

YOLOV11 APLICADO A LA SEGMENTACIÓN Y CLASIFICACIÓN DE QUEMADURAS EN LA PIEL

Iván Avena-Caro¹, Alexa Gabaldón-Márquez¹, Raymundo Cornejo García², Norman Rendón Mejía³,
Carlos R. Cervantes-Sánchez³, Graciela Ramírez-Alonso^{1*}

¹Laboratorio de Visión por Computadora y Ciencia de Datos, Facultad de Ingeniería, Universidad Autónoma de Chihuahua, Circuito Número I, Nuevo Campus Universitario, Chihuahua, Chihuahua, México

²Universidad Autónoma de Chihuahua, Circuito Número I, Nuevo Campus Universitario, Chihuahua, México

³Hospital General de Chihuahua, Dr. Salvador Zubirán Anchondo, Ave. Cristóbal Colón 31200, Chihuahua, Chihuahua, México

* galonso@uach.mx

RESUMEN.

Las quemaduras representan un problema de salud pública a nivel mundial, especialmente en países con acceso limitado a servicios especializados. En este trabajo se implementa y evalúa un modelo de segmentación de quemaduras basado en la arquitectura YOLOv11, utilizando un conjunto de datos público disponible en la plataforma Roboflow. El modelo permite segmentar y clasificar lesiones de primer, segundo y tercer grado a partir de imágenes, alcanzando su mejor desempeño en la detección de quemaduras de tercer grado, con valores de precisión, exhaustividad y mAP50 de 0.675, 0.774 y 0.67, respectivamente. No obstante, se identifican limitaciones en la detección de quemaduras de primer y segundo grado, reflejadas en un alto número de falsos negativos y bajos valores de exhaustividad. Este trabajo constituye un primer paso hacia el desarrollo de sistemas de apoyo al diagnóstico clínico de quemaduras, con potencial de implementación en entornos hospitalarios para mejorar la atención médica. En particular, se plantea su aplicación en la Unidad de Quemados del Hospital General Dr. Salvador Zubirán Anchondo del Estado de Chihuahua.

Palabras Clave: Segmentación de quemaduras, clasificación de lesiones, YOLOv11.

ABSTRACT.

Burns represent a global public health issue, particularly in countries with limited access to specialized services. This study implements and evaluates a burn segmentation model based on the YOLOv11 architecture, using a publicly available dataset on the Roboflow platform. The model enables the segmentation and classification of first, second, and third-degree burn injuries from images, achieving its best performance in detecting third-degree burns, with precision, recall, and mAP50 values of 0.675, 0.774, and 0.67, respectively. However, we identified limitations in detecting first and second-degree burns, reflected in a high number of false negatives and low recall values. This work represents a first step toward the development of clinical diagnostic support systems for burns, with potential implementation in hospital settings to improve medical care. We propose its application for the Burn Unit at the Dr. Salvador Zubirán Anchondo General Hospital in the State of Chihuahua

Keywords: Burn segmentation, lesion classification, YOLOv11.

1. INTRODUCCIÓN

Las quemaduras representan un problema global de salud pública, con alrededor de 195,000 muertes anuales, principalmente en países en desarrollo donde el acceso a atención médica especializada es limitado [1][2]. Estas lesiones pueden ser causadas por diversos agentes como fricción, frío, calor, radiación, sustancias químicas o fuentes eléctricas. Sin embargo, el principal desencadenante es el calor [3]. La profundidad y la extensión de la lesión son factores clave para determinar la gravedad de la quemadura, influyendo directamente en el pronóstico y el tratamiento adecuado. Según su profundidad, las quemaduras se clasifican en tres categorías: superficiales (primer grado), de espesor parcial (segundo grado) y de espesor total (tercer grado). Estas últimas son las más severas, con potencial afectación de tejidos profundos, pérdida de sensibilidad y riesgo de amputación. Un tratamiento inadecuado en este tipo de lesiones puede provocar complicaciones sistémicas como sepsis, shock hipovolémico y disfunción generalizada de órganos vitales [4].

