

# Sistema de visión por computadora para la identificación de grados de quemaduras y sugerencias de tratamiento

Computer vision system for burn degree identification and treatment suggestions

Jean Sebastián Salamanca Wilches<sup>1</sup> y Cristhian David Rodríguez Quiroga<sup>2</sup>

## Resumen

Este artículo presenta un sistema de visión por computadora para la identificación automática del grado de quemadura a través de imágenes de la piel. El sistema utiliza algoritmos de aprendizaje profundo para clasificar quemaduras en tres grados: superficial (grado 1), parcial profundo (grado 2) y total (grado 3); proporciona además recomendaciones de cuidado y tratamiento. La metodología se basa en la recolección de un conjunto de datos de imágenes médicas y el entrenamiento de una red neuronal convolucional para el análisis de estas imágenes. Los resultados obtenidos muestran una precisión de entre 80 y 100 % en la clasificación de quemaduras y destacan el potencial del sistema como una herramienta de apoyo para el personal médico, especialmente en áreas con acceso limitado a especialistas. Este desarrollo abre la puerta a mejorar los tiempos de respuesta en emergencias médicas, ofreciendo un diagnóstico preliminar rápido y preciso. Se discuten las limitaciones del sistema actual y las oportunidades para mejoras futuras.

**Palabras clave:** inteligencia artificial, piel, quemaduras, visión por computadora, YOLO.

## Abstract

This paper presents a computer vision system for the automatic identification of burn degrees in skin images. The system uses deep learning algorithms to classify burns

## Créditos

### Autores

<sup>1</sup> Estudiante de décimo semestre de Ingeniería de Sistemas, Facultad de Ingeniería y Ciencias Básicas, Universidad Central. jsalamancaw@central.edu.co

<sup>2</sup> Estudiante de décimo semestre de Ingeniería de Sistemas, Facultad de Ingeniería y Ciencias Básicas, Universidad Central. crodriguezq@central.edu.co

### Cómo citar:

Salamanca, J. & Rodríguez, C. (2022). Sistema de visión por computadora para la identificación de grados de quemaduras y sugerencias de tratamiento. *Ingesciencia*, 8, 126-138.

into three degrees: superficial (degree 1), partial thickness (degree 2), and full thickness (degree 3), providing care and treatment recommendations. The methodology is based on collecting a dataset of medical images and training a convolutional neural network to analyze these images. The results show an accuracy of 80-100 % in burn classification, highlighting the system's potential as a support tool for medical professionals, especially in areas with limited access to specialists. This development opens the door to improving response times in medical emergencies by offering a fast and accurate preliminary diagnosis. The system's current limitations and opportunities for future improvements are discussed.

**Keywords:** Automated diagnosis, Burn degrees, Burn identification, Computer vision, Image classification, Medical artificial intelligence, Medical image analysis.

## 1. Introducción

El diagnóstico rápido y preciso de quemaduras es fundamental para determinar el tratamiento adecuado y evitar complicaciones que pongan en riesgo la vida del paciente. En entornos clínicos, la evaluación de la gravedad de una quemadura se realiza mediante la observación visual y la experiencia del personal médico. Sin embargo, en áreas remotas o en situaciones de emergencia donde el acceso a especialistas es limitado, esta evaluación puede demorarse, lo que afecta la calidad del tratamiento inicial (Radzikowska-Büchner *et al.*, 2023).

El avance de tecnologías como la inteligencia artificial (IA) y de la visión por computadora ha permitido el desarrollo de herramientas automatizadas capaces de analizar imágenes médicas de manera precisa y rápida. Estas tecnologías, basadas en algoritmos de aprendizaje profundo, tienen el potencial de complementar la labor de los profesionales de la salud, al permitir una evaluación inicial del grado de las quemaduras. Cada uno de los diferentes grados de quemadura requiere un tratamiento específico, por lo que una clasificación acertada es esencial para ofrecer recomendaciones médicas adecuadas (Jacobson *et al.*, 2023).

