

HERRAMIENTA COMPUTACIONAL PARA LA ASISTENCIA AL TRATAMIENTO DE
HERIDAS CRÓNICAS EN PACIENTES DE HANSEN DEL DEPARTAMENTO DE
SANTANDER.

JUAN SEBASTIAN ESTUPIÑAN COBOS

UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FISICOMECÁNICAS
ESCUELA DE INGENIERÍA DE SISTEMAS
BUCARAMANGA
2023

HERRAMIENTA COMPUTACIONAL PARA LA ASISTENCIA AL TRATAMIENTO DE
HERIDAS CRÓNICAS EN PACIENTES DE HANSEN DEL DEPARTAMENTO DE
SANTANDER.

JUAN SEBASTIAN ESTUPIÑAN COBOS

Trabajo de Grado para optar al título de
Ingeniero de Sistemas

Directora:

Karen Yaneth Sánchez Quiroga

Magíster en INGENIERÍA ELECTRÓNICA

Codirector:

Henry Arguello Fuentes

Ph.D. en INGENIERÍA ELÉCTRICA Y COMPUTACIÓN

UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FISICOMECAÑICAS
ESCUELA DE INGENIERÍA DE SISTEMAS
BUCARAMANGA

2023

DEDICATORIA

Para mis padres y mi familia, son el motor de mi vida.

AGRADECIMIENTOS

A mis padres, Martha Cobos y Freddy Estupiñan, por todo el apoyo y amor que me dan día a día, sin ellos esto no sería posible.

A mi pareja Camila, por estar siempre apoyándome y escuchándome en los momentos más complicados.

A mis compañeros que vivieron todo este proceso conmigo desde el inicio, Sebastian, Geison y Anderson.

A las personas que destinaron una parte de su tiempo para ayudarme cuando lo necesitaba, Brayan y Fabian.

A mi directora de tesis, Karen Sánchez, por haberme brindado una guía durante todo el proceso.

Al grupo de investigación HDSP por brindarme los recursos para desarrollar este proyecto.

A todas las personas que me preguntaron “¿Y la tesis?”.

A todos los obstáculos que se presentaron, porque me obligaron a superarlos, aprendí muchas cosas y me han hecho cambiar para bien.

CONTENIDO

	pág.
INTRODUCCIÓN	11
1 CONTRIBUCIONES DEL AUTOR	15
2 OBJETIVOS	17
3 MARCO TEÓRICO	18
3.1 HERIDAS CRÓNICAS	18
3.2 ENFERMEDAD DE HANSEN EN SANTANDER	19
3.3 TRATAMIENTO DE HERIDAS CRÓNICAS	22
3.4 ALGORITMOS DE APRENDIZAJE PROFUNDO	23
3.4.1 REDES NEURONALES CONVOLUCIONALES	25
3.5 DETECCIÓN Y SEGMENTACIÓN BINARIA DE IMÁGENES	27
4 METODOLOGÍA PROPUESTA	29
4.1 CONSTRUCCIÓN DE CONJUNTO DE DATOS DE HERIDAS CRÓNICAS	30
4.2 ANÁLISIS DE CARACTERÍSTICAS SOCIO-DEMOGRÁFICAS DE LA POBLACIÓN OBJETIVO	32
4.3 DISEÑO DE ALGORITMO DE APRENDIZAJE PROFUNDO	33
4.4 EVALUACIÓN DEL ALGORITMO DE SEGMENTACIÓN Y SEGUIMIENTO DE HERIDAS	35
4.4.1 DEFINICIÓN DE MÉTRICAS DE EVALUACIÓN	35
4.5 COMPARACIÓN CON EL ESTADO DEL ARTE	38
5 RESULTADOS	39

5.1	CONJUNTO DE DATOS DE IMÁGENES DE HERIDAS	39
5.2	CARACTERÍSTICAS SOCIO-DEMOGRÁFICAS	45
5.3	ALGORITMO DE SEGMENTACIÓN Y SEGUIMIENTO DE HERIDAS	49
5.4	EVALUACIÓN DEL ALGORITMO DISEÑADO	53
5.4.1	ALGORITMO DE ELIMINACIÓN DE FONDO (E)	53
5.4.2	ALGORITMO DE DETECCIÓN (D)	56
5.4.3	ALGORITMO DE SEGMENTACIÓN (S)	56
5.4.4	EVALUACIÓN	57
5.5	COMPARACIÓN CON EL ESTADO DEL ARTE	61
6	CONCLUSIONES	65
7	TRABAJO FUTURO	66
	BIBLIOGRAFÍA	67

LISTA DE FIGURAS

		pág.
Figura 1	Fotografías de heridas crónicas.	18
Figura 2	Gerhard Armauer Hansen.	20
Figura 3	Sanatorio de Contratación E.S.E., en Santander.	21
Figura 4	Neurona real del cerebro humano y neurona artificial.	24
Figura 5	Arquitectura de red neuronal de clasificación binaria.	25
Figura 6	Arquitectura de red convolucional de clasificación.	26
Figura 7	Ejemplo de detección de objetos.	28
Figura 8	Segmentación binaria de herida.	28
Figura 9	Patrón de calibración.	40
Figura 10	Interfaz de Label-Studio.	42
Figura 11	Muestra del conjunto de datos construido.	44
Figura 12	Localización de Contratación en Santander.	47
Figura 13	Esquema de aprendizaje profundo propuesto.	52
Figura 14	Ejemplos de eliminación de fondo.	55
Figura 15	Parámetros de eliminación de fondo.	55
Figura 16	Resultados visuales del algoritmo propuesto.	60
Figura 17	Arquitectura VGG16.	62
Figura 18	Arquitectura SegNet.	62

LISTA DE CUADROS

		pág.
Cuadro 1	Consumo del algoritmo en entrenamiento.	58
Cuadro 2	Resultados del algoritmo propuesto.	58
Cuadro 3	Comparación cuantitativa con el estado del arte.	64

RESUMEN

TÍTULO: HERRAMIENTA COMPUTACIONAL PARA LA ASISTENCIA AL TRATAMIENTO DE HERIDAS CRÓNICAS EN PACIENTES DE HANSEN DEL DEPARTAMENTO DE SANTANDER.*

AUTOR: JUAN SEBASTIAN ESTUPIÑAN COBOS.**

PALABRAS CLAVE: Hansen, Heridas crónicas, Aprendizaje profundo, Segmentación.

DESCRIPCIÓN: Las heridas crónicas son un problema global, son padecidas por alrededor de 40 millones de personas en el mundo y son ocasionadas por enfermedades cardiovasculares, diabetes tipo-2 o infecciones agudas como la enfermedad de Hansen. La recuperación irregular de estas heridas hace necesario un tratamiento periódico, especialmente en los pacientes de Hansen, debido a la carga de la enfermedad, llegando a ocasionar deficiencias físicas irreversibles. A pesar de las complicaciones que generan estas heridas, en los países en desarrollo la asistencia no es oportuna debido al estado deficiente de las infraestructuras viales y sanitarias. Con el objetivo de asistir el tratamiento, varias herramientas computacionales basadas en el procesamiento de imágenes y el aprendizaje profundo han surgido recientemente. Sin embargo, estas propuestas se ven limitadas por factores de las imágenes de las heridas como la iluminación, tamaños, severidad, sombras o colores. Adicionalmente, los enfoques basados en datos solo cuentan con disponibilidad de datos de pacientes de diabetes de países desarrollados, dejando de lado los pacientes de Hansen y los países en desarrollo. Por lo tanto, este trabajo propone una herramienta computacional basada en aprendizaje profundo para el monitoreo de heridas crónicas de pacientes de la enfermedad de Hansen del municipio de Contratación, Santander, municipio en donde se encuentra el Sanatorio de Contratación E.S.E., el cual atiende más de 100 pacientes de Hansen. El enfoque permite un análisis de las heridas para evaluar su tamaño y forma al ejecutar la tarea de segmentación binaria. Por otro lado, un conjunto de datos anonimizado adquirido de pacientes de Hansen es presentado. El método propuesto presenta una mejora respecto a los trabajos del estado del arte, obteniendo un puntaje de 82.1 % en la métrica de valor-f1.

* Trabajo de grado.

** Facultad de Ingenierías Fisicomecánicas. Escuela de Ingeniería de Sistemas. Directora: Karen Yaneth Sánchez Quiroga. Codirector: Henry Arguello Fuentes.

ABSTRACT

TITLE: COMPUTATIONAL TOOL TO ASSIST IN THE TREATMENT OF CHRONIC WOUNDS IN HANSEN'S DISEASE PATIENTS IN THE DEPARTMENT OF SANTANDER.*

AUTHOR: JUAN SEBASTIAN ESTUPIÑAN COBOS.**

KEYWORDS: Hansen, Chronic wounds, Deep learning, Segmentation.

