic suturing system for flexible endoscopy. *IEEE Robotics & Automation Magazine*, in press, 1-8.
- Lindholm, C., & Richard, S. (2016). Wound management for the 21st century: combining effectiveness and efficiency. *International Wound Journal*, 29(2), 84-92.
- Chino, D. Y., Scabora, L. C., Cazzolato, M. T., Jorge, A. E., Traina-Jr, C., & Traina, A. J. (2020). Segmenting skin ulcers and measuring the wound area using deep convolutional networks. *Computer Methods and Programs in Biomedicine*, 191(105376).
- Liu, J. (2016). A new way of repairing special wounds. *Heliyon*, 9(5).
- Aldughayfiq, B., Ashfaq, F., Jhanjhi, N. Z., & Hamayun, M. (2023). YOLO-Based Deep Learning Model for Pressure Ulcer Detection and Classification. *Aldughayfiq*, 11(9), 1222.
- Blanco, G., Traina Jr, C., & Azevedo-Marques, P. (2020). A superpixel-driven deep learning approach for the analysis of dermatological wounds. *Computer methods and programs in biomedicine*, 183(105079).
- Baca, G. (2007). *Fundamentos de Ingeniería Económica* (4a. ed.). México D.F.: McGraw-Hill.

- Bates, J., McCreath, B. M., & Harputlu, H. E. (2019). Reliability of the Bates-Jensen wound assessment tool for pressure injury assessment: The pressure ulcer detection study. *Wound Repair and Regeneration*, 27(4), 386-395.
- Bhardwaj, N., Chouhan, D., & Mandal, B. B. (2017). Tissue Engineered Skin and Wound Healing: Current Strategies and Future Directions. *Bentham Science*, 3455 - 3482.
- Falanga, V., Rivkah Isseroff, R., M. Soulika, A., Romanelli, M., Margolis, D., Kapp, S., Harding, K. (2022). Chronic wounds. *Nature Reviews Disease Primers*, 8(50).
- Filko, D., Cupec, R., & Nyarko, E. K. (2016). Detection, reconstruction and segmentation of chronic wounds using Kinect v2 sensor. *International Conference On Medical Imaging Understanding and Analysis 2016, MIUA 2016, 6- 8 July 2016, Loughborough, UK*. Loughborough, UK: Science Direct.
- Foltynski, P., Ladyzynski, P., Ciechanowska, A., Migalska-Musial, K., Judzewicz, G., & Sabalinska, S. (2015). Wound Area Measurement with Digital Planimetry: Improved Accuracy and Precision with Calibration Based on 2 Rulers. *PloS one*, 10(8), e0134622.
- Foltynski, P., & Ladyzynski, P. (2023). Internet service for wound area measurement using digital planimetry with adaptive calibration and image segmentation with deep convolutional neural networks. *Biocybernetics and Biomedical Engineering*, 43(1), 17-29.
- García-Fernández, F. P., Soldevilla-Agreda, J. J., Rodríguez-Palma, M., & Pancorbo-Hidalgo, P. L. (2022). Skin injuries associated with severe life-threatening situations: A new conceptual framework. *Journal of Nursing Scholarship*, 54(1), 72-80.
- Garcia-Alcantara, E., Lopez-Callejas, R., Serment-Guerrero, J., Peña-Eguiluz, R., Muñoz-Castro, A. E., Rodríguez-Mendez, B. G., Barbosa-Pliego, A. (2013). Toxicity and Genotoxicity in HeLa and E. coli Cells Caused by a Helium Plasma Needle. *Applied Physics Research*, 5(5), 21-28.
- Garza, J. (2014). *Análisis multicriterio de puntos de inflexión de precio en el mercado de divisas*. San Nicolás de los Garza, Nuevo León: Universidad Autónoma de Nuevo León.
- Gomero, N. (2014). Análisis económico de los impuestos: Impacto en la rentabilidad de las inversiones. *Quipukamayoc*, 79-87.
- Instituto Nicaragüense de Investigaciones y Estudios Tributarios. (2015). *Balance de la Ley de Concertación Tributaria*. Managua, Nicaragua: INIET.
- Ishii, K., Takeuchi, A., Nishinoiri, O., Endo, G., & Ono-Ogasawara, M. (2022). Development of a method to determine workers' personal exposure levels to glyphosate. *Journal of Occupational Health*, 64(1).
- Jalilian, M., & Shiri, S. (2022). The reliability of the Wagner Scale for evaluation the diabetic wounds: A literature review. *Diabetes & Metabolic Syndrome: Clinical Research & Reviews*, 16(1), 102507.
- Jeong, S., Kim, J., Choi, K., & Cho, Y.-R. (2025). Development of AI-Based Diagnostic Systems for Wound Images. *2024 15th International Conference on Information and Communication Technology Convergence (ICTC)* (pp. 16-18). Island: IEEE.
- M. Miller, G., & K. Abraham, M. (2024). Pitfalls of Wound Management. In D. G. Goyal, & A. Mattu, *Urgent Care Emergencies: Avoiding the Pitfalls and Improving the Outcomes, Second Edition*. Wiley Online Library.
- Mankowitz MD, S. (2017). Laceration Management. *The Journal of Emergency Medicine*, 53(3), 369-382.
- Martines, E., Brun, P., Cavazzana, R., Cordaro, L., Zuin, M., Martinello, T., Iacopetti, I. (2020). Wound healing improvement in large animals using an indirect helium plasma treatment. *Clinical Plasma Medicine*, 17(100095).