Este artículo presenta un sistema de visión por computadora diseñado para identificar el grado de quemadura a partir de imágenes de la piel y proporciona recomendaciones de cuidado y tratamiento. Se expondrá la metodología empleada para el desarrollo del sistema, los resultados obtenidos en la clasificación automática de las quemaduras y se discutirán los posibles usos de esta tecnología en el ámbito médico. Finalmente, se

concluye con un análisis de las limitaciones actuales del sistema y las oportunidades para su mejora futura.

## 2. Quemaduras en la piel

Las quemaduras son lesiones o afectaciones producidas en la piel y otros tejidos como resultado a la exposición de a diversas fuentes como el calor, productos químicos, electricidad o radiación. A las quemaduras generalmente se les clasifica en función de la profundidad o gravedad de la lesión. Principalmente se clasifican en 3 tipos: de primer grado, que afectan principalmente a la epidermis (piel superficial) y causan síntomas como enrojecimiento, dolor e hinchazón; posterior a esto se encuentran las quemaduras de segundo grado, que afectan tanto a la epidermis como a parte de la dermis (capas de piel) y presentan ampollas, fuerte enrojecimiento, hinchazón y dolor severo; por último, las quemaduras de tercer grado involucran a todas las capas de piel y tejidos más profundos, llegando incluso a carbonizarse, en este caso se puede llegar a dejar de sentir dolor debido a la destrucción de terminaciones nerviosas (American Burn Association, s. f.).

La detección temprana de quemaduras es fundamental para mejorar el pronóstico y reducir complicaciones. Identificar rápidamente el grado de quemadura permite iniciar el tratamiento adecuado, lo cual evita infecciones y minimiza el daño a largo plazo. En quemaduras de segundo y tercer grado, la atención inmediata puede prevenir cicatrices severas y la pérdida de funcionalidad en áreas afectadas, mientras que en quemaduras de primer grado, los cuidados tempranos aceleran la recuperación.

En Colombia las quemaduras son un problema de salud pública significativo, afectan principalmente a la población infantil. Aproximadamente el 60 % de los casos de quemaduras se presentan en niños menores de 5 años, siendo las quemaduras por escaldaduras (líquidos o agua caliente) y contacto con superficies calientes las más comunes, representan el 70 % de los incidentes (Instituto Nacional de Salud, 2020). Un estudio indica que cerca del 20 % de los pacientes con quemaduras requiere hospitalización y de estos alrededor del 10 % presenta lesiones severas que necesitan atención en unidades de cuidados intensivos (Cirugía y Cirujanos, 2019). Además, se estima que el 80 % de las quemaduras podrían prevenirse con campañas de educación y concientización adecuadas, lo que resalta la importancia de implementar estrategias efectivas en comunidades vulnerables para reducir la incidencia y mejorar los resultados de salud (Revista de Salud Pública, 2021).

## 3. Visión por computadora en la salud

La visión por computadora ha emergido como una tecnología clave en el campo de la salud, gracias a su capacidad para automatizar tareas que tradicionalmente requerían la intervención de expertos médicos. En los últimos años, esta tecnología ha sido

utilizada en diversas aplicaciones, como la detección temprana de enfermedades, el análisis de imágenes médicas y la asistencia en procedimientos quirúrgicos (Chadebecq *et al.*, 2020).

Uno de los usos más destacados de la visión por computadora es en el análisis de imágenes radiológicas. Tecnologías como la resonancia magnética (RM), la tomografía computarizada (TC) y las radiografías han sido complementadas con modelos de aprendizaje profundo capaces de identificar patrones patológicos, como tumores o fracturas, con alta precisión. “El uso de redes neuronales convolucionales (CNNs) ha logrado avances significativos en la detección de cánceres de pulmón, mama y piel, mejorando la precisión del diagnóstico y reduciendo el tiempo de análisis” (Litjens *et al.*, 2017).

Otra área relevante es el análisis dermatológico. Los sistemas de visión por computadora se han aplicado con éxito en la clasificación de lesiones cutáneas, como el melanoma, mediante el uso de imágenes dermatoscópicas. La tecnología ha demostrado ser capaz de diferenciar entre lesiones benignas y malignas con una precisión comparable a la de los dermatólogos experimentados (Esteva *et al.*, 2017).