DESCRIPTION: Chronic wounds are a global problem, affecting approximately 40 million people worldwide and caused by cardiovascular diseases, type-2 diabetes, or acute infections such as Hansen's disease. The irregular healing of these wounds makes necessary periodic treatment, especially in Hansen's disease patients, due to the burden of the illness, which can lead to irreversible physical impairments. Despite the complications associated with these wounds, timely assistance is lacking in developing countries due to inadequate road and healthcare infrastructures. In order to aid treatment, several computational tools based on image processing and deep learning have recently emerged. However, these proposals are limited by factors in wound images such as lighting, sizes, severity, shadows, or colors. Additionally, data-driven approaches only have access to data from diabetes patients in developed countries, neglecting Hansen's disease patients and developing countries. Therefore, this work proposes a deep learning-based computational tool for monitoring chronic wounds in patients with Hansen's disease in the municipality of Contratación, Santander, where the institution "Sanatorio de Contratación E.S.E." is located, nursing to over 100 Hansen's disease patients. The approach allows for wound analysis to assess their size and shape by performing binary segmentation. Furthermore, an anonymized dataset acquired from Hansen's disease patients is presented. The proposed method exhibits an improvement compared to state-of-the-art works, achieving a score of 82.1 % in f1-score metric.

* Bachelor Thesis.

** Facultad de Ingenierías Fisicomecánicas. Escuela de Ingeniería de Sistemas. Advisor: Karen Yaneth Sánchez Quiroga. Co-advisor: Henry Arguello Fuentes.

INTRODUCCIÓN

Las úlceras o heridas crónicas son un problema global, que está presente en alrededor de 40 millones de pacientes en el mundo ¹. Son generadas principalmente por enfermedades cardiovasculares, diabetes tipo-2 o infecciones agudas como la enfermedad de Hansen (conocida comúnmente como lepra) ^{2, 3}. Las heridas crónicas se caracterizan por presentar una recuperación irregular y ser un factor de riesgo de morbilidad ⁴.

El tratamiento de las heridas crónicas se realiza generalmente por personal del área de la salud, quien analiza visualmente la anomalía cutánea para determinar el diagnóstico y tratamiento adecuado ². Estos tratamientos deben realizarse periódicamente para lograr una evolución positiva de las heridas, lo que hace necesario el desplazamiento periódico del paciente al centro médico. No obstante, múltiples factores implican que el cuidado de estas heridas se realice de forma inapropiada o que no siempre sea posible el desplazamiento de los pacientes desde su lugar de residencia hasta el centro médico, especialmente en países en vías de desarrollo ⁵, donde las infraestructuras viales no presentan condiciones óptimas que faciliten el

-
- ¹ Kevin Las Heras et al. "Chronic wounds: Current status, available strategies and emerging therapeutic solutions". En: *Journal of Controlled Release* 328 (2020), págs. 532-550.
 - ² Steven Bowers y Eginia Franco. "Chronic wounds: evaluation and management". En: *American family physician* 101.3 (2020), págs. 159-166.
 - ³ VS Chauhan, SS Pandey y VK Shukla. "Management of plantar ulcers in Hansen's disease". En: *The international journal of lower extremity wounds* 2.3 (2003), págs. 164-167.
 - ⁴ Maja Olsson et al. "The humanistic and economic burden of chronic wounds: A systematic review". En: *Wound Repair and Regeneration* 27.1 (2019), págs. 114-125.
 - ⁵ Shivani Gupta et al. "Chronic wounds: Magnitude, socioeconomic burden and consequences". En: *Wounds Asia* 4 (2021), págs. 8-14.

transporte de los ciudadanos. Este caso se intensifica, particularmente, en territorios rurales, como es el caso del municipio de Contratación, en el departamento de Santander, Colombia. Los obstáculos terrestres que dificultan la asistencia de los pacientes pueden llevar a infecciones graves que incluso desencadenan la amputación posterior de las extremidades afectadas ⁶.

A lo largo del tiempo, diversas herramientas de asistencia computacional han surgido con el objetivo de apoyar la evaluación de estas heridas y obtener una mejora progresiva de las mismas. Inicialmente, se desarrollaron métodos tradicionales de procesamiento de imágenes digitales ^{7, 8}. Sin embargo, recientemente, estos algoritmos se han dejado de lado o se han fusionado con la inteligencia artificial y el aprendizaje profundo ^{9, 10, 11}, obteniendo herramientas automáticas que ofrecen una asistencia al personal médico en el tratamiento de las heridas crónicas a través de imágenes de las mismas. Estos algoritmos buscan la extracción de las características principales de las heridas, con el objetivo de evaluarlas en términos de tamaño, estado u otros aspectos. Sin embargo, se presentan múltiples limitaciones que llegan a afectar el rendimiento de estos métodos computacionales, como los

⁶ Leila Yazdanpanah, Morteza Nasiri y Sara Adarvishi. "Literature review on the management of diabetic foot ulcer". En: *World journal of diabetes* 6.1 (2015), pág. 37.

⁷ Jui-Tse Hsu et al. "Chronic wound assessment and infection detection method". En: *BMC medical informatics and decision making* 19.1 (2019), págs. 1-20.

⁸ Mohammad Faizal Ahmad Fauzi et al. "Computerized segmentation and measurement of chronic wound images". En: *Computers in biology and medicine* 60 (2015), págs. 74-85.

⁹ Brayan Monroy et al. "Two-step Deep Learning Framework for Chronic Wounds Detection and Segmentation: A Case Study in Colombia". En: *2021 XXIII Symposium on Image, Signal Processing and Artificial Vision (STSIVA)*. IEEE, 2021, págs. 1-6.

¹⁰ Rania Niri et al. "Multi-View Data Augmentation to Improve Wound Segmentation on 3D Surface Model by Deep Learning". En: *IEEE Access* 9 (2021), págs. 157628-157638.

¹¹ Dhanesh Ramachandram et al. "Fully Automated Wound Tissue Segmentation Using Deep Learning on Mobile Devices: Cohort Study". En: *JMIR mHealth and uHealth* 10.4 (2022), e36977.

diferentes niveles de iluminación, sombras, colores y resolución de las fotografías dadas por el equipo de adquisición ¹².

Con la inclusión del aprendizaje profundo en el tratamiento de las heridas crónicas, surge la necesidad de obtener y procesar una gran cantidad de datos sobre las mismas. Debido a esto, se han construido conjuntos de datos de heridas crónicas alrededor del mundo, principalmente en países desarrollados ¹³, dando a conocer un problema en esta área, la particularidad demográfica de los datos. Además, los datos son enfocados principalmente en pacientes de diabetes, dejando de lado otras enfermedades que influyen en la generación de heridas, como la enfermedad de Hansen. Estos factores han llevado a que las herramientas desarrolladas no presenten un buen rendimiento a la hora de adaptarse a entornos de países en desarrollo o heridas afectadas por otras enfermedades, resaltando así las diferencias en las condiciones de las heridas, como el color de piel, el tamaño y el grado de severidad ⁹. Por lo cual se deben recopilar y exponer las condiciones de las heridas dadas en países en desarrollo y ocasionadas por otras enfermedades.

El objetivo de este trabajo de investigación es diseñar e implementar una herramienta computacional de procesamiento de datos y aprendizaje profundo, que permita la evaluación de fotografías RGB de heridas crónicas o úlceras en pacientes de Hansen en el departamento de Santander adquiridas con cámaras de celulares convencionales. Por lo tanto, este proyecto implica también la creación de un conjunto de datos anonimizado de heridas crónicas pertenecientes a pacientes de la enfermedad de Hansen ubicados en el municipio de Contratación, Santander, una población

¹² Manu Goyal et al. "Fully convolutional networks for diabetic foot ulcer segmentation". En: *2017 IEEE international conference on systems, man, and cybernetics (SMC)*. IEEE. 2017, págs. 618-623.

¹³ Michał Kręćichwost et al. "Chronic wounds multimodal image database". En: *Computerized Medical Imaging and Graphics* 88 (2021), pág. 101844.

reconocida a nivel departamental y nacional en el sector de la salud por el alto número de casos de pacientes con úlceras en tratamiento, que cuenta con el Sanatorio de Contratación E.S.E., el cual es uno de los dos hospitales expertos en el tratamiento de la enfermedad de Hansen en Colombia y presentó su apoyo para este trabajo. El conjunto de datos de heridas incluirá fotografías RGB, sus coordenadas de detección de heridas, y sus máscaras binarias de segmentación correspondientes. Finalmente, el método desarrollado será comparado con otros enfoques del estado del arte.

1. CONTRIBUCIONES DEL AUTOR

Publicaciones no indexadas en actividades de divulgación, modalidad póster.

