

**DISEÑO DE UN PROTOTIPO DE ANÁLISIS DIGITAL DE IMÁGENES
PARA ESTIMACIÓN DE PROFUNDIDAD DE QUEMADURAS.**

**ANNA KATHERINE RUIZ RUALES, M.D.
WALTER ARIAS FLOREZ**

Directora: Ana María Salinas, M.D., Esp.

**Trabajo de Investigación para optar al Título de Especialista en
Cirugía Plástica Maxilofacial y de la Mano**

**UNIVERSIDAD DE ANTIOQUIA
FACULTAD DE MEDICINA
MEDELLIN
2021**

RESUMEN

Introducción: La tecnología de inteligencia artificial y las redes neuronales convolucionales (RNC) son uno de los principales campos de investigación en el desarrollo de herramientas de apoyo en medicina, con potencial aplicación en el diagnóstico de quemaduras.

Metodología: Se diseñó un modelo de RNC con una base de datos de 150 fotografías de pacientes hospitalizados en las unidades de quemados del Hospital Universitario San Vicente Fundación. Las fotografías fueron marcadas según grados de profundidad por 3 cirujanos plásticos con experiencia en el manejo de pacientes quemados y editadas en 466 imágenes, de las cuales 400 se clasificaron según el grado de profundidad y se destinaron al entrenamiento del modelo y 66 a la validación del mismo, estas últimas sin división según grado.

Resultados: La base de datos incluyó 91 imágenes de segundo grado superficial, 200 imágenes de segundo grado profundo y 175 imágenes de tercer grado. La validación del modelo de RNC mostró una eficiencia del 84.85% para clasificación de quemaduras según profundidad, resultado acorde a la precisión descrita en la literatura para la evaluación clínica realizada por un cirujano plástico.

Conclusiones: Es factible el diseño de un prototipo de herramienta de apoyo diagnóstico para la clasificación de quemaduras según profundidad, usando RNC.

Palabras clave: Quemaduras, Clasificación, Diagnóstico por imagen, Redes neuronales convolucionales, Telemedicina.

INTRODUCCIÓN

Las quemaduras constituyen un problema de salud pública en Colombia, con una incidencia de 1.3 casos por cada cien mil habitantes (1); son la tercera causa más frecuente de muerte por trauma y una de las principales causas de discapacidad, afectando principalmente personas en edad laboral y niños menores de 5 años (2).

El tratamiento oportuno de un paciente quemado es fundamental para mejorar la sobrevida y disminuir las secuelas funcionales, para esto es necesario un diagnóstico y clasificación adecuados que permitan el acceso al nivel de atención de acuerdo con la gravedad de la lesión (3). Uno de los principales factores de clasificación es el grado de profundidad, este divide las quemaduras en 4 categorías (I grado, II grado superficial, II grado profundo y III grado) de acuerdo con las capas de la piel afectadas y se evalúa según características clínicas (4). La clasificación de profundidad es difícil, debido a que depende de la evaluación de parámetros subjetivos y requiere de una curva de aprendizaje que se obtiene únicamente mediante la exposición a un gran número de casos (5).

Estudios que comparan la evaluación de ingreso con el desenlace final muestran que la precisión diagnóstica para médicos de áreas distintas a cirugía plástica es del 50%, aumenta al 65 - 75% para cirujanos plásticos y hasta el 80% para cirujanos plásticos dedicados al manejo de quemados (4, 6). Todo esto afecta principalmente a los servicios de urgencias, donde la mayoría de los médicos no cuentan con experiencia específica en el manejo de quemaduras, lo que lleva a un mayor número de errores diagnósticos, traslados y tratamientos inadecuados (4).

Problemas similares derivados de la dificultad de acceso a la atención especializada han encontrado solución mediante el uso de estrategias de telemedicina; particularmente en cirugía plástica, han facilitado la colaboración entre médicos generales y especialistas para casos como la evaluación remota de heridas mediante fotografías, permitiendo reducción del tiempo de diagnóstico y del número de traslados innecesarios, o en el monitoreo de colgajos libres a través de video, donde la disminución del tiempo diagnóstico entre un 65 a 90%, ha mejorado el porcentaje de reintervención temprana y por tanto su éxito (7). En este

contexto surge la necesidad de buscar herramientas que permitan mejorar el proceso diagnóstico de las quemaduras, especialmente en entornos con difícil acceso a evaluación especializada.