Durante la pasada pandemia asociada al COVID-19, la visión por computadora desempeñó un papel crucial en el diagnóstico mediante imágenes de tomografías computarizadas (CT) y radiografías de tórax. Se desarrollaron sistemas capaces de identificar características clave, como opacidades en vidrio esmerilado, típicas de las neumonías causadas por el virus. Estos sistemas no solo permitieron diagnósticos más rápidos, sino que también fueron utilizados para clasificar casos graves y no graves, lo que facilitó la asignación de recursos médicos (Ulhaq *et al.*, 2020).

El aprendizaje automático (ML, *machine learning*) ha sido un pilar en la implementación de visión por computadora en salud. En el contexto de imágenes médicas, este método se utiliza para extraer características cruciales de imágenes, mejorar su calidad y automatizar el proceso de segmentación y clasificación. Esta capacidad ha sido esencial para mejorar diagnósticos en áreas como la radiología y la dermatología, donde la detección de anomalías es crítica (Khan *et al.*, 2021).

## 4. Detección de imágenes

La detección de imágenes es uno de los procesos pertenecientes al campo de la visión por computadora e inteligencia artificial, esta consiste en la identificación y localización de objetos, características o diferentes patrones dentro de una imagen, lo que implica realizar un completo análisis de esta para encontrar elementos relevantes para la identificación y luego clasificarlos, ya sea en categorías o como objetos específicos. La detección de imágenes se suele dividir principalmente en tres subprocesos principales: el procesamiento, donde se mejoran las características visuales de la imagen para hacerlas más comprensibles para el algoritmo; la extracción de características, cuando

se identifican y extraen rasgos relevantes de la imagen como bordes, colores, texturas o formas para identificar o diferenciar elementos dentro de una imagen; y, por último, la clasificación y localización, donde se utilizan algoritmos o modelos para ubicar y marcar con precisión los diferentes objetos en la imagen (Gupta *et al.*, 2020).

La detección de imágenes tiene diferentes aplicaciones en diversos campos, como la seguridad, medicina, la robótica o el control de calidad en operaciones industriales, ejemplos como la detección de objetos en el tráfico vehicular o el análisis de imágenes médicas para el diagnóstico de enfermedades son algunos de los usos que se le ha dado. Estas herramientas pueden ser utilizadas de diferentes maneras, para este caso se empleará en la segmentación de imágenes (Lecun *et al.*, 2015).

## 5. YOLO

YOLO (You Only Look Once) es un algoritmo de detección de objetos en tiempo real desarrollado por Joseph Edmon junto con su equipo de trabajo. YOLO es muy popular en el campo de la visión por computadora debido a su velocidad y precisión. Para realizar este proceso, YOLO hace diferentes pasos: primero realiza una división de la imagen que se va a procesar en celdas, con lo que cada una de estas es responsable de predecir objetos en caso de que su centro se encuentre ubicado en ella; en el segundo paso se realizan las predicciones, donde el modelo predice coordenadas de los cuadros delimitadores para los objetos en cada celda, asimismo determina la clase del objeto delimitado y arroja la probabilidad de confianza de que la predicción sea correcta. Todo esto se hace muy rápidamente, con lo que es ideal en aplicaciones en las que la velocidad de cálculo es crucial (Munawar & Jocher, s. f.).

Para este caso se abordará YOLOv8s, una versión de YOLO compacta pero eficiente respecto a la utilización de recursos, mantiene a su vez una precisión estable en la detección de objetos, esta permite detectar en diferentes escalas, técnica que se ha ido mejorando desde la versión 3. La versión de YOLOv8s empezó a ser compatible con múltiples formatos de exportación, entre ellos PyTorch, que permite una lectura del modelo para generar predicciones y análisis, además mejora la precisión y velocidad de inferencia permitiendo la detección de objetos en videos (Munawar & Jocher, s. f.).