1. "Automatic segmentation and measurement of chronic wounds based on convolutional neural networks". Monroy B., Arguello P., **Estupiñán, J.**, Sanchez K., Bacca, J., Correa C.V., Arguello H. and Rojas-Morales F. *International Workshop on Adaptive, Compressive and Computational Imaging WACCI*, 2022.
2. "Automatic segmentation and measurement of chronic wounds based on convolutional neural networks". Autores: Monroy B., Arguello P., **Estupiñán, J.**, Sanchez K., Bacca, J., Correa C.V., Arguello H. y Rojas-Morales F. *Jornada de Divulgación del Grupo de investigación en Diseño de Algoritmos y Procesamiento de Datos Multidimensionales (HDSP)*, Universidad Industrial de Santander (UIS), Escuela de Ingeniería de Sistemas e Informática. 2022.

Publicaciones indexadas en conferencias.

1. "Plataforma de evaluación remota, objetiva y automatizada de la evolución de lesiones crónicas en extremidades por Enfermedad de Hansen". L. Valencia, O. Mielles, J.C. Castillo, B. Monroy, K. Sanchez, P. Arguello, **J. Estupiñán, J.** Bacca, C. Correa-Pugliese, H. Arguello, S. Castillo, y F. Rojas-Morales. *48 Congreso Semana Quirúrgica Nacional*. 2022.

Publicaciones indexadas en conferencias, en otros tópicos durante el estudio de pregrado.

1. "Deep unrolled phase retrieval approach from coded diffraction patterns". **Estupiñán, J.**, Jerez, A., Bacca, J., & Arguello, H. (2021, Septiembre). *2021 XXIII Symposium on Image, Signal Processing and Artificial Vision (STSIVA)* (pp. 1-4). IEEE.

Artículo A1 en revisión.

1. “Automated chronic wounds medical assessment and tracking framework based on deep learning”. Monroy B., Sanchez K., Arguello P., **Estupiñán J.**, Bacca J., Correa C.V., Valencia L., Castillo J.C., Mieles O., Arguello H., Castillo S., and Rojas-Morales F. *Computers in Biology and Medicine Journal*. ISSN 1879-0534. Paper sometido el 20 de Diciembre de 2022. Categoría A1 de Min-ciencias.

2. OBJETIVOS

Objetivo general

- Desarrollar una herramienta computacional basada en procesamiento de imágenes y aprendizaje profundo para la asistencia al tratamiento de heridas crónicas en pacientes de Hansen del departamento de Santander.

Objetivos específicos

1. Construir un conjunto de imágenes RGB de úlceras crónicas en extremidades inferiores adquiridas en pacientes del departamento de Santander con sus coordenadas de detección y máscaras de segmentación correspondientes.
2. Identificar las características socio-demográficas de los pacientes de úlceras crónicas por Hansen en el departamento de Santander y las necesidades de asistencia sanitaria que debe abordar el algoritmo a desarrollar.
3. Diseñar e implementar un algoritmo de inteligencia artificial para la segmentación y seguimiento de heridas crónicas en imágenes RGB.
4. Evaluar el algoritmo diseñado en términos de precisión, tiempo y costo computacional, a través de simulaciones ejecutadas con el conjunto de datos construido en el objetivo 1.
5. Comparar la herramienta computacional diseñada en este trabajo con otros métodos del estado del arte.

3. MARCO TEÓRICO

3.1. HERIDAS CRÓNICAS

Las heridas o úlceras crónicas son lesiones en la piel que presentan una recuperación lenta a lo largo del tiempo y tienen un aspecto como el mostrado en la Figura 1. Están presentes globalmente en alrededor de 40 millones de pacientes ¹, estas heridas pueden ser causadas por enfermedades cardiovasculares, diabetes tipo-2 o infecciones agudas como la enfermedad de Hansen (o lepra) ⁹ y son consideradas “crónicas” si su duración supera los 3 meses ¹⁴. El impacto humano y económico de las heridas crónicas es de un factor alto, afectando la calidad de vida de quienes las portan y haciendo necesario tratamientos especializados ⁴.

Figura 1. Fotografías de heridas crónicas en pacientes de Hansen residentes del municipio de Contratación que hacen parte del conjunto de datos resultante del presente trabajo.



Existen diversas categorías de heridas crónicas, sin embargo, se resaltan 3 categorías principales, las heridas por presión, vasculares y diabéticas ¹⁵. Las primeras

¹⁴ Alexander Stojadinovic et al. “Topical advances in wound care”. En: *Gynecologic oncology* 111.2 (2008), S70-S80.

¹⁵ Sabine A Eming, Paul Martin y Marjana Tomic-Canic. “Wound repair and regeneration:

se generan por una presión en la piel dada por un tiempo prolongado ¹⁶, la cual puede llevar a evitar una correcta circulación de la sangre por los tejidos subyacentes, haciendo que estos se expongan a infecciones, quiebres y se generen heridas crónicas. Por otro lado, un funcionamiento anormal del sistema vascular puede llevar a generar daños en las venas, ocasionando coágulos de sangre y lesiones que lleguen a un estado severo de herida crónica ¹⁷. Finalmente, la diabetes puede ser una causa de estas heridas, dado que puede dañar los nervios y los vasos sanguíneos llevando a la generación de heridas crónicas ¹⁸. Las úlceras diabéticas en extremidades inferiores son la causa más común de amputaciones ².

3.2. ENFERMEDAD DE HANSEN EN SANTANDER


El *Mycobacterium leprae* es un bacilo acidorresistente, conocido como el agente causal de la lepra o enfermedad de Hansen ¹⁹. Fue descubierto en 1873 por Gerhard Armauer Hansen ²⁰, cuyo retrato se observa en la Figura 2. Se conoce como una de las enfermedades más antiguas del mundo, siendo registrada en la literatura de

mechanisms, signaling, and translation". En: *Science translational medicine* 6.265 (2014), 265sr6-265sr6.

- ¹⁶ Gary M. Yarkony. "Pressure ulcers: A review". En: *Archives of Physical Medicine and Rehabilitation* 75.8 (1994), págs. 908-917. DOI: [https://doi.org/10.1016/0003-9993\(94\)90117-1](https://doi.org/10.1016/0003-9993(94)90117-1).
- ¹⁷ Chukwuemeka N. Etufugh y Tania J. Phillips. "Venous ulcers". En: *Clinics in Dermatology* 25.1 (2007), págs. 121-130. DOI: <https://doi.org/10.1016/j.clindermato1.2006.09.004>.
- ¹⁸ David L Steed et al. "Guidelines for the treatment of diabetic ulcers". En: (2006).
- ¹⁹ Matthew McEwen y Tejesh Patel. "Hansen Disease (Leprosy)". En: *Mayo Clinic Proceedings* 95 (nov. de 2020), págs. 2555-2556. DOI: [10.1016/j.mayocp.2020.09.001](https://doi.org/10.1016/j.mayocp.2020.09.001).
- ²⁰ Andrzej Grzybowski et al. "Gerhard Henrik Armauer Hansen (1841-1912)—The 100th anniversary of the death of the discoverer of *Mycobacterium leprae*". En: *Clinics in Dermatology* 31.5 (2013). Nails and the Clinician, págs. 653-655. DOI: <https://doi.org/10.1016/j.clindermato1.2012.10.001>.

civilizaciones de épocas anteriores.

Figura 2. Gerhard Armauer Hansen, descubridor del bacilo *Mycobacterium leprae*. Tomado de²¹.



La enfermedad de Hansen afecta la piel, los nervios periféricos, la mucosa de las vías respiratorias altas y los ojos ²². Tiene un periodo de incubación largo, aproximadamente de 5 años. Se creía que era una enfermedad altamente infecciosa, sin embargo, su contagio requiere de un contacto frecuente, prolongado y cercano con pacientes que no han sido tratados. Además, esta enfermedad se puede curar y su tratamiento puede durar de 6 meses a dos años con una administración frecuente de medicamentos. Anteriormente, se tenía un estigma sobre las personas portadoras de la enfermedad de Hansen, llegando a describir la misma como un “castigo divino”. Debido a esto, se crearon los leprosarios o lazaretos, lugares destinados a aislar a estas personas de la sociedad permanentemente y aplicarles un tratamiento ^{22,23}.

En la antigüedad, la enfermedad de Hansen era tratada con la dapsona, sin embar-

²² Thomas M. Shinnick. “Chapter 11 Hansen disease”. En: *Microbiology*. Ed. por E. Edward Bittar y Neville Bittar. Vol. 9. Principles of Medical Biology. Elsevier, 1998, págs. 167-174. DOI: [https://doi.org/10.1016/S1569-2582\(97\)80148-1](https://doi.org/10.1016/S1569-2582(97)80148-1).