El rápido desarrollo tecnológico de las últimas décadas y el uso generalizado de teléfonos inteligentes en la actualidad son claves en este proceso al facilitar el desarrollo y accesibilidad de herramientas computacionales de apoyo diagnóstico. Una de las tecnologías que más se destaca en este aspecto es la Inteligencia artificial y más específicamente el uso de Redes Neuronales Convolucionales (RNC) para análisis digital de imágenes, el cual, se ha usado con éxito en diversas áreas de la medicina como neurología, radiología y oftalmología (8). En el campo específico del manejo de quemaduras, el desarrollo realizado por Acha en 2005 con 250 imágenes ha logrado resultados promisorios con una eficiencia del 82%, mediante procesamiento con la RNC Fuzzy-ARTMAP (9). El presente estudio plantea el diseño de un prototipo de herramienta de apoyo diagnóstico mediante la construcción de un modelo de RNC de software libre, con ventajas como un bajo costo operacional, posibilidad de aplicación en múltiples dispositivos con conexión a internet y bajos requerimientos de sistema para su ejecución, orientado al uso en salas de urgencias y primeros niveles de atención.

METODOLOGÍA

Tipo de estudio y población.

Estudio de tipo observacional de corte transversal, realizado en el Hospital San Vicente Fundación (HSVF) de Medellín, centro de referencia en el manejo de quemaduras del noroccidente colombiano, con un promedio de 300 casos al año según estadísticas de 2005 (2).

Se tomó una muestra por conveniencia de 119 pacientes entre los meses de diciembre de 2020 y marzo de 2021, incluyendo pacientes hospitalizados en las unidades de quemados de adultos e infantil, sin discriminación de etnia, edad o género, con quemaduras de 0 a 5 días de evolución de cualquier etiología y con

exclusión de pacientes con quemaduras sobre infectadas o en postoperatorio de escarectomía y/o injertos de piel. El estudio fue aprobado por el comité institucional de ética y se obtuvo consentimiento informado de todos los pacientes participantes en el estudio o de sus tutores. Los datos recolectados en forma de fotografías usadas para el desarrollo del prototipo no están al alcance de los usuarios finales ni puede accederse a ellas mediante ingeniería inversa.

Recolección y construcción de la base de datos.

Se tomaron 150 fotografías de quemaduras de 119 pacientes, posteriores al primer lavado en sala de urgencias, con más de una fotografía por paciente en casos de quemaduras múltiples. Todas las fotografías fueron tomadas con un dispositivo Smartphone Realme 6 pro® (Sky Li - Realme® 2019), con tamaño mínimo de imagen de 960 x 1280 píxeles, bajo iluminación blanca y sin uso de flash.

Las fotografías fueron evaluadas por cirujanos plásticos con al menos 3 años de experiencia en el manejo de quemaduras, quienes marcaron cada fotografía mediante el uso del Software Procreate® (Savage Interactive Pty Ltd. 2019), delimitando las áreas correspondientes a cada grado de quemadura identificado. Posteriormente las fotografías se editaron manualmente por la investigadora principal, separando las áreas delimitadas en imágenes diferentes, obteniendo 466 imágenes numeradas por orden de recolección, de las cuales las primeras 400 se destinaron a entrenamiento y se dividieron en 3 categorías: segundo grado superficial, segundo grado profundo y tercer grado, sin incluir la categoría de primer grado debido a que no es relevante para la clasificación de gravedad (10). Las 66 imágenes restantes se destinaron a validación y almacenaron en una carpeta separada sin división según grado.