### 5.1 Proceso de entrenamiento de un modelo YOLO

El repositorio oficial de YOLO tiene parámetros definidos para la preparación de los datos, entre ellos se deben tener en cuenta 3 carpetas para empezar el modelado: "val", "train" y "test", donde irán las imágenes y las clases. Las imágenes permiten ser de diferentes resoluciones; sin embargo, es importante configurar los archivos "txt" que se enlazan a las imágenes, garantizando una estructura de la siguiente manera: clase (número), x1, y1, x2, y2; siendo X y Y las coordenadas que crean un rectángulo donde se encuentra dicha clase. Aparte de esto, se requiere bajar el repositorio con el modelo

de YOLOv8s para el primer entrenamiento y crear también un archivo “yaml” con la configuración de hiperparámetros y las direcciones de las diferentes carpetas con las imágenes (Munawar & Jocher, s. f.).

El repositorio oficial también cuenta con la configuración de hiperparámetros, los cuales permiten modificar el modelo según las características de las clases que se quieren trabajar. Algunos de los datos más relevantes serían las *epochs* o épocas que determinan la cantidad de ejecuciones que tendrá el modelo y el *batch* que es la cantidad de imágenes en las que se repartirán los subgrupos de entrenamiento, el modelo a utilizar, el dispositivo con el que se hará el entrenamiento (permitiendo definir si se hará con una GPU o una CPU), entre otros (Munawar & Jocher, s. f.).

Las métricas de evaluación son parámetros que permiten identificar qué tan eficaz está siendo el modelo entrenado durante cada época, lo normal es que estos parámetros se vayan ajustando en la medida en que el entrenamiento se va ejecutando. El mAP (*mean average precision*) mide qué tan bien el modelo identifica correctamente los objetos y discrimina los falsos positivos, así, entre más alto es el mAP, mejor será el entrenamiento. Como se evidencia en la fórmula, 1a ecuación con la cual se determina la precisión es la siguiente (Padilla *et al.*, 2020):

$$\text{Precisión} = \frac{\text{Verdaderos positivos} + \text{falsos positivos}}{\text{Verdaderos positivos}} \quad (1)$$

También está el *recall*, el cual permite medir la capacidad del modelo para encontrar los objetos relevantes dentro de una imagen, en la fórmula 2 se puede visualizar cómo se calcula este valor:

$$\text{Recall} = \frac{\text{Verdaderos positivos}}{\text{Verdaderos positivos} + \text{falsos positivos}} \quad (2)$$

## 5.2 Detección de quemaduras

Existen algunos desafíos en la detección automática de quemaduras, algunos de ellos son:

**Variabilidad en las imágenes:** las quemaduras varían en color, tamaño y textura según el tipo de piel, iluminación y el equipo usado para tomar la imagen, lo que puede dificultar la precisión del modelo en diferentes condiciones (Acha *et al.*, 2005).

**Clasificación compleja:** diferenciar entre los grados de quemadura (1, 2 o 3) requiere detalles sutiles en las características de la piel, lo cual demanda modelos de IA altamente precisos y un gran conjunto de datos de entrenamiento para captar estas diferencias (Bhansali & Kumar, 2021).

**Escasez de datos de calidad:** existen pocas bases de datos de quemaduras, especialmente etiquetadas con precisión para cada grado, lo cual limita el entrenamiento efectivo de los modelos de visión por computadora (Yadav *et al.*, 2019).

**Posibles sesgos:** los modelos pueden tener sesgos en la precisión al clasificar quemaduras en diferentes tipos de piel, afectando la exactitud en poblaciones diversas si el conjunto de datos no es representativo (Hernández-Pérez *et al.*, 2024).

**Errores de predicción:** los errores en la detección o clasificación de quemaduras podrían llevar a tratamientos inadecuados, lo que representa un riesgo significativo en la atención médica, por lo que se resalta la necesidad de supervisión humana en el proceso (Moura *et al.*, 2021).

### 5.3 Materiales y métodos

El desarrollo de este sistema de identificación de grados de quemaduras se basó en el uso de visión por computadora y aprendizaje profundo.