²³ Jesús E Ochoa. “El lazareto de Boyacá: lepra, medicina, iglesia y Estado 1869-1916. Cómo Colombia fue convertida en la primera potencia leprosa del mundo y Boyacá!, en una inmensa leprosería: Abel Fernando Martínez M”. es. En: *Revista Facultad Nacional de Salud Pública* 26 (ene. de 2008), págs. 100 -100.

Figura 3. Sanatorio de Contratación E.S.E., lugar donde se tratan a pacientes de Hansen, ubicado en el municipio de Contratación, Santander. Tomado de²⁴.



go, con el paso del tiempo se empezaron a registrar casos de resistencia a esta medicina, fue entonces alrededor de la década de los 80, en donde el tratamiento pasó a ser de multi medicamento, compuesto por la dapsona, rifampicina y clofazimina²⁵. Los tratamientos para la enfermedad de Hansen han mejorado históricamente, haciendo que actualmente se haya llegado a la meta de eliminación de la misma como un problema de salud pública (menos de 1 caso cada 10.000 personas)²⁶, sin embargo, esta enfermedad sigue presente en el mundo, registrando 127.558 casos globales en 2020. El impacto de la enfermedad de Hansen en la piel hace que esta sea vulnerable a traumas, quiebres y desarrollo de heridas²⁷ que pueden presentar una alta dificultad de recuperación, llevándolas a un estado crónico. Es-

²⁵ K Eichelmann et al. "Leprosy. An update: definition, pathogenesis, classification, diagnosis, and treatment". En: *Actas Dermo-Sifiligráficas (English Edition)* 104.7 (2013), págs. 554-563.

²⁶ World Health Organization et al. "Global leprosy update, 2013; reducing disease burden". En: *Weekly Epidemiological Record= Relevé épidémiologique hebdomadaire* 89.36 (2014), págs. 389-400.

²⁷ Heloísa Cristina Quatrini Carvalho Passos Guimarães et al. "Evidencias científicas sobre las úlceras de piernas como secuela de la lepra". En: 2019.

tas heridas afectan los aspectos físicos y psicológicos de los pacientes, y también representan un factor de morbilidad e incluso de mortalidad. En Colombia existen actualmente dos lugares -que en el siglo pasado fueron lazaretos- especializados en el tratamiento de pacientes de Hansen, el municipio de Contratación ubicado en el departamento de Santander, mostrado en la Figura 3, y el municipio de Agua de Dios en Cundinamarca.

3.3. TRATAMIENTO DE HERIDAS CRÓNICAS

El tratamiento de las heridas crónicas se realiza bajo el esquema TIME, el cual se basa en 4 pasos, debridación de tejido, control de infección, equilibrio hídrico y tratamiento del borde de la herida ²⁸. El primer paso consta de la eliminación de tejidos necróticos o esfacelados y restos de vendajes o elementos que contaminan la herida. El control de infección es la aplicación del debido antibiótico a la herida con el fin de eliminar el área infectada y disminuir la inflamación asociada a esta. El equilibrio hídrico se basa en dar a la herida la humedad necesaria, dado que es recomendado no dejar que la herida se seque. Se ha comprobado que las heridas húmedas tienen una mejor recuperación y son menos vulnerables a las infecciones ²⁹. Como último paso, el tratamiento de los bordes de la herida busca eliminar los bordes socavados y enrollados ². Estos tratamientos deben darse de forma periódica para lograr la evolución continua de las heridas.

²⁸ David J Leaper et al. "Extending the TIME concept: what have we learned in the past 10 years?*" En: *International Wound Journal* 9.s2 (2012), págs. 1-19. DOI: <https://doi.org/10.1111/j.1742-481X.2012.01097.x>. eprint: <https://onlinelibrary.wiley.com/doi/pdf/10.1111/j.1742-481X.2012.01097.x>.

²⁹ Charles K. Field y Morris D. Kerstein. "Overview of wound healing in a moist environment". En: *The American Journal of Surgery* 167.1, Supplement (1994). A Symposium: Wound Infection and Occlusion-Separating Fact from Fiction, S2-S6. DOI: [https://doi.org/10.1016/0002-9610\(94\)90002-7](https://doi.org/10.1016/0002-9610(94)90002-7).

3.4. ALGORITMOS DE APRENDIZAJE PROFUNDO


En el área de la informática y la computación, ha emergido en las últimas décadas la creación de modelos de aprendizaje capaces de tomar decisiones y resolver tareas específicas. El aprendizaje profundo permite a modelos neuronales adaptarse y obtener una representación abstracta de un conjunto de datos ³⁰, estas representaciones son usadas para cumplir distintos tipos de tareas, como clasificación, detección, reconstrucción, etc. Los modelos usados en esta área cuentan con una unidad principal, llamada neurona, la cual nace inspirada de las neuronas reales, en las que el funcionamiento se basa en recibir información de entrada a través de las dendritas, la cual es procesada por el núcleo y finalmente entregada como salida final por medio del axón, estas estructuras son replicadas artificialmente, en donde las dendritas vendrían a darse como variables de entrada x_1, x_2, \dots, x_n , las cuales van hacia una función lineal y una función de activación que representan el núcleo para finalmente ser entregadas como una salida procesada, una ilustración de esta analogía se observa en la Figura 4. Estas unidades se conectan entre sí y funcionan como unidades de procesamiento que contienen ciertos parámetros que se pueden optimizar ³¹, los cuales son usados para adaptarse y aprender a realizar la tarea deseada.

En los trabajos, generalmente se enfoca en el área del aprendizaje profundo conocida como “aprendizaje supervisado” ³⁰, en esta, un modelo recibe un conjunto de datos de entrenamiento, los cuales contienen la entrada y la salida deseada de la red. Estos datos son dados al modelo para “entrenarlo”, es decir, buscar que se

³⁰ Yann LeCun, Yoshua Bengio y Geoffrey Hinton. “Deep learning”. En: *nature* 521.7553 (2015), págs. 436-444.

³¹ VA Golovko. “Deep learning: an overview and main paradigms”. En: *Optical memory and neural networks* 26.1 (2017), págs. 1-17.

Figura 4. Neurona real del cerebro humano (izquierda) y neurona artificial propuesta como unidad de procesamiento en los modelos de aprendizaje profundo (derecha). Tomado y traducido de³².



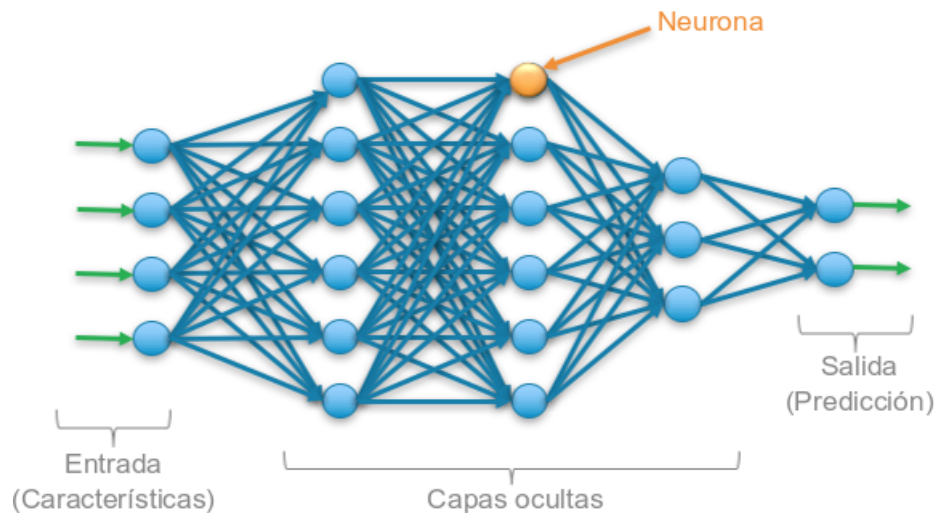
adapte al conjunto de información utilizada³³. Una vez adaptado, el modelo es evaluado, en donde se utilizan únicamente datos de entrada diferentes a los usados en el entrenamiento, para que la red devuelva la salida según sus parámetros optimizados. La principal característica con la que cuentan los modelos de aprendizaje profundo para entrenarse, es el algoritmo de retropropagación³⁴. Para entender este algoritmo, se debe tener en cuenta que el entrenamiento y optimización de las redes se realiza por medio de una función de error, la cual será seleccionada específicamente para la tarea a realizar, esta función se calcula respecto a la entrada y la salida real en la fase de entrenamiento, con el objetivo de que los modelos se adapten a la información que se les provee. La disminución de este error es responsabilidad de la retropropagación, la cual permite que cada unidad de un modelo

³³ Amitha Mathew, P Amudha y S Sivakumari. "Deep learning techniques: an overview". En: *International conference on advanced machine learning technologies and applications*. Springer. 2020, págs. 599-608.