Tras la división y clasificación, las fotografías se normalizaron a un tamaño de 224x224 píxeles y se transformaron al espacio de color LUV (Luminosidad – valor cromático U – valor cromático V), el cual mejora la percepción de pequeñas variaciones de color mediante la transformación matemática de los canales RGB (Rojo – verde – azul) usados por defecto en la fotografía digital. Adicionalmente,

desvincula el canal de iluminación (L) de los canales de valor cromático (U, V) lo que lo hace independiente del dispositivo de captura, e idóneo para el trabajo donde las diferencias de iluminación podrían afectar el resultado del análisis de la imagen (11). Esto flexibiliza la toma de fotografías permitiendo diversos tipos de iluminación, tanto artificial como natural. Más detalles acerca del espacio de color se describen en el anexo técnico.

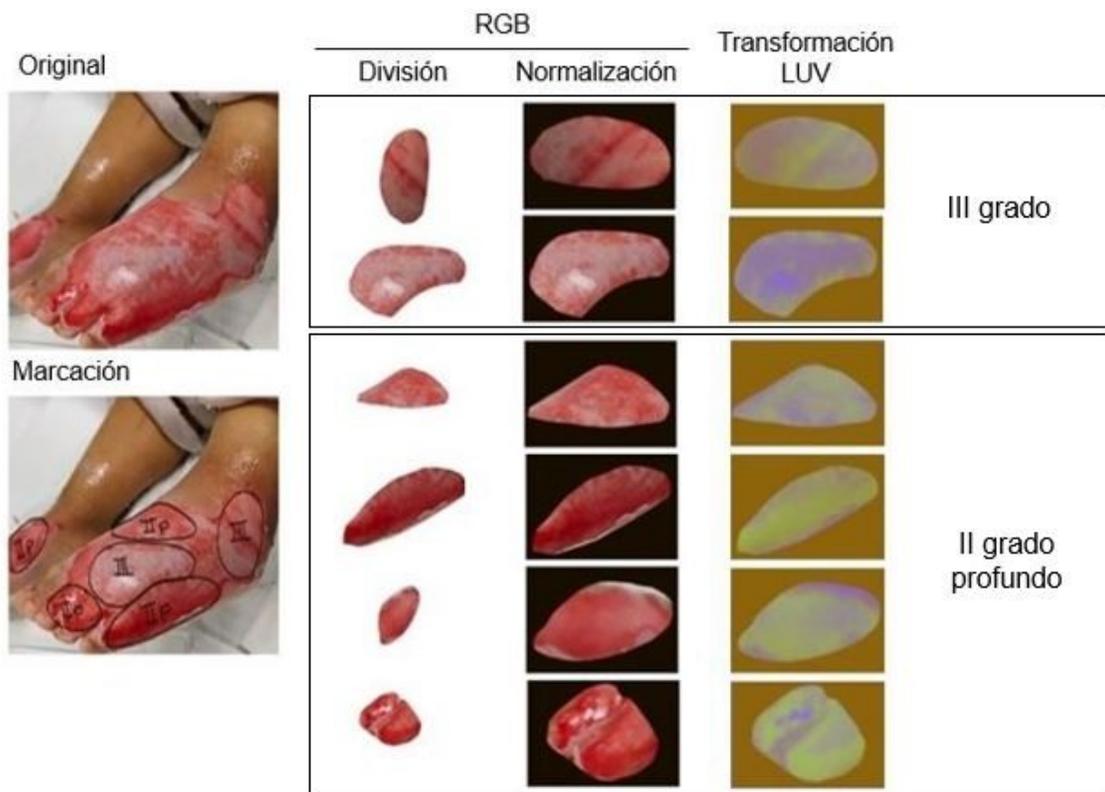


Figura 1. Ejemplo del proceso de edición y transformación de las fotografías.

Diseño del modelo de RNC

Las RNC son sistemas de procesamiento computacional inspirados en el modelo biológico del sistema nervioso, están compuestos por subsistemas interconectados llamados “nodos”; cada nodo representa una neurona y se encarga de tomar una decisión basándose en sus parámetros de calibración. La estructura básica de una RNC consiste en una entrada en forma de matriz de

información y una serie de capas ocultas, a través de las cuales la información es procesada, reorganizada y distribuida para tomar diferentes decisiones, según las características que se quieran obtener del vector de entrada para dar con una información de salida (8).