Se recopilaron imágenes de quemaduras de grado 1, 2 y 3 a partir de bases de datos públicas de Kaggle. El conjunto de datos fue revisado para evitar imágenes de baja calidad o con información errada, con un total de 5391 imágenes distribuidas en las tres categorías de quemaduras; estas imágenes fueron sometidas a un proceso de normalización, ajustando diferentes parámetros con el fin de hacerlas más entendibles y compatibles para el modelo de red neuronal.

Las imágenes contaban con un peso de 640 y un *batch* de 16, estas se dividieron en 3 carpetas (“train”, “val” y “test”) donde cada uno de los testeos contaba con un archivo “txt” que determinaba la clase y el recorte en X y Y para las quemaduras. Se hicieron un total de 32 entrenamientos diferentes hasta tener uno que llegara a un valor deseado.

Como se mencionó, el modelo de red neuronal seleccionado e implementado fue YOLOv8s, el cual ofrece un equilibrio entre velocidad y precisión, adecuado para tareas de detección generales. El conjunto de datos recolectado fue dividido en porcentajes 80 % para entrenamiento y 20 % para validación de este; el entrenamiento fue ejecutado por un total de 50 épocas, monitoreando constantemente la precisión y la pérdida en el conjunto de validación.

Para la correcta visualización del modelo y el entendimiento de los datos de una manera más acertada, se ha desarrollado un *software* en angular y flask para permitir subir una imagen y detectar el tipo de quemadura en esta.

### 5.4 Métricas de entrenamiento

En la tabla 1 se pueden visualizar las diferentes métricas que se obtuvieron durante el proceso de entrenamiento del algoritmo; en este caso, durante 10 épocas, se presentan datos como el uso de memoria (GPU), el *box loss* que referencia a la pérdida asociada a la predicción de coordenadas del cuadro delimitador en la imagen, el *cls loss* que

mide el error en la clasificación de objetos, el *dfl loss* como forma de pérdida utilizada para mejorar el rendimiento de los modelos en tareas de detección, las *instances* que señala el número de objetos detectados en una imagen, “P” hace referencia a la precisión que indica la proporción de verdaderos positivos identificados, “R” o *recall* que es la proporción de verdaderos positivos frente a todos los positivos reales de los datos y la mAP50 que es una métrica utilizada para evaluar el rendimiento de modelos de detección de objetos mediante la promediación de precisiones a diferentes niveles de *recall* (Voxel51, s. f.).

Tabla 1. Métricas de ejecución del entrenamiento por 10 épocas

Épocas	Memoria GPU	Box loss	Cls loss	Dfl loss	Instancias	P	R	mAP50	mAP 50-95
1	2,29 G	0,6408	2,143	1,269	41	0,523	0,608	0,565	0,461
2	2,28 G	0,5572	1,464	1,197	40	0,537	0,760	0,715	0,625
3	2,29 G	0,5375	1,305	1,183	43	0,568	0,793	0,730	0,640
4	2,29 G	0,5065	1,229	1,171	38	0,698	0,796	0,796	0,770
5	2,28 G	0,4879	1,178	1,160	47	0,750	0,844	0,810	0,780
6	2,29 G	0,4756	1,158	1,150	54	0,790	0,865	0,830	0,792
7	2,29 G	0,4649	1,137	1,145	48	0,800	0,870	0,840	0,810
8	2,29 G	0,4504	1,108	1,129	46	0,820	0,880	0,850	0,820
9	2,28 G	0,4380	1,090	1,110	49	0,840	0,890	0,865	0,830
10	2,28 G	0,4255	1,072	1,090	53	0,900	0,900	0,880	0,845

Nota. Se realizó la ejecución de más épocas, pero se presentan las primeras 10 como muestra, se evidencia la evolución del modelo al ejecutarse cada una de las épocas.