³⁴ Timothy P Lillicrap et al. "Backpropagation and the brain". En: *Nature Reviews Neuroscience* 21.6 (2020), págs. 335-346.

actualice sus parámetros, de modo que construya la representación abstracta que permita realizar la tarea que se busca.

Figura 5. Arquitectura de red neuronal de clasificación binaria. Tomado y traducido de³⁵.

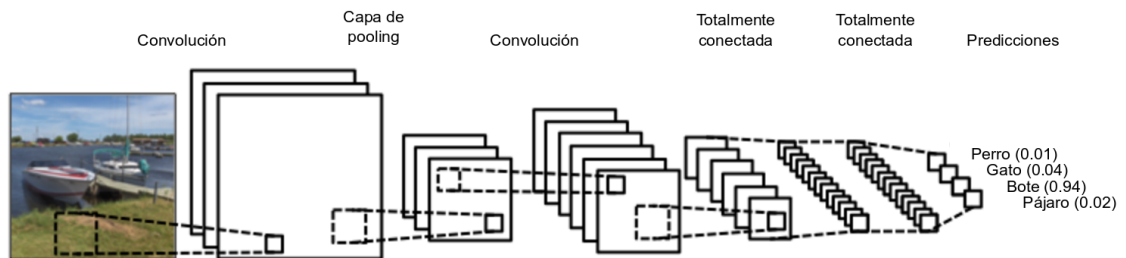


La Figura 5 ilustra la estructura de una red neuronal de 4 capas, sin contar la capa de entrada. Cada entrada pasa por una neurona, la cual está conectada a otras sucesivamente, estas realizan un procesamiento de la entrada y la transforman en una salida según sus parámetros optimizados. Este proceso se realiza sucesivamente por capas hasta llegar a la capa final, la cual se considera la salida de la red.

3.4.1. REDES NEURONALES CONVOLUCIONALES Con el origen del aprendizaje profundo y las redes neuronales, surge una nueva arquitectura enfocada al tratamiento de imágenes y la visión por computadora, esta recibe el nombre de red convolucional. La principal característica de estas arquitecturas es que tratan una imagen teniendo en cuenta su estructura espacial y se usan principalmente

en tareas que involucran reconocimiento de patrones complejos en imágenes ³⁶. El parámetro principal de estas redes es llamado “kernel”, el cual es una ventana de neuronas que tratan un conjunto de píxeles simultáneamente, logrando procesar la información espacialmente y buscar información como bordes, curvas u otros detalles de mayor complejidad ³⁷. Estos parámetros son optimizados y actualizados según la tarea que se desee llevar a cabo. La Figura 6 muestra un ejemplo de una red convolucional que lleva a cabo la tarea de clasificación, esta recibe una imagen, la cual se procesa espacialmente por distintas capas. Después del proceso de análisis por las capas convolucionales, la información procesada pasan a otro conjunto de neuronas, las cuales, usando los datos y características extraídas por las capas anteriores, realizan la clasificación y obtienen la salida final de la red, en este caso, identificando que hay un barco en la imagen.

Figura 6. Arquitectura de red convolucional de clasificación. Tomado y traducido de³⁸.



En el área de tratamiento de heridas crónicas, este tipo de redes son continuamente

³⁶ Keiron O’Shea y Ryan Nash. “An introduction to convolutional neural networks”. En: *arXiv preprint arXiv:1511.08458* (2015).

³⁷ Jiuxiang Gu et al. “Recent advances in convolutional neural networks”. En: *Pattern recognition 77* (2018), págs. 354-377.

te utilizadas, principalmente en las tareas de detección y segmentación, en donde múltiples enfoques se han desarrollado usando estas arquitecturas llevándolas a ser estado del arte ³⁹.

3.5. DETECCIÓN Y SEGMENTACIÓN BINARIA DE IMÁGENES

La detección y la segmentación son dos tareas que se realizan generalmente en el tratamiento de heridas crónicas, esto con el fin de optimizar la adquisición de información sobre una herida y lograr una mejor visualización de la misma. La primera trata sobre el cálculo de un conjunto de coordenadas sobre una imagen entre las cuales se encuentre el objeto a detectar, es decir, la detección se encarga de señalar una región en una imagen en donde se encuentra específicamente el objeto que se quiere detectar ⁴⁰, un ejemplo de esto se puede observar en la Figura 7. Por otro lado, la segmentación binaria se basa en la estimación de un mapa binario ^{40,41}, el cual representa la clasificación de una imagen en dos clases, en el caso de las heridas crónicas, las clases serían herida o piel sana, permitiendo un mejor análisis de las imágenes y procedimientos como cálculo de área o perímetro de la región segmentada, un ejemplo de mapa binario se observa en la Figura 8.

³⁹ Chuanbo Wang et al. "Fully automatic wound segmentation with deep convolutional neural networks". En: *Scientific reports* 10.1 (2020), págs. 1-9.

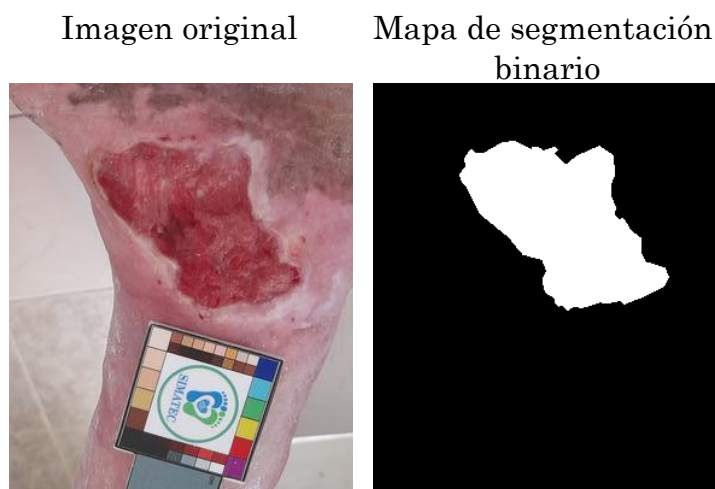
⁴⁰ Zhengxia Zou et al. "Object detection in 20 years: A survey". En: *arXiv preprint arXiv:1905.05055* (2019).

⁴¹ Shervin Minaee et al. "Image segmentation using deep learning: A survey". En: *IEEE transactions on pattern analysis and machine intelligence* (2021).

Figura 7. Imagen resultante de una red neuronal de detección, capaz de identificar 5 objetos diferentes, cuyas coordenadas de detección están representadas por los rectángulos que encierran a cada una de estas con su respectiva etiqueta. Tomado y traducido de⁴².



Figura 8. Segmentación binaria (derecha) de una herida crónica en paciente de Hansen del Sanatorio de Contratación E.S.E., la segmentación fue realizada por el autor del presente trabajo.



4. METODOLOGÍA PROPUESTA

El tratamiento de heridas crónicas en pacientes de Hansen es un proceso complejo que requiere una atención muy cuidadosa. En este sentido, la aplicación de técnicas de inteligencia artificial (aprendizaje profundo) puede ser de gran ayuda para los profesionales de la salud, ya que les permite analizar y procesar grandes cantidades de datos en tiempo real, lo que resulta en una mejor toma de decisiones y un tratamiento efectivo para los pacientes.

Con el fin de contribuir a este campo de investigación, en este trabajo de grado se propone el desarrollo de un algoritmo para la asistencia en el tratamiento de heridas crónicas en pacientes de Hansen. Para lograr este objetivo general, se llevará a cabo un proceso de cinco etapas, cada una, equivalente a uno de los objetivos planteados en la propuesta de trabajo de grado de este autor. La primera etapa se enfocará en la construcción del conjunto de datos, mientras que la segunda etapa se centrará en un análisis socio-demográfico de la población objetivo. La tercera etapa consistirá en el diseño del algoritmo de aprendizaje profundo, la cuarta etapa se enfocará en la evaluación de su desempeño. Finalmente, la quinta etapa se centrará en la comparación con los métodos presentes en el estado del arte, enfocados al tratamiento de heridas crónicas. Cada una de estas etapas será detalladamente expuesta en esta sección.

4.1. CONSTRUCCIÓN DE CONJUNTO DE DATOS DE HERIDAS CRÓNICAS

Objetivo específico No. 1. “Construir un conjunto de imágenes RGB de úlceras crónicas en extremidades inferiores adquiridas en pacientes del departamento de Santander con sus coordenadas de detección y máscaras de segmentación correspondientes.”