Nosotros diseñamos un modelo de RNC mediante la plataforma de código abierto TensorFlow® y la interfaz de programación de aplicaciones (API) Keras® (12), disponibles para el lenguaje de programación Python®, el cual es un lenguaje orientado a la investigación con licencia de código abierto, con bajos requerimientos del sistema para su ejecución y con una amplia comunidad de desarrolladores en el mundo (13).

El diseño consta de tres etapas: entrenamiento, evaluación interna o monitoreo del aprendizaje y evaluación externa o validación, las cuales se describen a continuación (para detalles técnicos ver documento anexo).

Entrenamiento

Es el proceso de extracción de las características visuales inherentes a cada grado de profundidad. Para esto, el modelo toma como matriz de información de entrada la base de datos de 400 imágenes previamente procesadas y etiquetadas según el grado de profundidad. Esta base de datos se denomina “verdad oculta” y constituye el punto de referencia y comparación con base el cual se realizará todo el proceso de entrenamiento (8) .

A continuación, las imágenes se procesan a través de una secuencia de capas ocultas de tres clases: convolución, sub-muestreo y capas densas. Las capas de convolución toman dos funciones de entrada; en este caso, cada imagen y una serie de filtros de información sobre las que se realizan una serie de operaciones matemáticas que ofrecen una función de salida, la cual representa las características extraídas en forma de matriz numérica. Las capas de sub-muestreo realizan convolución sobre segmentos de la imagen, lo que sirve para

extraer características de zonas específicas. Finalmente, las capas densas integran la información obtenida en las capas anteriores.

Cada paso a través de las capas ocultas se denomina bucle o época; tras finalizar el primer bucle, la información integrada por las capas densas se usa para determinar los filtros de información más eficientes en la extracción de características (14), los cuales se establecen como filtros iniciales en el bucle posterior y así sucesivamente hasta completar los 30 bucles que conforman el modelo, permitiendo la optimización de los filtros que serán usados para realizar la clasificación en la etapa de validación.

Monitoreo del aprendizaje

Se realiza automáticamente por el modelo, evalúa el proceso de entrenamiento al final de cada bucle con base en dos factores: precisión en entrenamiento y precisión de evaluación. La precisión de entrenamiento hace referencia a la cantidad de características extraídas como comunes en una categoría de imágenes y da una medida del grado de aprendizaje. Por otro lado, la precisión de evaluación mide cuántas imágenes son reconocidas exitosamente tras la aplicación de los filtros, en comparación con las etiquetas originales o verdad oculta.

La relación entre la precisión de entrenamiento y evaluación se conoce como ajuste, el cual debe tener un valor de 1 ± 0.1 . Valores inferiores significan que el entrenamiento es insuficiente, mientras que valores superiores indican que se ha superado la capacidad de adaptación del modelo a nueva información (14). Las técnicas usadas para el manejo del ajuste se describen en el anexo técnico.

Validación

Es la evaluación externa de la RNC entrenada, simula el uso del modelo por un usuario final. Se realizó usando la base de datos de 66 fotografías no clasificadas que no se incluyeron en la base de datos de entrenamiento y por tanto no están incluidas en la verdad oculta o información de referencia. Las fotografías de validación fueron procesadas de manera individual por el modelo, usando los filtros optimizados durante el proceso de entrenamiento, lo que resulta en un valor numérico para cada categoría que expresa el grado de correlación de la imagen con los patrones aprendidos; finalmente, el número más alto indica la clasificación de salida.

Para determinar el rendimiento del modelo se definen una serie de marcadores o métricas.

- Eficiencia (E): probabilidad del modelo de acertar una clasificación independientemente de la categoría.
- Error global (eG): probabilidad del modelo de errar una clasificación independientemente de la categoría.
- Precisión (P): probabilidad de que una predicción sea verdadera para una categoría determinada.
- Sensibilidad (S): probabilidad de clasificar correctamente una categoría.
- Error de precisión (eP): probabilidad de obtener una predicción falsa en una categoría determinada.
- Error de sensibilidad (eS): Probabilidad de clasificar incorrectamente una categoría.
- Valor F1: relación entre precisión y sensibilidad, expresa el rendimiento de la RNC.