El diagnóstico inicial de una quemadura suele realizarse mediante inspección visual, un método con precisión limitada, especialmente cuando lo realizan profesionales sin especialización en quemaduras. De acuerdo con la investigación presentada en [5], la precisión en el diagnóstico de la profundidad de las quemaduras es inferior al 50 % cuando la evaluación es realizada por profesionales no especializados en el manejo de este tipo de lesiones. Esta limitación se agrava en regiones con escasos recursos e infraestructura médica.

Frente a esta limitación diagnóstica, distintos trabajos de investigación han propuesto el uso de modelos basados en inteligencia artificial, los cuales permiten analizar imágenes para identificar y clasificar lesiones por quemaduras con alta precisión [4], [6]–[9]. En particular, modelos de segmentación de imágenes han demostrado ser herramientas efectivas para delimitar el área afectada y diferenciar entre los distintos grados de lesión, lo que resulta clave para una evaluación clínica más precisa y un tratamiento oportuno.

En este trabajo, se implementa un modelo de segmentación basado en la arquitectura *You Only Look Once* versión 11 (YOLOv11), con el objetivo de segmentar y clasificar automáticamente lesiones de primer, segundo y tercer grado en imágenes de quemaduras. Aunque YOLOv11 ha sido utilizado con éxito en tareas de segmentación en otros tipos de problemas, su aplicación para la segmentación de quemaduras en la piel aún no ha sido explorada. Este estudio, por lo tanto, evalúa la factibilidad y el desempeño de dicho modelo en este contexto específico. El entrenamiento y validación del modelo se realizaron utilizando un conjunto de datos público disponible en la plataforma Roboflow, que contiene imágenes anotadas de quemaduras en piel. Esta investigación representa un primer acercamiento hacia el desarrollo de una aplicación clínica que se planea implementar en el Hospital General Dr. Salvador Zubirán Anchondo del Estado de Chihuahua. Dicho hospital cuenta con una Unidad de Quemados, especializada en la atención integral de pacientes con lesiones de este tipo, brindando tratamiento médico, intervenciones quirúrgicas y programas de rehabilitación orientados a reducir las secuelas físicas y mejorar la calidad de vida de los pacientes.

2. MATERIALES Y METODOS

En esta sección se presenta una descripción del algoritmo YOLOv11, características del conjunto de datos del experimento, y proceso de análisis de la información.

2.1. YOLOv11.

YOLO (*You Only Look Once*) es un algoritmo de detección de objetos propuesto por Redmon et al. [10], el cual aborda esta tarea como un problema de regresión. A partir de una red neuronal, el modelo es capaz de predecir simultáneamente las coordenadas de los *bounding boxes* y las clases a las que pertenecen los objetos presentes en una imagen. A la fecha del presente estudio, YOLOv11 [11] representa la versión más reciente de esta familia de modelos, y ha sido extendida para tareas como estimación de pose, seguimiento de objetos (*tracking*), clasificación de imágenes y segmentación de instancias. En este trabajo, se utilizará específicamente para la segmentación de instancias identificando y clasificando los distintos grados de quemaduras en la piel a partir de imágenes.

La arquitectura neuronal de YOLOv11 se compone de tres elementos principales: *backbone*, *neck* y *head*. Esta estructura, junto con sus componentes internos, se presenta en la Figura 1. El *backbone* está compuesto por capas convolucionales que reducen progresivamente la dimensión espacial de la imagen mientras aumenta el número de canales, permitiendo una representación más rica de las características. El bloque C3K2, está diseñado para ser computacionalmente eficiente favoreciendo así un procesamiento más rápido.