Para construir el conjunto de datos se deben llevar a cabo 3 sub-etapas, que incluyen el diseño de un patrón de calibración, la adquisición de datos y el procesamiento de los datos adquiridos. Los detalles de cada una de estas sub-etapas está a continuación:

1. **El diseño del patrón de calibración** que tiene como objetivo ser usado como referencia real para calibrar los niveles de color de la imagen y obtener medidas de las heridas. Este patrón deberá ser utilizado durante la adquisición de datos y su diseño deberá permitir que se identifique claramente en las imágenes (fotografías). El diseño de este patrón se realizó dentro del marco del proyecto de investigación 2707 de la VIE y su funcionalidad se encuentra fuera del alcance del trabajo de grado presente.
2. **La adquisición de datos** se realizará obteniendo fotografías de heridas crónicas tomadas desde distintos dispositivos móviles. Para garantizar la calidad de las imágenes y su posterior procesamiento, se propondrá un protocolo de adquisición que incluirá aspectos como la iluminación, ubicación del patrón de calibración, la distancia y el ángulo de la toma. La adquisición de las imágenes se llevará a cabo por profesionales de la salud en el Sanatorio de Contratación E.S.E., en colaboración con la institución y los pacientes que sufran de la enfermedad de Hansen. Se obtendrán fotografías de heridas crónicas en extremidades inferiores, ya que son las áreas más afectadas por esta enfer-

medad.

3. **El procesamiento de los datos adquiridos** será llevado a cabo manualmente por el autor del presente trabajo, y constará de dos fases distintas.
 - La primera fase del procesamiento consistirá en una **detección** manual de las imágenes, en la que se establecerán las coordenadas de detección de las heridas y el patrón de calibración en las fotografías. Este proceso permitirá generar un archivo de formato *.txt* para cada imagen.
 - A continuación, se procederá a construir los mapas de **segmentación binaria** para cada herida. En este proceso, las imágenes RGB obtenidas se transformarán en imágenes binarias, que representan dos clases: herida y no herida. Cada imagen RGB adquirida se convertirá en una imagen de segmentación binaria en formato *.png*. En este formato, los píxeles blancos representarán la zona de la herida, mientras que los negros representarán la zona donde no hay herida. En total, se generarán tantas imágenes binarias como imágenes RGB adquiridas.

La construcción del conjunto de datos se llevará a cabo utilizando un software gratuito que está pendiente de selección y el conjunto de datos construido se detalla en la sección 5.1 de los resultados.

4.2. ANÁLISIS DE CARACTERÍSTICAS SOCIO-DEMOGRÁFICAS DE LA POBLACIÓN OBJETIVO

Objetivo específico No. 2. *“Identificar las características socio-demográficas de los pacientes de úlceras crónicas por Hansen en el departamento de Santander y las necesidades de asistencia sanitaria que debe abordar el algoritmo a desarrollar.”*

El análisis socio-demográfico se basará en las características y necesidades de la población objetivo y se llevará a cabo mediante la recopilación y evaluación de las necesidades de los pacientes en el departamento de Santander. Además, se contará con las recomendaciones del personal médico y los pacientes del Sanatorio de Contratación E.S.E., quienes poseen el conocimiento necesario para identificar los factores que influyen en el tratamiento y la atención adecuada de los pacientes. También se estudiarán los principios y la información necesaria para apoyar el tratamiento de las heridas con el objetivo de utilizar la información recopilada para definir las características que debe tener la herramienta a desarrollar y brindar una retroalimentación completa al personal médico que facilite la toma de decisiones. Los resultados del análisis socio-demográfico se presentarán en la sección 5.2 de los resultados.

4.3. DISEÑO DE ALGORITMO DE APRENDIZAJE PROFUNDO

Objetivo específico No. 3. “Diseñar e implementar un algoritmo de inteligencia artificial para la segmentación y seguimiento de heridas crónicas en imágenes RGB.”

El algoritmo basado en aprendizaje profundo que será desarrollado está basado en 3 fases, eliminación de fondo, detección y segmentación binaria. El algoritmo se desarrollará en el lenguaje de programación Python y se ejecutará en la plataforma Google Colaboratory ⁴³. Cada una de estas fases es detallada a continuación:

1. **Eliminación de fondo:** La primera fase consta de una eliminación de fondo, esta se propone considerando la homogeneidad y la información irrelevante que puede presentar el fondo de una imagen, llegando a representar un factor posiblemente desventajoso para el funcionamiento del algoritmo. Es por esto que se busca eliminar esta información, para contar solo con la información necesaria, es decir, la piel y la herida.
2. **Detección de herida:** La detección de la herida consta de un proceso en donde, sobre la imagen con el fondo retirado, el algoritmo buscará acotar unas regiones específicas y garantizar que en estas regiones se encuentren las heridas presentes. Este paso realiza un enfoque de alta precisión hacia la zona de la extremidad en donde se encuentra la herida, eliminando las partes sanas que no requieren seguimiento. Las regiones detectadas son recortadas, superpuestas sobre un fondo negro y pasadas a la fase de segmentación.

⁴³ Ekaba Bisong. “Google Colaboratory”. En: *Building Machine Learning and Deep Learning Models on Google Cloud Platform: A Comprehensive Guide for Beginners*. Berkeley, CA: Apress, 2019, págs. 59-64. DOI: 10.1007/978-1-4842-4470-8_7.

- 3. Segmentación binaria de herida:** Con las regiones detectadas y superpuestas, se procede a realizar una segmentación binaria, este proceso se encargará de dividir las regiones detectadas en dos clases, herida y no herida, dando como resultado una imagen de 2 niveles de color.

Siguiendo estas 3 etapas, el algoritmo dará como resultado un mapa de segmentación binario de las zonas en la imagen que representan una herida.

El algoritmo de aprendizaje profundo resultante es expuesto en la sección 5.3 de los resultados.

4.4. EVALUACIÓN DEL ALGORITMO DE SEGMENTACIÓN Y SEGUIMIENTO DE HERIDAS

Objetivo específico No. 4. “Evaluar el algoritmo diseñado en términos de precisión, tiempo y costo computacional, a través de simulaciones ejecutadas en el conjunto de datos construido en el objetivo 1.”

La evaluación del algoritmo se realizará cuantitativamente usando métricas de evaluación enfocadas a la tarea de segmentación binaria, equivalente a una clasificación binaria. Estas métricas son precisión, exhaustividad y el valor-f1. Tomando como métrica principal el valor-f1, dado que comprende las métricas de precisión y exhaustividad. Adicionalmente, se hará una evaluación y análisis de recursos como tiempo y memoria usada durante la fase de entrenamiento. Finalmente, también se recopilará el tiempo de inferencia del algoritmo desarrollado.

4.4.1. DEFINICIÓN DE MÉTRICAS DE EVALUACIÓN La tarea que realiza el algoritmo es un proceso de clasificación binaria, ya que la salida del mismo es una imagen que representa 2 clases, herida (1) y no herida (0), es decir, se asigna una etiqueta a cada píxel, usando estas etiquetas, es posible aplicar distintas métricas enfocadas en el trabajo de la clasificación binaria. Estas métricas cuentan con 4 cantidades principales explicadas a continuación.

- **Verdadero positivo** (*True Positive - TP* - en inglés) representa los píxeles de la clase 1 que fueron etiquetados correctamente con esta clase.
- **Verdadero negativo** (*True Negative - TN* - en inglés) representa los píxeles de la clase 0 que fueron etiquetados correctamente con esta clase.
- **Falso negativo** (*False Negative - FN* - en inglés) representa los píxeles de la clase 1 que fueron etiquetados con la clase 0, es decir, incorrectamente.

- **Falso positivo** (*False Positive - FP* - en inglés) representa los píxeles de la clase 0 que fueron etiquetados con la clase 1, es decir, incorrectamente.

Usando estas 4 cantidades, se pueden calcular las métricas mencionadas anteriormente.

Precisión: Expresada en la ecuación 1, se obtiene usando TP y FP , e indica el porcentaje de píxeles clasificados como 1 que pertenecen realmente a esa clase⁴⁴. Esta métrica se encuentra en el rango de $[0, 1]$.

$$Precisión = \frac{TP}{TP + FP} \quad (1)$$

Exhaustividad: Expresada en la ecuación 2, es conocida en inglés como *Recall* y se obtiene usando TP y FN , e indica el porcentaje píxeles de la clase 1 que fueron clasificados correctamente⁴⁴. Esta métrica se encuentra en el rango de $[0, 1]$.

$$Exhaustividad = \frac{TP}{TP + FN} \quad (2)$$

Valor-f1: Expresada en la ecuación 3, es conocida en inglés como *F1-score*. Une las métricas de precisión y exhaustividad en una sola métrica y es utilizada cuando las clases a clasificar no están balanceadas⁴⁴, situación que se presenta en la segmentación binaria de heridas, dado que la herida generalmente representa una parte mínima de una imagen.

$$Valor - f1 = 2 \cdot \frac{Precisión \cdot Exhaustividad}{Precisión + Exhaustividad} \quad (3)$$

⁴⁴ *Towards Data Science. Korstanje, Joos. The F1 score.* [Sitio web]. [Consultado: 13 de Enero de 2023]. Disponible en: <https://towardsdatascience.com/the-f1-score-bec2bbc38aa6>.