RESULTADOS

Se incluyeron en el estudio 119 pacientes, de estos el 76.5% fueron pacientes adultos con un rango de edad entre 19 y 64 años y 23.5% niños entre 0 y 5 años. Se tomaron un total de 150 fotografías de las cuales un 55.3% correspondieron a

quemaduras únicas (83 pacientes con afectación de una sola área corporal) y 44.7% a quemaduras múltiples (24 pacientes con afectación de múltiples áreas corporales). Todas las fotografías incluyeron al menos dos áreas de distintos grados de profundidad por quemadura.

Los resultados de la clasificación de las imágenes tras el proceso de edición se muestran en la tabla 1.

Tabla 1. Clasificación de las imágenes editadas

Imágenes editadas		Clasificación según cirujanos plásticos		
		II grado superficial	II grado profundo	III grado
Entrenamiento	400	82	165	153
Evaluación	66	9	35	22
Total	466	91	200	175

Evaluación del entrenamiento - monitoreo del aprendizaje

La figura 2. Muestra el comportamiento del modelo a través de los diferentes bucles del proceso de entrenamiento. Los valores finales fueron de 83.5% para precisión de entrenamiento y 82.7% para la precisión evaluación. El resultado de la relación de ambas precisiones muestra un ajuste de 1.01, con tendencia a la disminución en el error de clasificación.

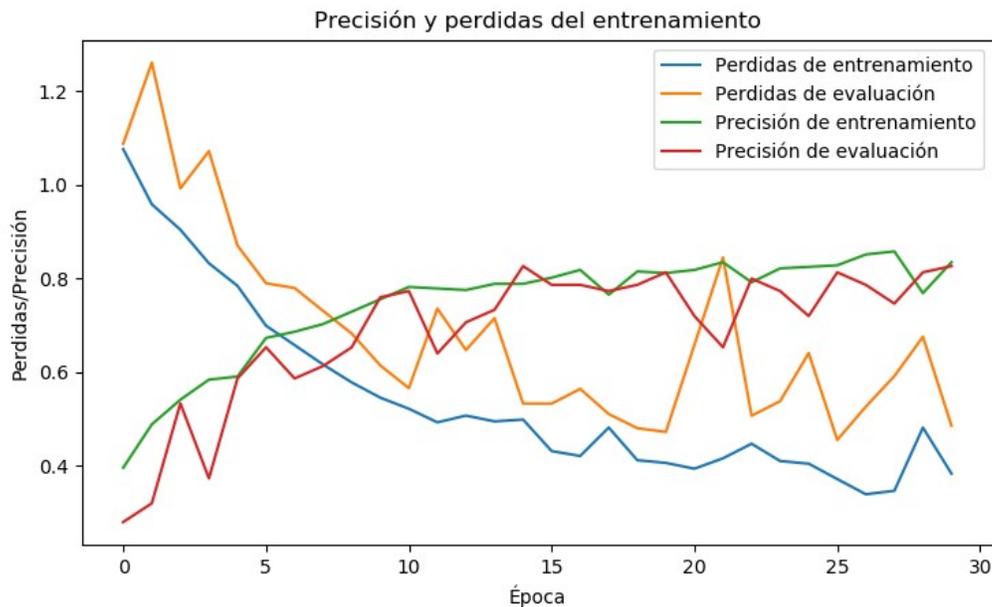


Figura 2. Comportamiento del modelo durante el proceso de entrenamiento.

Precisión de entrenamiento y evaluación a través de los diferentes bucles o épocas, datos normalizados (0 a 1). Las pérdidas de entrenamiento y evaluación se refieren al porcentaje estimado de cometer un error en una predicción aislada, con tendencia a la disminución gracias al ajuste.

Validación

Los resultados de la validación se consignan en la tabla 2.