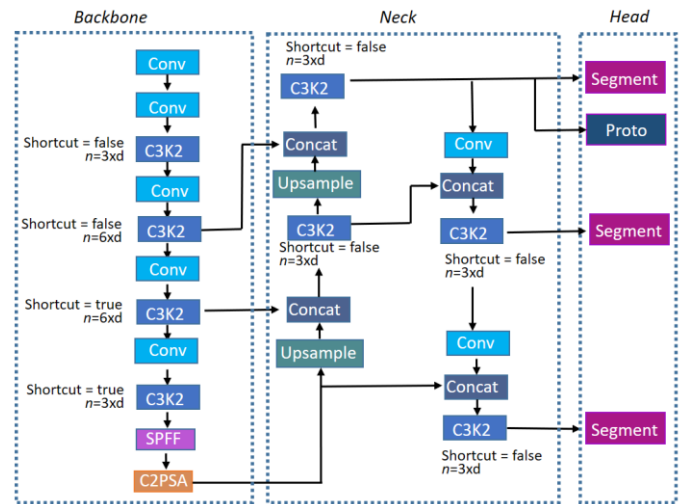


Figura 1. Diagrama a bloques del modelo YOLOv11, compuesto por *backbone*, *neck* y *head*, junto con sus respectivos submódulos internos para la extracción de características, fusión multiescala, segmentación y clasificación.

Este bloque contiene múltiples sub-bloques C3K, los cuales a su vez integran estructuras tipo *BottleNeck*. Adicionalmente, dentro del *backbone* se tienen los bloques de *Spatial Pyramid Pooling – Fast* (SPPF) junto con *Cross Stage Partial with Spatial Attention* (C2PSA), una combinación que mejora la atención espacial sobre los mapas de características, permitiendo al modelo enfocarse en las regiones más relevantes de la imagen.

La sección *neck* se encarga de fusionar características extraídas a diferentes escalas por el *backbone*, utilizando técnicas de *upsampling* y concatenación. Dentro del *neck* se tienen bloques C3K2, los cuales permite analizar información multiescala. Las características combinadas se transfieren posteriormente al módulo *head*, encargado de generar las segmentaciones finales de los objetos de interés, en este caso particular, el segmentar diferentes tipos de lesiones en la piel.

El modelo YOLOv11, en su versión orientada a tareas de segmentación, incorpora el enfoque de segmentación por instancias adoptado por YOLACT [12]. Esta arquitectura emplea rutas paralelas que permiten realizar de manera conjunta la detección de objetos y la segmentación.

YOLOv11 utiliza una función de pérdida que combina cuatro funciones: *Box_loss* (L_{box}), *Cls_loss* (L_{cls}), *Seg_loss* (L_{seg}), y *Dfl_loss* (L_{dfl}). *Box_loss* (L_{box}) mide la diferencia entre las cajas delimitadoras predichas y las reales. *Cls_loss* (L_{cls}) emplea la pérdida de entropía cruzada para optimizar los resultados de clasificación. *Seg_loss* (L_{seg}) combina entropía cruzada y la pérdida Dice para perfeccionar la segmentación a nivel de píxel en la región del deslizamiento. Por su parte, la *Dfl_loss* (L_{dfl}) incrementa la precisión en la localización de áreas complejas y objetos pequeños al estimar la distribución de probabilidad de la caja objetivo.

La ecuación (1) presenta la función de pérdida L_{box} , utilizada para optimizar la detección de objetos.

$$\begin{aligned}
 L_{box} &= \lambda_{center} * L_{center} + \lambda_{wh} * L_{wh} + \lambda_{conf} * L_{conf} \\
 L_{center} &= \sum_{i=0}^N smooth_{L1}(x_i - x_p) + smooth_{L1}(y_i - y_p) \\
 L_{wh} &= \sum_{i=0}^N smooth_{L1}(w_i - w_p) + smooth_{L1}(h_i - h_p) \\
 L_{conf} &= - \sum_{i=0}^N [C_i * \log(C_p) + (1 - C_i) * \log(1 - C_p)] \\
 smooth_{L1}(X) &= \begin{cases} 0.5X^2, & |X| < 1 \\ |X| - 0.5, & otherwise \end{cases}
 \end{aligned} \quad (1)$$

donde (x_i, y_i) y (x_p, y_p) representan las coordenadas del centro de la i -ésima caja real y predicha, respectivamente; (w_i, h_i) y (w_p, h_p) son el ancho y alto de dichas cajas. Además, C_i indica si la caja real contiene un objeto (1) o no (0), mientras que C_p representa la confianza predicha de que la caja contiene un objeto.