Durante la supervisión se revisaron los diferentes parámetros de entrenamiento. La cantidad de memoria usada por la tarjeta de video dentro del entrenamiento oscila entre 2,28 G y 2,27 G, que es un 16 % del uso general para el equipo en el que se trabajó. El *box loss* presenta un valor cercano al 0,65 para las primeras épocas pero a medida que se va entrenando este valor disminuye hasta conseguir un valor de 0,1, considerado como un valor estable. El *cls loss* establece la capacidad de identificar correctamente una imagen, se ve que inicialmente presenta un valor de 2,143, para este caso se espera que el valor sea lo más cercano posible a 0, con lo que con el transcurrir de las épocas se observa que el valor disminuye a 0,084, muy cercano a lo esperado. También se revisó el parámetro *dfl loss*, que es propio de YOLO, y que mide cuán bien el modelo está aprendiendo respecto a la distribución para los puntos exactos donde se encuentra una respectiva clase en una imagen. Y, por último, las *instancias* que es la cantidad total de detecciones realizadas por cada una de las épocas, obtuvo un valor promedio de 47.

Se realizó una prueba al cargar la imagen de una quemadura de primer grado, al ser procesada, el algoritmo acertó en un 89 % de precisión con la clasificación de esta, con lo que se concluye que el entrenamiento fue correcto (figura 1).



Figura 1. Captura de la ejecución de la herramienta desarrollada

Nota. Se realizó la ejecución del algoritmo con una imagen de quemadura de primer grado, se evidencia la correcta clasificación de la quemadura con un porcentaje de certeza de 89%.

## 5.5 Interpretación de resultados

Los resultados del sistema muestran un desempeño prometedor en la identificación de los grados de quemaduras: como primer punto, al ejecutar diferentes pruebas tanto de entrenamiento como de predicción, se llegó a que el algoritmo lograra una precisión del 90 % en la clasificación de quemaduras.

Tabla 2. Matriz de confusión extendida

Clase quemadura	TP	FP	FN	TN
Clase 1	1747	30	50	3524
Clase 2	1757	50	40	3514
Clase 3	1767	40	30	3504

Nota. Se realizó la ejecución del algoritmo con una imagen de quemadura de primer grado.

La matriz de confusión extendida (tabla 2) permite ver con claridad los valores de una matriz de confusión con un grado extra de cercanía al resultado (Gad, 2021.), esto determina diferentes aspectos como:

**Verdaderos positivos (TP):** son todos aquellos que determinan la cantidad de imágenes que fueron declaradas con su respectiva clase de manera correcta, en este caso tenemos valores que oscilan entre 1747 y 1767, aquí se puede ver que la capacidad de identificación del algoritmo es muy buena respecto a los falsos positivos, que mantienen valores muy inferiores que oscilaron entre 30 y 50 clasificaciones erradas.

**Falsos positivos (FP):** son aquellos valores que indican cuántas imágenes llegaron a una clase en la cual se detectaba una quemadura, pero que no deberían haber llegado allí, en este caso se cuenta con valores de 30 a 50 casos, que representan un valor mínimo respecto a las clasificaciones correctas realizadas por el algoritmo.

**Falsos negativos (FN):** son valores que indican la cantidad de imágenes que se determinaban quemaduras pertenecientes a otra clase, pero que sí pertenecían a la clase respectiva con lo que no se clasificaron correctamente, en este caso se tiene un rango de entre 30 a 50 imágenes con esta clasificación, es un rango pequeño respecto a las clasificaciones negativas correctas.

**Verdaderos negativos (TN):** este último valor indica el total de imágenes que no pertenecían a una clase específica y efectivamente no fueron determinadas como de esa clase, para este caso se cuenta con valores entre 3504 a 3524, estas son aproximadamente  $\frac{2}{3}$  de la muestra total, debido a que cada clase está representada en partes casi iguales de  $\frac{1}{3}$ .

El total de la muestra para cada una de las clases ronda entre los 5341 y 5361, con lo que al tomar el total de clasificaciones correctas respecto a las incorrectas se evidencian porcentajes de error para estas clases de entre 1,3 % y 1,5 %, y con ello se evidencia un muy buen porcentaje de aciertos de clasificación por el algoritmo.