Tabla 2. Resultados de validación

Image n	Clasificación por el cirujano plástico	Clasificación por el modelo
1	Grado III	Grado III
2	Grado III	Grado III
3	Grado III	Grado III
4	Grado III	Grado III
5	Grado III	Grado III
6	Grado III	Grado III
7	Grado III	Grado III
8	Grado III	Grado III
9	Grado III	Grado III

10	Grado III	Grado III
11	Grado III	Grado II profundo
12	Grado III	Grado III
13	Grado III	Grado III
14	Grado III	Grado III
15	Grado III	Grado II profundo
16	Grado III	Grado III
17	Grado III	Grado III
18	Grado III	Grado III
19	Grado III	Grado III
20	Grado III	Grado III
21	Grado III	Grado III
22	Grado III	Grado III
23	Grado II profundo	Grado II profundo
24	Grado II profundo	Grado II profundo
25	Grado II profundo	Grado II profundo
26	Grado II profundo	Grado II profundo
27	Grado II profundo	Grado II profundo
28	Grado II profundo	Grado II profundo
29	Grado II profundo	Grado II profundo
30	Grado II profundo	Grado II profundo
31	Grado II profundo	Grado II profundo
32	Grado II profundo	Grado II profundo
33	Grado II profundo	Grado II profundo
34	Grado II profundo	Grado II profundo
35	Grado II profundo	Grado II profundo
36	Grado II profundo	Grado II profundo
37	Grado II profundo	Grado II profundo
38	Grado II profundo	Grado II profundo
39	Grado II profundo	Grado II profundo
40	Grado II profundo	Grado II profundo
41	Grado II profundo	Grado II profundo
42	Grado II profundo	Grado II profundo
43	Grado II profundo	Grado II profundo
44	Grado II profundo	Grado II profundo
45	Grado II profundo	Grado II profundo
46	Grado II profundo	Grado II profundo
47	Grado II profundo	Grado II profundo
48	Grado II profundo	Grado II profundo
49	Grado II profundo	Grado II profundo
50	Grado II profundo	Grado II profundo
51	Grado II profundo	Grado III
52	Grado II profundo	Grado II profundo
53	Grado II profundo	Grado II profundo
54	Grado II profundo	Grado II profundo
55	Grado II profundo	Grado III
56	Grado II profundo	Grado II profundo
57	Grado II profundo	Grado II profundo
58	Grado II superficial	Grado II superficial

59	Grado II superficial	Grado II superficial
60	Grado II superficial	Grado II profundo
61	Grado II superficial	Grado III
62	Grado II superficial	Grado II profundo
63	Grado II superficial	Grado II profundo
64	Grado II superficial	Grado II profundo
65	Grado II superficial	Grado III
66	Grado II superficial	Grado II superficial

Los marcadores de rendimiento del modelo se muestran en la tabla 3. Matriz de confusión

Tabla 3. Matriz de confusión.

Salida	Segundo Superficial	VP = 3 0.45%	FP/FN = 0 0.00%	FP/FN = 0 0.00%	P 100% eP 0%
	Segundo Profundo	FP/FN = 4 0.06%	VP = 33 50.00%	FP/FN = 2 0.03%	P 84.61% eP 15.39%
	Tercero	FP/FN = 2 0.03%	FP/FN = 2 0.03%	VP = 20 30.30%	P 83.33% eP 16.67%
		S 33.33% eS 66.67%	S 94.28% eS 5.72%	S 90.90% eS 9.10%	E 84.85% eG 15.15%
	Segundo Superficial	Segundo Profundo	Tercero		
	Entrada				

Verdaderos positivos (VP): Predicciones correctas. Falsos positivos (FP): La categoría de salida no concuerda con la categoría de entrada. Falsos negativos (FN): La categoría de entrada se clasificó erróneamente.