La evaluación del algoritmo de aprendizaje profundo es expuesta en la sección 5.4 de los resultados.

4.5. COMPARACIÓN CON EL ESTADO DEL ARTE

Objetivo específico No. 5. “Comparar la herramienta computacional diseñada en este trabajo con otros métodos del estado del arte.”

En esta fase, se llevará a cabo una revisión de los trabajos previos relacionados con el tratamiento de heridas crónicas en la piel, centrándose específicamente en aquellas que abordan la segmentación binaria a partir de imágenes RGB de este tipo de heridas. Adicionalmente, se evaluarán diferentes arquitecturas de aprendizaje profundo en la tarea de segmentación binaria en heridas crónicas. Para ello, se realizará un análisis detallado de los enfoques y técnicas empleadas en cada estudio. A continuación, se llevará a cabo una comparación cuantitativa de los resultados obtenidos en los trabajos previos con las métricas expuestas en la sección anterior. Se evaluarán los algoritmos empleados y se comparará su desempeño. Los resultados de esta evaluación y comparación se presentarán detalladamente en la sección 5.5 de los resultados, lo que permitirá establecer un análisis riguroso y objetivo de los trabajos previos relacionados con el tratamiento de heridas crónicas en la piel.

5. RESULTADOS

En esta sección se presentan los resultados finales del trabajo desarrollado, esta sección se divide en 5 subsecciones, cada una correspondiente a cada objetivo planteado.

5.1. CONJUNTO DE DATOS DE IMÁGENES DE HERIDAS


Objetivo específico No. 1. “Construir un conjunto de imágenes RGB de úlceras crónicas en extremidades inferiores adquiridas en pacientes del departamento de Santander con sus coordenadas de detección y máscaras de segmentación correspondientes.”

En esta sección, se exponen los resultados obtenidos en la construcción del conjunto de datos para el tratamiento de heridas crónicas en pacientes de Hansen. La construcción de este conjunto de datos se llevó a cabo siguiendo las tres fases propuestas en la metodología, las cuales fueron cruciales para obtener un conjunto de datos completo y representativo de la población objetivo. En particular, se incluyen detalles sobre la adquisición de las imágenes de heridas crónicas y el procesamiento de las mismas.

El diseño del patrón de calibración: Se diseñó un patrón de calibración personalizado, como se muestra en la Figura 9. Además, se seleccionaron cuidadosamente características adicionales del patrón, es decir, cuadrados de colores, de manera que la red de detección pueda detectar fácilmente el patrón debido al contraste de colores. La fila superior incluye los colores RGB y CMYK. La fila inferior contiene seis colores correspondientes a la Escala de Color de la Piel de Fitzpatrick. Esta

escala clasifica la piel de una persona según su tez, color de cabello, tendencia a broncearse y tolerancia a la luz solar, llamados fototipos de la piel. Los cuadrados de las dos columnas izquierdas y la columna derecha interna corresponden a 22 colores especialmente definidos y seleccionados para que coincidan con la representación del tejido ulceroso. Por último, la columna derecha exterior contiene una escala de grises, tradicionalmente utilizada en sistemas de patrones para calibrar las respuestas del sensor blanco y negro. El diseño del patrón de calibración está destinado a tareas de calibración y obtención de mediciones reales de las heridas, sin embargo, estos procesos se encuentran fuera del alcance de este proyecto.

Figura 9. Patrón de calibración personalizado diseñado para ser usado como referencia real para tareas de calibración y medición de úlceras.



Adquisición de datos: En esta etapa se obtuvo un conjunto de imágenes RGB de pacientes de la enfermedad de Hansen con úlceras crónicas. Estos pacientes fueron seleccionados del Sanatorio de Contratación E.S.E., ubicado en el municipio de Contratación, en el departamento de Santander, Colombia. Para esta fase, se diseñó un protocolo de adquisición de imágenes que se compartió con el personal médico de la institución. Este protocolo constó de una serie de pasos detallados para la adquisición de imágenes con el fin de estandarizar el proceso y obtener datos consistentes:

1. Usar un fondo homogéneo posiblemente, como una manta o una superficie

monocromática.

2. Ubicar el plano de la herida de forma paralela al plano de la cámara del dispositivo de adquisición.
3. Ubicar el patrón de calibración de forma paralela al plano de la cámara del dispositivo de adquisición.
4. Asegurarse de que la iluminación sea suficiente para obtener una imagen clara y sin distorsiones.
5. Adquirir la imagen desde una distancia prudente, en donde se logre ver la herida en su totalidad.

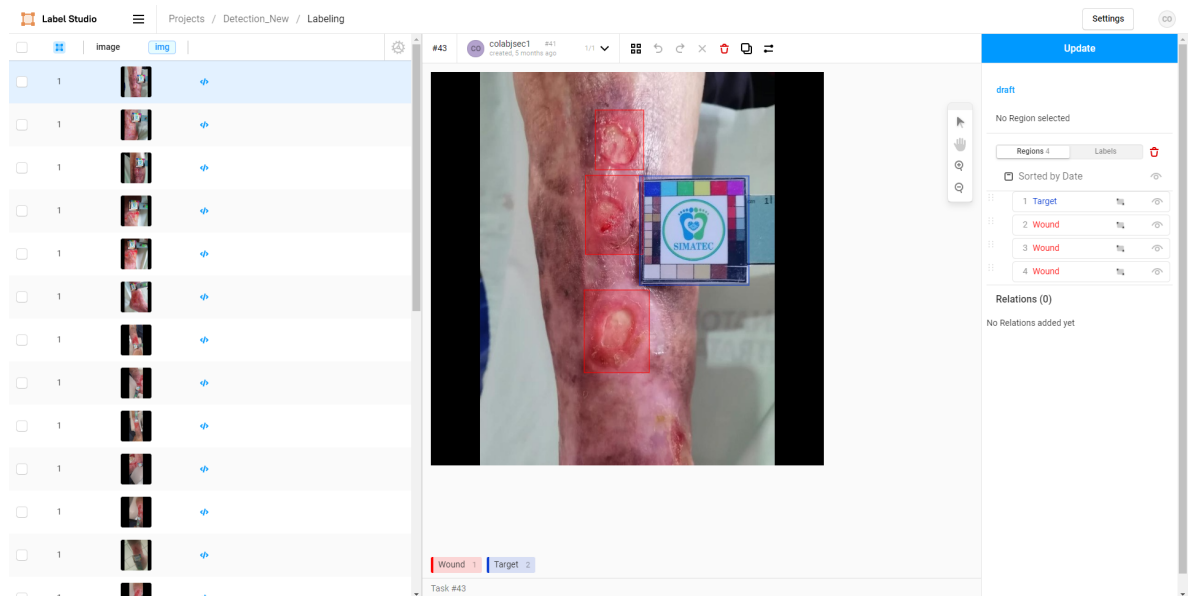
En total, 164 imágenes RGB anónimas fueron adquiridas usando las cámaras de distintos dispositivos móviles con características diferentes. Cabe resaltar que las imágenes fueron adquiridas siguiendo un protocolo avalado por los comités de ética de la Universidad Industrial de Santander (UIS) y del Sanatorio de Contratación E.S.E. Adicionalmente, los pacientes firmaron un consentimiento informado avalado por la UIS y el Sanatorio de Contratación E.S.E. El conjunto de datos construido es de acceso público y se puede encontrar en el siguiente enlace: <https://doi.org/10.17632/nkw5gx57hw.1>.

Procesamiento de datos: A partir de las imágenes obtenidas, se estimaron manualmente las respectivas coordenadas de detección y las máscaras de segmentación binaria usando la herramienta de *Label-Studio*⁴⁵, una plataforma de código abierto brindada al público para realizar etiquetado para diferentes tareas como detección, segmentación o clasificación. Estas tareas se pueden ejecutar sobre distin-

⁴⁵ Maxim Tkachenko et al. *Label Studio: Data labeling software*. Open source software available from <https://github.com/heartexlabs/label-studio>. 2020-2022.

tos tipos de datos, como imágenes, audio, texto, vídeo u otros.

Figura 10. Interfaz de la herramienta Label-Studio, la cual permite realizar segmentación y detección manual. La imagen muestra el proceso de etiquetado de coordenadas de detección para una de las fotografías del conjunto de datos construido.