La ecuación (2) define la función de pérdida de clasificación L_{cls} , la cual se encarga de optimizar la asignación correcta de clases a las cajas predichas.

$$L_{cls} = - \sum_{i=0}^N \sum_{c=0}^C \alpha_c [\delta_{i,c} * \log(p_{i,c}) + (1 - \delta_{i,c}) * \log(1 - p_{i,c})] \quad (2)$$

donde N es el número total de cajas predichas, y C es el número total de clases. El coeficiente α_c se usa para ponderar cada clase, asignando mayores valores a clases menos frecuentes para compensar el desbalance durante el entrenamiento. La función $\delta_{i,c}$ vale 1 si la clase verdadera de la i -ésima caja es c , y 0 en caso contrario. Por último, $p_{i,c}$ representa la probabilidad de que la caja i pertenezca a la clase c .

La siguiente ecuación, define la función de pérdida total para la tarea de segmentación semántica, L_{seg} donde H y W representan la altura y el ancho de la imagen. Finalmente, λ_{ce} y λ_{dice} son factores de ponderación que ajustan la importancia relativa entre las pérdidas cross-entropy y Dice.

$$\begin{aligned}
 L_{seg} &= \lambda_{ce} * L_{ce} + \lambda_{dice} * L_{dice} \\
 L_{ce} &= - \sum_{i=0}^H \sum_{j=0}^W \sum_{c=0}^C [\delta_{i,j,c} * \log(p_{i,j,c}) + (1 - \delta_{i,j,c}) * \log(1 - p_{i,j,c})] \\
 L_{dice} &= 1 - \frac{2 \sum_{i,j} \delta_{i,j,c} * p_{i,j,c}}{\sum_{i,j} \delta_{i,j,c} + \sum_{i,j} p_{i,j,c}}
 \end{aligned} \quad (3)$$

La función de pérdida L_{dfl} , utilizada para refinar la regresión de los bordes de las cajas mediante una distribución de probabilidad discreta, se presenta en la siguiente ecuación:

$$L_{dfl} = - \sum_{i=1}^N \sum_{k=1}^K \alpha_{i,k} * (1 - p_{i,k})^\gamma * \log(p_{i,k}) \quad (4)$$

donde K representa los puntos de distribución discreta usados para estimar los bordes de cada caja. El factor $\alpha_{i,k}$ asigna mayor peso a los puntos más difíciles de predecir, mientras que $p_{i,k}$ indica la probabilidad predicha en el punto k para la muestra i , siendo más precisa la predicción cuanto más cercano esté a 1. Por último, γ , usualmente igual a 2, ajusta el énfasis en muestras difíciles durante el entrenamiento.

2.2. Dataset.

El conjunto de datos utilizado para entrenar el modelo fue descargado de la plataforma Roboflow¹. Este dataset es público y contiene imágenes anotadas de quemaduras en la piel, clasificadas según su gravedad.

La Figura 2 presenta ejemplos de las imágenes incluidas en este conjunto de datos, junto con la clasificación del grado de quemadura correspondiente. Cada imagen está acompañada de una máscara que delimita la región afectada en la piel, la cual fue generada manualmente por los autores del conjunto de datos.

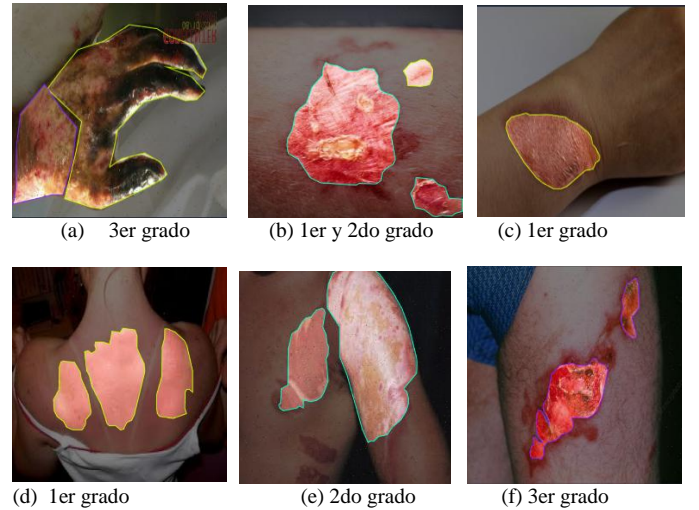


Figura 2. Ejemplos de lesiones de primer, segundo y tercer grado presentes en el conjunto de datos de Roboflow.