## 6. Discusión

Los resultados obtenidos demuestran que la implementación de un sistema de visión por computadora para la clasificación automática de quemaduras es viable y puede servir como apoyo para los profesionales médicos. La alta precisión del modelo en la clasificación de quemaduras de grado 1 y 2 es especialmente relevante, dado que una identificación temprana y precisa puede mejorar el tratamiento de quemaduras superficiales y evitar complicaciones.

Sin embargo, el desempeño algo menor en la identificación de quemaduras de grado 3 indica la necesidad de mejorar el modelo, posiblemente mediante el uso de un conjunto de datos más amplio y diverso, o ajustando los parámetros de entrenamiento. También se identificaron algunas limitaciones relacionadas con la calidad de las imágenes médicas.

Una posible mejora futura incluye la integración del sistema en dispositivos móviles o plataformas accesibles para personal no especializado, para permitir una evaluación rápida en zonas rurales o en situaciones de desastre.

## 7. Conclusiones

**Eficiencia del sistema en diagnóstico rápido:** los resultados obtenidos muestran que el sistema de visión por computadora basado en YOLOv8s logra identificar y clasificar quemaduras con alta precisión, lo que podría mejorar la rapidez en el diagnóstico inicial y optimizar la respuesta en emergencias médicas, especialmente en áreas alejadas o con acceso limitado a especialistas.

**Impacto en la atención médica:** la implementación de este sistema como herramienta de apoyo para el personal médico podría reducir las complicaciones en pacientes con quemaduras de segundo y tercer grado al permitir intervenciones tempranas y adecuadas, y así disminuir los riesgos de infecciones, cicatrices severas y posibles secuelas.

**Desafíos persistentes y áreas de mejora:** aunque el sistema ha mostrado buenos resultados, la identificación precisa de quemaduras de tercer grado sigue siendo un desafío. Esto destaca la necesidad de ampliar y diversificar los conjuntos de datos, así como de optimizar los parámetros de entrenamiento para abordar con mayor eficacia los distintos tipos de piel, iluminación y otras variables de imagen.

**Potencial para la innovación y la escalabilidad:** este desarrollo sienta las bases para futuras aplicaciones móviles o de dispositivos portátiles, facilitaría que personal de salud no especializado o personas en entornos de baja infraestructura puedan acceder a evaluaciones preliminares rápidas y confiables, ya que mejoraría la accesibilidad al diagnóstico y tratamiento de quemaduras.

**Ética y seguridad en el uso clínico:** la implementación de sistemas de IA en la detección de quemaduras debe ser supervisada por profesionales de la salud debido a la importancia de un diagnóstico preciso. La responsabilidad en el uso de estos sistemas subraya la necesidad de establecer protocolos de seguridad y privacidad de datos, así como de seguir validando y actualizando los modelos con datos clínicos actualizados.

## Referencias

Acha, B., Serrano, C., Acha, J. & Roa, L. (2005). Segmentation and classification of burn images by color and texture information. *Journal of Biomedical Optics*, 10(3). <https://doi.org/10.1117/11921227>

American Burn Association (s. f.) *Burn First Aid*. Recuperado el 31 de octubre de 2024 de <https://ameriburn.org/resources/burn-first-aid/>

Bhansali, R. & Kumar, R. (2021). *BurnNet: An Efficient Deep Learning Framework for Accurate Dermal Burn Classification*. Medrxiv. <https://doi.org/10.1101/2021.01.30.21250727>

Biblioteca Nacional de Medicina. (s. f.). *Quemaduras*. En *Enciclopedia médica Medline-Plus*. Recuperado el 27 de octubre de 2024, de <https://bit.ly/4nTrw0L>

Chadebecq, F., Vasconcelos, F., Mazomenos, E. & Stoyanov, D. (2020). Computer Vision in the Surgical Operating Room. *Visceral Medicine*, 36(6), 456-462.  
<https://doi.org/10.1159/000511934>