Métricas:

- *Eficiencia (E): probabilidad del modelo de acertar una clasificación independientemente de la categoría.*
- *Error global (eG): probabilidad del modelo de errar una clasificación independientemente de la categoría.*
- *Precisión (P): probabilidad de que una predicción sea verdadera para una categoría determinada.*
- *Sensibilidad (S): probabilidad de clasificar correctamente una categoría.*
- *Error de precisión (eP): probabilidad de obtener una predicción falsa en una categoría determinada.*
- *Error de sensibilidad (eS): Probabilidad de clasificar incorrectamente una categoría.*
- *Valor F1: relación entre precisión y sensibilidad, expresa el rendimiento de la RNC.*

La eficiencia del modelo fue del 84.8%, al discriminar por categoría se encontró para segundo grado superficial, segundo grado profundo y tercer grado una sensibilidad de 33.3%, 94.3% y 90.9% y una precisión de 100%, 84.6% y 83.3%. Por último, el valor F1 resultante para segundo superficial, segundo profundo y tercero fue del 50%, 89.2% y 86.9% respectivamente.

DISCUSIÓN

El modelo de RNC diseñado en este estudio cuenta con una eficiencia del 84.85%, por encima del objetivo planteado inicialmente de 65 a 70%, con una probabilidad global de error del 15.1%. Al discriminar por categoría se encontró que para segundo grado superficial hay un 33.3% de probabilidad de acertar en la clasificación, pero una vez detectada la categoría se tiene el 100% de seguridad de que es una clasificación verdadera; para segundo grado profundo, la sensibilidad aumenta con 94.3% de probabilidad de acertar en la clasificación y la precisión disminuye con 84.6% de probabilidad de que la clasificación sea verdadera, el tercer grado cuenta con valores similares al segundo grado profundo, con 90.9% de sensibilidad y 83.3% de precisión. Los valores F1

descritos de 50% para segundo grado superficial, 89.2% para segundo grado profundo y 86.9% para tercer grado son la relación de la precisión y la sensibilidad e indican el grado de correlación de la información de entrada y la de salida.

Los datos obtenidos durante el desarrollo de este estudio muestran buenos resultados en el uso del modelo de RNC para clasificación de quemaduras, con una eficiencia del 84.8% comparable a la descrita en la literatura para un cirujano plástico (4, 6). Al discriminar por categorías se encuentra un buen resultado de sensibilidad y precisión para los grados segundo profundo y tercero, manifiesto en el valor de la relación F1; por otra parte, aunque la categoría de segundo grado superficial muestra una baja sensibilidad tiene una precisión elevada lo que indica que hay margen de mejora para el entrenamiento de esta categoría específica.

De acuerdo a la revisión de la literatura existe otro estudio acerca del uso de RNC para clasificación de la profundidad de quemaduras realizado por Acha en 2005, en el que describe un modelo diseñado en el software de licencia comercial Matlab® con una eficiencia del 82%. Cuenta con una base de datos de 250 fotografías con un riguroso protocolo de recolección incluyendo parámetros específicos de exposición y obturación para el dispositivo de captura, ángulo y distancia de toma definidos, adicionalmente, los investigadores pre procesan las imágenes con una serie de transformaciones del espacio de color y aplicación de filtros, estas consideraciones, si bien mejoran la eficiencia del modelo disminuyen su aplicabilidad.

El modelo diseñado en este estudio aborda estas limitaciones flexibilizando la toma de fotografías y disminuyendo el pre procesamiento a una única transformación RGB – LUV. Esto facilita su implementación disminuyendo el tiempo dedicado a la toma de fotografías y la probabilidad de errores por parte del operador, lo que mejora su aplicabilidad clínica. Otro punto a favor incluye que se usa una base de datos de entrenamiento más amplia, que se traduce en una

mayor eficiencia y el uso de software de código abierto que no requiere la adquisición de licencia por parte del usuario final.

La principal limitación encontrada en el trabajo es el tamaño de la base de datos. RNC con mayor eficiencia como el MNIST y COCO (16) cuentan con bases de datos más grandes, 15.000 y 60.000 imágenes respectivamente, que permiten un mayor reconocimiento de patrones. Esta limitación se ve especialmente representada en la categoría de segundo grado superficial la cual cuenta con un menor número de fotografías respecto a las otras y es a su vez la categoría de menor sensibilidad. Este hallazgo de un menor número de imágenes en una muestra por conveniencia concuerda con el perfil epidemiológico local (2) y debe mejorarse en desarrollos posteriores del prototipo mediante una nueva adquisición de datos para entrenamiento. Adicionalmente, debido al uso de la evaluación clínica de los expertos para categorizar las imágenes de entrenamiento la máxima eficiencia alcanzable por el modelo está sujeta a la experiencia de los evaluadores, por lo que un paso lógico a seguir es el entrenamiento del modelo con una base de datos categorizada de acuerdo al desenlace final de las quemaduras.