El conjunto de datos contiene 4,148 imágenes. Sin embargo, tras una inspección visual detallada, se eliminaron aquellas imágenes

¹ Disponible en: <https://universe.roboflow.com/zakiyya/kulit-bakar/browse?queryText=&pageSize=50&startIndex=0&browseQuery=true>

repetidas y aquellas que carecen de información de la máscara delimitadora necesaria para la segmentación. La Tabla 1 presenta la distribución final de imágenes e instancias seleccionadas después del ajuste del conjunto de datos original. En ella se detalla la distribución de las particiones de entrenamiento, validación y prueba, así como el grado de quemadura correspondiente en cada caso. Se puede apreciar que las imágenes correspondientes a quemaduras de primer grado son menos numerosas.

Tabla 1. Cantidad de imágenes e instancias disponibles en las diferentes particiones del conjunto de datos.

Grado	Entrenamiento		Validación		Prueba	
	Img	Insts	Img	Insts	Img	Insts
1er	186	242	39	55	44	61
2do	320	467	57	74	60	82
3er	342	391	25	28	27	31
Total	736	1100	107	157	120	174

2.3 Métricas de evaluación

Para la evaluación del modelo de segmentación YOLOv11, se calcula la métrica *Intersection over Union* (IoU) entre cada máscara predicha y su correspondiente máscara *ground truth* (GT) a nivel de píxel. Cuando la IoU supera un umbral establecido (generalmente 0.5), la predicción se considera un verdadero positivo. A partir de esta comparación se construyen valores de *precision* contra *recall* para cada clase, y el área bajo cada curva corresponde al *Average Precision* (AP). Finalmente, el valor de mAP (*mean Average Precision*) se obtiene promediando los APs entre todas las clases. El cálculo de la IoU se define mediante la siguiente Ecuación 5.

$$IoU = \frac{|M_p \cap M_{gt}|}{|M_p \cup M_{gt}|} \quad (5)$$

donde \cap representa la operación de intersección y \cup la de unión entre la máscara predicha por el modelo, M_p y la máscara correspondiente del *ground truth*, M_{gt} . La métrica de *precision* está definida por la Ecuación (6).

$$Precision = \frac{TP}{TP + FP} \quad (6)$$

donde TP hace referencia a los verdaderos positivos, es decir, aquellas predicciones cuya IoU con la máscara real supera un umbral determinado (típicamente 0.5), y FP corresponde a los falsos positivos, que son aquellas predicciones incorrectas o que no alcanzan dicho umbral. Además de la precisión, otra métrica fundamental en la evaluación del desempeño de modelos de segmentación es el *Recall*, la cual indica la proporción de objetos reales que fueron correctamente detectados por el modelo. Esta métrica se define mediante la siguiente Ecuación:

$$Recall = \frac{TP}{TP + FN} \quad (7)$$

donde FN representan los falsos negativos, es decir aquellas regiones donde el modelo no logró predecir correctamente. Tanto la *precision* como el *recall* se utilizan para el cálculo del *Average Precision* (AP) y *mean Average Precision* (mAP) definidos por

$$AP = \int_0^1 Precision(r) dr \quad (8)$$

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (9)$$

donde r indica el valor de *recall*, $Precision(r)$ el valor de la precisión correspondiente al valor de r , N indica el número total de clases a identificar y AP_i el valor de *Average Precision* para la clase i .