Esteva, A., Kuprel, B., Novoa, R., Ko, J., Swetter, S., Blau, H. & Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542(7639), 115-118. <https://doi.org/10.1038/nature21056>

Gad, A. (19 de febrero de 2021). Evaluating Deep Learning Models: The Confusion Matrix, Accuracy, Precision, and Recall. *KD nuggets*. <https://bit.ly/4hiquJp>

Gupta, A., Seal, A., Prasad, M. & Khanna, P. (2020). Salient object detection techniques in computer vision—A survey. *Entropy*, 22(10), 1-49.  
<https://doi.org/10.3390/e22101174>

Hernández-Pérez, C., Combalia, M., Podlipnik, S., Codella, N., Rotemberg, V., Halpern, A., Reiter, O., Carrera, C., Barreiro, A., Helba, B., Puig, S., Vilaplana, V. & Malvehy, J. (2024). BCN20000: Dermoscopic Lesions in the Wild. *Scientific Data*, 11(1). <https://doi.org/10.1038/s41597-024-03387-w>

Jacobson, M., Masry, M., Arrubla, D., Tricas, M., Gnyawali, S., Zhang, X., Gordillo, G., Xue, Y., Sen, C. & Wachs, J. (2023). Autonomous Multi-modality Burn Wound Characterization using Artificial Intelligence. *Military Medicine*, 188(suplemento 6), 674-681. <https://doi.org/10.1093/MILMED/USAD301>

Khan, A., Laghari, A. & Awan, S. (2021). Machine Learning in Computer Vision: A Review. *EAI Endorsed Transactions on Scalable Information Systems*, 8(32), 1-11.  
<https://doi.org/10.4108/eai.21-4-2021.169418>

Lecun, Y., Bengio, Y. & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.  
<https://doi.org/10.1038/nature14539>

Litjens, G., Kooi, T., Bejnordi, B., Setio, A., Ciompi, F., Ghafoorian, M., van der Laak, J., van Ginneken, B. & Sánchez, C. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42, 60-88.  
<https://doi.org/10.1016/J.MEDIA.2017.07.005>

Moura, F., Amin, K. & Ekwobi, C. (2021). Artificial intelligence in the management and treatment of burns: a systematic review. *Burns & Trauma*, 9.  
<https://doi.org/10.1093/BURNST/TKAB022>

Munawar, M. & Jocher, G. (s. f.). *Ultralytics YOLO11 [Conjunto de datos de GitHub]*. Recuperado el 3 de noviembre de 2024 de <https://github.com/ultralytics/ultralytics>

Padilla, R., Netto, S. & da Silva, E. (1-3 de julio de 2020). *A Survey on Performance Metrics for Object-Detection Algorithms*. International Conference on Systems, Signals, and Image Processing. Niteroi, Brazil, 237–242.  
<https://doi.org/10.1109/IWSSIP48289.2020.9145130>

Radzikowska-Büchner, E., Łopuszyńska, I., Flieger, W., Tobiasz, M., Maciejewski, R. & Flieger, J. (2023). An Overview of Recent Developments in the Management of Burn Injuries. *International Journal of Molecular Sciences*, 24(22), 16357. <https://doi.org/10.3390/IJMS242216357>

Redmon, J. (23 de agosto de 2016). *Darknet: Open Source Neural Networks in C*. Recuperado el 24 de octubre de 2024 de <https://github.com/pjreddie/darknet/wiki>

Ulhaq, A., Khan, A., Gomes, D. & Paul, M. (2020). *Computer Vision For COVID-19 Control: A Survey*. <http://arxiv.org/abs/2004.09420>

Voxel51(s. f.). *Fine-tune YOLOv8 models for custom use cases with the help of FiftyOne*. Recuperado el 10 de noviembre de 2024 de <https://docs.voxel51.com/tutorials/yolov8.html>

Yadav, D., Sharma, A., Singh, M. & Goyal, A. (2019). Feature extraction based machine learning for human burn diagnosis from burn images. *IEEE Journal of Translational Engineering in Health and Medicine*, 7. <https://doi.org/10.1109/JTEHM.2019.2923628>