CONCLUSIONES

El prototipo diseñado en este estudio sienta bases promisorias para el desarrollo de una herramienta diagnóstica de utilidad clínica. Desarrollos posteriores deben incluir una mayor cantidad de datos categorizados de acuerdo al desenlace con el fin de mejorar la precisión y confiabilidad del modelo.

DECLARACIÓN DE CONFLICTOS DE INTERÉS

Los autores declaran que no tienen conflictos de interés asociados con el desarrollo de este estudio. El desarrollo del prototipo se realizó completamente en software libre.

FINANCIACIÓN

Este estudio fue financiado con recursos indirectos de la Universidad de Antioquia, el Hospital San Vicente Fundación de Medellín y recursos propios de los investigadores.

REFERENCIAS

1. Navarrete N, Rodriguez N. Epidemiologic characteristics of death by burn injury from 2000 to 2009 in Colombia, South America: a population-based study. *Burns Trauma*. 2016;4:8.
2. Hoyos MA, Jaramillo N, Molina ME, Valverde S. Epidemiological and clinical profile of burn victims, Hospital Universitario San Vicente de Paúl, Medellín, 1994-2004. *Burns Journal*. 2006;32.
3. Atiyeh B, Masellis A, Conte C. Optimizing burn treatment in developing low- and middle-income countries with limited health care resources (part 1). *Ann Burns Fire Disasters*. 2009;22(3):121-5.
4. Karim AS, Shaum K, Gibson ALF. Indeterminate-Depth Burn Injury- Exploring the Uncertainty. *J Surg Res*. 2020;245:183-97.
5. Jaspers M. A systematic review on the quality of measurement techniques for the assessment of burn wound depth or healing potential2018; 45(2):[261-81 pp.].
6. Jaskille AD, Shupp JW, Jordan MH, Jeng JC. Critical review of burn depth assessment techniques: Part I. Historical review. *J Burn Care Res*. 2009;30(6):937-47.
7. Vyas KS, Hambrick HR, Shakir A, Morrison SD, Tran DC, Pearson K, et al. A Systematic Review of the Use of Telemedicine in Plastic and Reconstructive Surgery and Dermatology. *Ann Plast Surg*. 2017;78(6):736-68.
8. Currie G, Hawk KE, Rohren E, Vial A, Klein R. Machine Learning and Deep Learning in Medical Imaging: Intelligent Imaging. *J Med Imaging Radiat Sci*. 2019;50(4):477-87.
9. Acha B, Serrano C, Acha JI, Roa LM. Segmentation and classification of burn images by color and texture information. *J Biomed Opt*. 2005;10(3):034014.
10. Herndon D. *Total Burn Care*. 5 edition ed. London: Elsevier; 2018. 896 p.
11. Noor I, Mokhtar H, Rafiqul Z. Understanding Color Models: A Review. *ARPN Journal of Science and Technology*; 2012.
12. Martín A, Ashish A. TensorFlow: Large-scale machine learning on heterogeneous systems 2015 [Available from: <https://www.tensorflow.org>].

13. G VR, FL D. Python 3 Reference Manual. Scotts Valley, CA: CreateSpace; 2009.
14. Zebin T, Scully P, Peek N. Design and implementation of a convolutional neural net network on an edge computing smartphone for human activity recognition. IEEEAccess; 2019.
15. Kiser M, Beijer G, Mjuweni S, Muyco A, Cairns B, Charles A. Photographic assessment of burn wounds: a simple strategy in a resource-poor setting. Burns. 2013;39(1):155-61.
16. LeCun Y, Cortes C. Mnist Database of Handwritten Digits 2015 [Available from: <http://yann.lecun.com/exdb/mnist/>].