- Masri, S., & Fauzi, M. B. (2021). Current insight of printability quality improvement strategies in natural-based bioinks for skin regeneration and wound healing,. *Polymers*, 13(7), 1011.
- Masson-Meyers, D. S., Andrade, T. A., Caetano, G. F., Guimaraes, F. R., Leite, M. N., Leite, S. N., & Frade, M. A. (2018). Experimental models and methods for cutaneous wound healing assessment. *International Journal of Experimental Pathology*, 101(1-2), 21-37.
- Moholkar, D. N., Sadalage, P. S., Peixoto, D., & Paiva-Santos, A. C. (2021). Recent advances in biopolymer-based formulations for wound healing applications. *European Polymer Journal*, 160(5).
- Negussie Tesema, S., & Bourennane, E.-B. (2021). Multi-Grid Redundant Bounding Box Annotation for Accurate Object Detection. *IEEE Intl Conf on Dependable, Autonomic and Secure Computing, Intl Conf on Pervasive Intelligence and Computing, Intl Conf on Cloud and Big Data Computing*, 145-152.
- Nira, & Kumar, H. (2022). Epidemiological Mucormycosis treatment and diagnosis challenges using the adaptive properties of computer vision techniques based approach: a review. *Multimedia Tools And Applications*, 81(10), 14217-14245.
- Puri, S., Mandal, S. K., Pal, P., Lamba, R. P., Miller, V., Pal, E. N., & Deepa, P. R. (2024). Biochemical evaluation of wound healing efficacy of cold plasma-conditioned media under different operational conditions. *Journal of Physics D: Applied Physics*, 57(405201).
- Raj M.D, S., Raj M.D., S., P.A.-C., W. A., Charles M.D., W., & Alexander M.D., A. (2015). Novel Penile Splint and Its Use in Microsurgical Penile Replantation. *Plastic and Reconstructive Surgery Journal of the American Society of Plastic Surgeons*, 135(6), 1082-1083.
- Ramachandram, D., Ramirez-GarciaLuna, J., Fraser, R. D., Arriaga-Caballero, J., & Allport, J. (2022). *JMIR mHealth and uHealth*.
- Rosillo, J. (2005). La inflación: ¿Elemento inocuo en las decisiones de inversión? *Forum Empresarial*, 20-46.
- Ruiz, J. (1992). *Capital y depreciación: Una aproximación endógena*. Valencia, España: Universitat de Valencia.
- Scebba, G., Zhang, J., Catanzaro, S., Mihai, C., Distler, O., Berli, M., & Karlen, W. (2022). Detect and-segment: A deep learning approach to automate wound image segmentation. *Informatics in Medicine Unlocked*.
- Scebba, G., Zhang, J., Catanzaro, S., Mihai, C., distler, O., Berli, M., & Karlen, W. (2022). Detect-and-segment: A deep learning approach to automate wound image segmentation. *Informatics in Medicine Unlocked*, 29(100884).
- Shrestha, R., Krishan, K., Ishaq, H., & Kanchan, T. (2023). Abrasion. In StatPearls, *NAtional Library of Medicine NAtional Center for Biotechnology Information*.
- Sina Jelodar, K. Y., Khalatbari, M. R., Reza Bahrami , S., & Abbas Amirjamshidi, I. (2018). Stab Wounds to the Head; Case Series, Review of Literature, and Proposed Management Algorithm. *Asian Journal of Neurosurgery*, 13(03), 754-759.
- Skalski, P. (2019). *Alpha Make Sense*. Make Sense: <https://github.com/SkalskiP/make-sense>
- Twormey, D. M., Petrass, L. A., Fleming, P., & Lenehan, K. (2018). Abrasion injuries on artificial turf: a systematic review. *Journal of Science and Medicine in Sport*, 550-556.
- Wang, S. C., Anderson, J. A., Evans, R., Woo, K., Beland, B., Sasseville, D., & Moreau, L. (2017). Point-of-care wound visioning technology: Reproducibility and accuracy of a wound measurement app. *Reproducibility and accuracy of a wound measurement app. PloS one*, 12(8), e0183139.

- Yazici, R. (2024). Retrospective analysis of penetrating and cutting instrument injury cases from the prehospital emergency medical system perspective. *Medicine Science*, 13(3), 667.
- Zahia, S., Garcia Zapiain, M., Sevillano, X., Gonzalez, A., Kim, P. J., & Elmaghrabi, A. (2020). Pressure injury image analysis with machine learning techniques: A systematic review on previous and possible future methods. *Artificial Intelligence in Medicine*, 102(101742).
- Zhang, R., Tian, D., Xu, D., Qian, W., & Yudong, Y. (2022, Julio 28). A Survey of Wound Image Analysis Using Deep Learning: Classification, Detection, and Segmentation. *IEEE Access*, 10, 79502-79511.