3. RESULTADOS

La Tabla 2 presenta los resultados de segmentación obtenidos por el modelo en el conjunto de prueba. Se observa que las lesiones de tercer grado muestran el mejor desempeño, con valores de *precision* (0.675), *recall* (0.774) y *mAP50* (0.67) superiores a los de primer y segundo grado. Esto sugiere que el modelo es más eficiente en la segmentación de quemaduras de tercer grado, posiblemente debido a características visuales más definidas o a una mejor representación de estas lesiones en el conjunto de datos. Por otro lado, los bajos valores de *recall* para las quemaduras de primer (0.178) y segundo grado (0.415) evidencian las dificultades del modelo para detectar estos tipos de lesiones.

Tabla 2. Resultados de segmentación por grado de quemadura en la partición de prueba (*precision*, *recall* y *mAP50*)

Grado	Mask(P)	Mask(R)	Mask (mAP50)
1er	0.376	0.178	0.194
2do	0.595	0.415	0.452
3er	0.675	0.774	0.67
Total	0.549	0.456	0.438

La Figura 3 muestra los resultados de la matriz de confusión de la partición de prueba, donde se observa que un total de 45 instancias con quemaduras de primer grado y 43 con quemaduras de segundo grado no fueron detectadas por el modelo, lo cual muestra una alta tasa de falsos negativos para estos grados de quemaduras. En contraste, las quemaduras de tercer grado son las que el modelo logra detectar con mayor precisión.

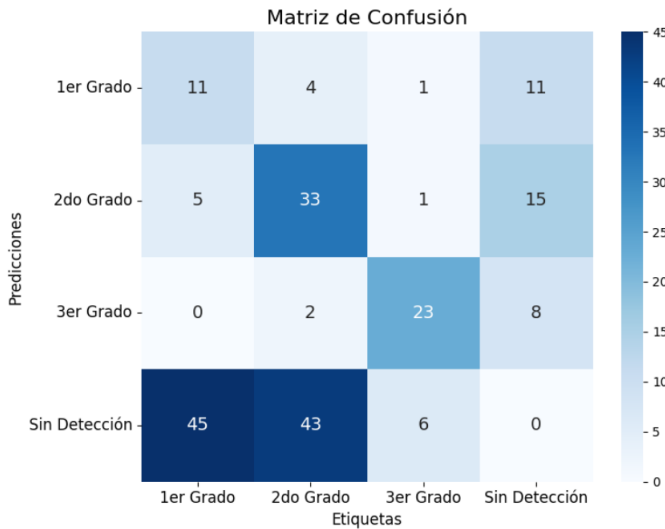


Figura 3. Matriz de confusión de las predicciones del modelo para lesiones de quemaduras de primer, segundo y tercer grado.

Este comportamiento reafirma los resultados observados en la Tabla 2, donde se reporta un mayor desempeño del modelo en la segmentación de lesiones de tercer grado en comparación con las de primer y segundo grado.

La Figura 4 muestra algunas predicciones generadas por el modelo. En los primeros tres renglones se observa que logra identificar correctamente quemaduras de primer, segundo y tercer grado, incluso en imágenes que presentan lesiones de más de un tipo. En contraste, en los últimos renglones se presentan ejemplos de casos en los que el modelo no logra detectar quemaduras de primer y segundo grado, evidenciando limitaciones en la sensibilidad para identificar lesiones menos extensas o con características menos diferenciadas.

4. DISCUSIÓN

Con el fin de contrastar el desempeño de YOLOv11 con otros trabajos relacionados, se describen los siguientes estudios. Ferdinand et al. [13] implementaron modelos YOLOv5 y YOLOv7 para la detección y clasificación de quemaduras utilizando un conjunto de datos de Roboflow, reportando como mejor resultado un mAP50 de 0.837 con YOLOv5 tras ajuste de hiperparámetros. Aunque sus resultados son competitivos, no especificaron en qué clases se presentaron mayores dificultades. Por otro lado, Luo et al. [14] desarrollaron YOLOv7-PSA, un modelo que incorpora el módulo *Pyramid Split Attention*, alcanzando valores de *recall* de 0.857, 0.832 y 0.869 para quemaduras de primer, segundo y tercer grado, respectivamente. Si bien sus resultados son sólidos, el modelo fue entrenado con un conjunto de datos propio, lo que dificulta la reproducibilidad.

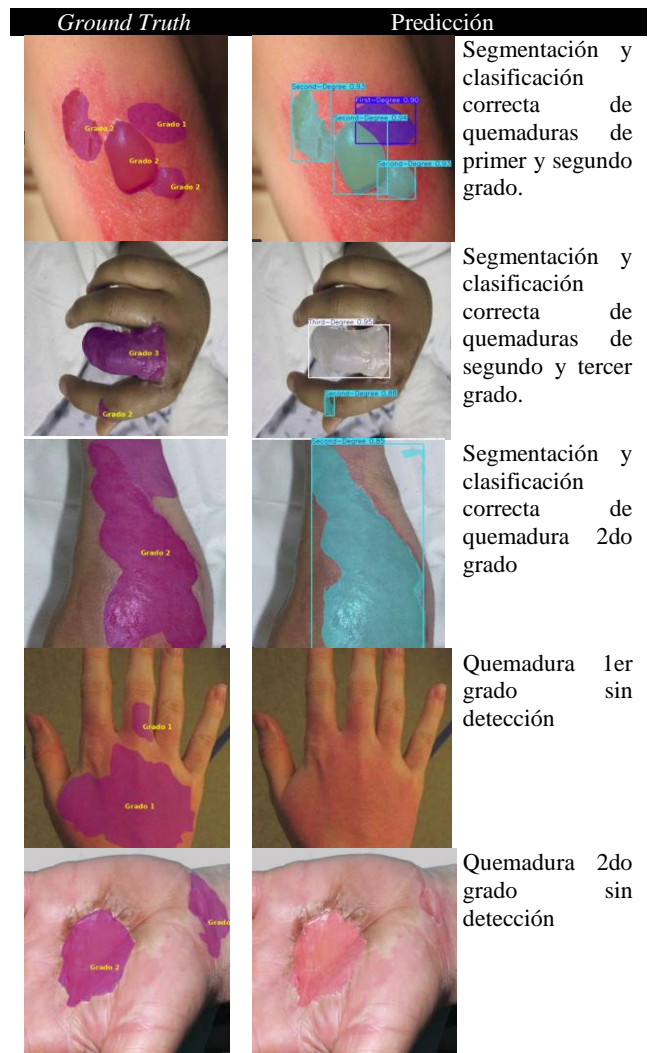


Figura 4. Predicciones del modelo en la segmentación y clasificación de quemaduras.

Ambos trabajos se centraron en la detección mediante cajas delimitadoras y no en la segmentación de instancias. En contraste, nuestro modelo YOLOv11 se orienta a la segmentación a nivel de píxel, lo que permite delimitar con mayor precisión el área afectada y ofrecer una interpretación más clara de las clases más complejas, en particular las quemaduras superficiales y de espesor parcial, aportando así un valor clínico adicional para el diagnóstico y tratamiento.

Finalmente, el estudio de Yıldız et al. [8], desarrollado en Turquía con YOLOv7 y una aplicación móvil, alcanzó un mAP50 de 0.751 y mostró menor desempeño en la identificación de quemaduras de primer grado. Estos resultados coinciden con nuestras observaciones, donde las quemaduras superficiales y de espesor parcial representan las clases más difíciles de identificar.

Es importante destacar que no es posible establecer una comparación totalmente justa entre los modelos, ya que, aunque dos de ellos mencionan el uso de la base pública de Roboflow, las particiones difieren entre estudios. En este trabajo se optó por emplear YOLOv11 por ser la versión más reciente y con mejoras específicas para segmentación, quedando como trabajo futuro la evaluación de distintas arquitecturas bajo condiciones experimentales equivalentes.

5. CONCLUSIONES

En este trabajo se implementó y evaluó un modelo de segmentación de quemaduras basado en YOLOv11, utilizando un conjunto de datos de Roboflow. Los resultados muestran un desempeño destacado en la segmentación de quemaduras de tercer grado, atribuible a su mayor diferenciación visual y representación en el conjunto de datos. En contraste, se observaron limitaciones en la detección de quemaduras de primer y segundo grado, lo que evidencia la necesidad de contar con bases de datos más equilibradas y validadas por especialistas.

Como trabajo futuro, se plantea validar el modelo con datos clínicos reales y explorar técnicas de segmentación multiclase más robustas que permitan mejorar la sensibilidad en lesiones superficiales. De este modo, este estudio constituye un primer paso hacia el desarrollo de herramientas de apoyo al diagnóstico de quemaduras, con potencial de aplicación en entornos hospitalarios.

6. REFERENCIAS

- [1] “OMS EMRO | Introducción | Quemaduras | Temas de salud.” [En línea]. Disponible: https://www-emro-who-int.translate.google.com/health-topics/burns/introduction.html?_x_tr_sl=en&_x_tr_tl=es&_x_tr_hl=es&_x_tr_pto=wa. [Accessed: 6-Junio-2025].
- [2] “World Health Organization, A WHO Report Plan for Burn Prevention and Care, Newsroom.” [En línea]. Disponible: <https://www.who.int/news-room/factsheets/detail/burns/>. [Accessed: 6-Junio-2025].
- [3] M. G. Jeschke, M. E. van Baar, M. A. Choudhry, K. K. Chung, N. S. Gibran, and S. Logsetty, “Burn injury,” *Nat. Rev. Dis. Prim.* 2020 61, vol. 6, no. 1, pp. 1–25, Feb. 2020.
- [4] X. Xu, Q. Bu, J. Xie, H. Li, F. Xu, and J. Li, “On-site burn severity assessment using smartphone-captured color burn wound images,” *Comput. Biol. Med.*, vol. 182, p. 109171, Nov. 2024.
- [5] R. L. Brekke, S. K. Almeland, K. O. Hufthammer, and E. Hansson, “Agreement of clinical assessment of burn size and burn depth between referring hospitals and burn centres: A systematic review,” *Burns*, vol. 49, no. 3, pp. 493–515, May 2023.
- [6] C. Pabitha and B. Vanathi, “Densemack RCNN: A Hybrid Model for Skin Burn Image Classification and Severity Grading,” *Neural Process. Lett.*, vol. 53, no. 1, pp. 319–337, Feb. 2021.
- [7] J. Chauhan and P. Goyal, “Convolution neural network for effective burn region segmentation of color images,” *Burns*, vol. 47, no. 4, pp. 854–862, Jun. 2021.
- [8] M. Yildiz *et al.*, “Segmentation and classification of skin burn images with artificial intelligence: Development of a mobile application,” *Burns*, vol. 50, no. 4, pp. 966–979, May 2024.
- [9] C. W. Chang *et al.*, “Application of multiple deep learning models for automatic burn wound assessment,” *Burns*, vol. 49, no. 5, pp. 1039–1051, Aug. 2023.
- [10] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, “You Only Look Once: Unified, Real-Time Object Detection,” in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016, pp. 779–788.
- [11] R. Khanam and M. Hussain, “YOLOv11: An Overview of the Key Architectural Enhancements,” Oct. 2024.
- [12] D. Bolya, C. Zhou, F. Xiao, and Y. J. Lee, “YOLACT: Real-time Instance Segmentation.” 2019.
- [13] J. Ferdinand, D. Viriya Chow, y S. Yuda Prasetyo, “Automated skin burn detection and severity classification using YOLO Convolutional Neural Network Pretrained Model,” *E3S Web Conf.*, vol. 426, pp. 01076, 2023. doi: 10.1051/e3sconf/202342601076
- [14] Y. Luo, K. Zhang, R. Wang, L. Yi, y Z. Zhou, “YOLOv7-PSA, an intelligent detection model, is designed for assessing the severity of skin burns,” *Regenesi Repair Rehabilitation*, vol. 1, no. 2, pp. 80–86, 2025. doi: 10.1016/j.rerere.2025.03.002.