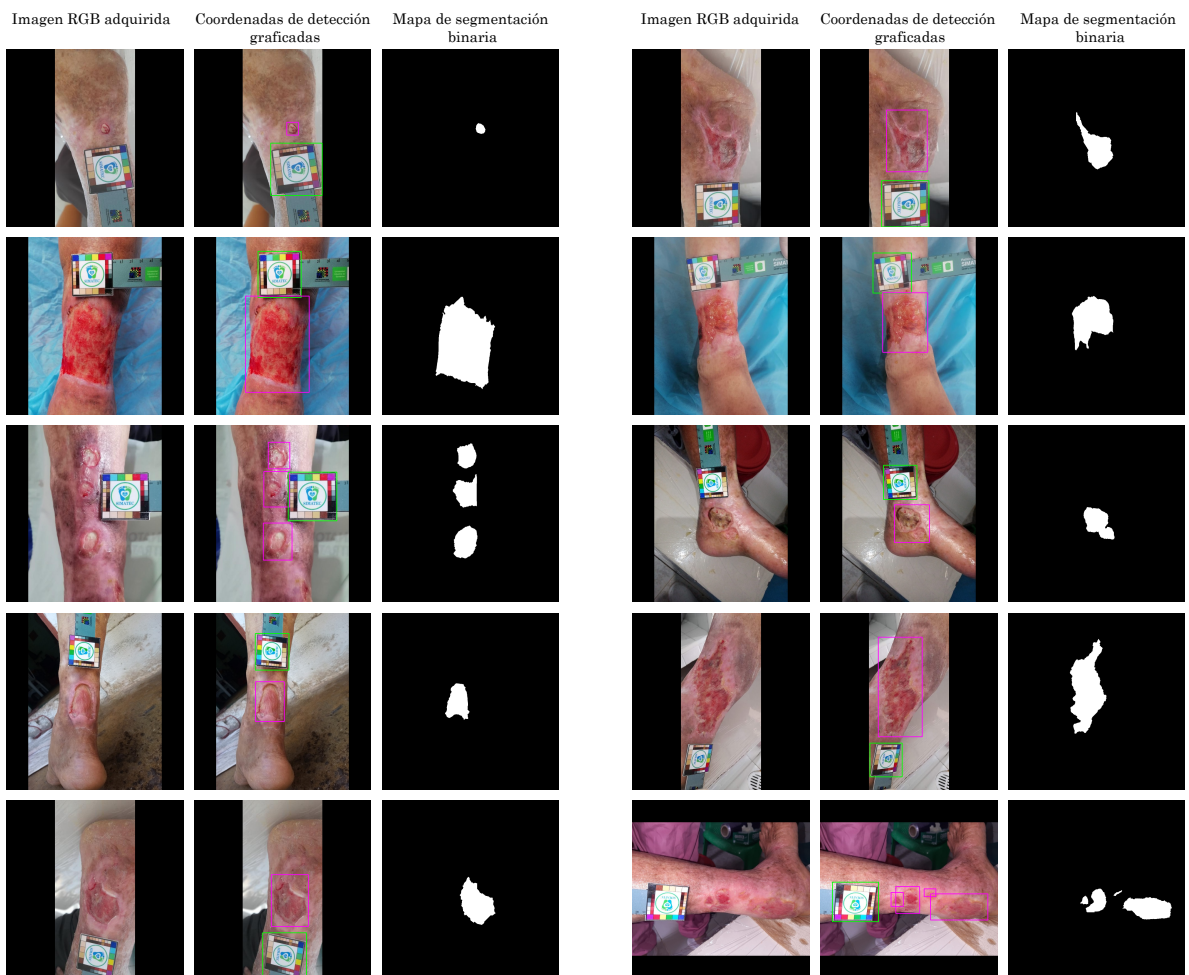


Finalmente, se estandarizó el tamaño de las imágenes RGB y máscaras de segmentación a 640×640 píxeles usando un relleno de píxeles negros, es decir, de intensidad 0. El conjunto de datos cuenta con las 164 imágenes junto con sus respectivas coordenadas de detección y máscaras de segmentación binaria, la Figura 11 muestra distintos ejemplos de la información brindada por el conjunto de datos y los detalles de cada categoría se muestran a continuación:

- **Imágenes RGB de heridas:** Imágenes RGB en formato .png, representando la fotografía obtenida de la herida.

- **Coordenadas de detección:** Archivo en formato .txt, el cual contiene una coordenada de detección por cada línea. Estas coordenadas se conforman por 5 elementos, clase de la detección (Herida o patrón de calibración), coordenada central en el eje horizontal, coordenada central en el eje vertical, altura y anchura del rectángulo de detección. Para este proyecto, se tuvieron en cuenta únicamente las coordenadas de detección de las heridas, descartando las del patrón de calibración.
- **Máscaras de segmentación binaria:** Imágenes RGB en formato .png, estas solo cuentan con 2 colores, blanco y negro, representando si la región segmentada es herida o no, respectivamente.

Figura 11. Muestras aleatorias del conjunto de datos construido. Cada fila incluye dos ejemplos de muestras del conjunto de datos así: La fotografía RGB, mostrada en la primera columna, las coordenadas de detección de la herida y del patrón de calibración, mostradas en la segunda columna, y el mapa de segmentación binario de la herida, que se muestra en la tercera columna.



5.2. CARACTERÍSTICAS SOCIO-DEMOGRÁFICAS

Objetivo específico No. 2. “Identificar las características socio-demográficas de los pacientes de úlceras crónicas por Hansen en el departamento de Santander y las necesidades de asistencia sanitaria que debe abordar el algoritmo a desarrollar.”

El análisis de características socio-demográficas es una parte esencial en el desarrollo de herramientas para el tratamiento de heridas crónicas. Se trata de un proceso que implica la recopilación y el análisis de diferentes aspectos que pueden influir significativamente en el éxito de la herramienta en cuestión.

Estas características socio-demográficas son variadas y abarcan aspectos como la ubicación geográfica o el nivel socio económico. Cada uno de estos factores puede afectar la forma en que una persona experimenta una herida crónica y su tratamiento, por lo que deben ser considerados. En este sentido, se han recopilado y analizado diferentes aspectos relevantes de estas características socio-demográficas. Este análisis es fundamental para asegurar que la herramienta para el tratamiento de heridas crónicas sea efectiva y esté adaptada a las necesidades y particularidades de la población a la que se dirige.

Región de interés: La zona de interés determinada es el departamento de Santander, ubicado en el noreste de Colombia, en la región andina del país. Es el sexto departamento más grande de Colombia, contando con una población de 2.185 millones. El departamento está conformado por 87 municipios y se divide en siete provincias: Comunera, García Rovira, Guanentá, Metropolitana, Yariguíes, Soto Norte y Vélez. La altitud varía de 200 a 4000 metros sobre el nivel del mar, lo que influye en el clima, que es tropical de montaña. Estas condiciones climáticas pueden afectar significativamente el tratamiento de heridas crónicas, ya que la humedad y las

fluctuaciones de temperatura pueden retrasar el proceso de curación.

Enfermedad de Hansen en Santander: La enfermedad de Hansen ha tenido un impacto significativo en la historia del departamento de Santander. Desde finales del siglo XIX y hasta mediados del siglo XX, la enfermedad fue una de las principales preocupaciones de salud pública en la región, y se cree que miles de personas fueron afectadas. En aquellos tiempos, el aislamiento y la estigmatización eran las prácticas comunes para las personas que padecían la enfermedad.

Hoy en día, la enfermedad de Hansen sigue siendo una preocupación para la salud pública en el departamento, y el municipio de Contratación sigue siendo un punto focal en la lucha contra la enfermedad. La institución principal encargada del cuidado y tratamiento de pacientes con Hansen en el departamento se encuentra en este municipio, y cuenta con una larga historia de brindar atención médica especializada a personas que padecen la enfermedad. Además, el Sanatorio de Contratación E.S.E. ha desempeñado un papel importante en la investigación y el desarrollo de nuevos tratamientos y estrategias para combatir la enfermedad.

Municipio de Contratación: Se encuentra ubicado en la provincia comunera. Esta región está conformada por 16 municipios: El Socorro, Confinés, Contratación, Chima, Galán, Gámbita, El Guacamayo, Guadalupe, Guapotá, Hato, Oiba, Palmar, Palmas del Socorro, Santa Helena del Opón, Simacota y Suaita ⁴⁶. El municipio de Contratación cuenta con una población total de 3491 habitantes (2015), siendo 2698 de ellos, población urbana. Es conocido históricamente por su relación con la enfermedad de Hansen, contando con el Sanatorio de Contratación E.S.E., institución

⁴⁶ *Alcaldía Municipal de Contratación en Santander. CONTRATACIÓN, SU HISTORIA.* [Sitio web]. [Consultado: 6 de Marzo de 2023]. Disponible en: <http://www.contratacion-santander.gov.co/municipio/contratacion-su-historia>.

que se encarga de atender a los pacientes de esta enfermedad en Santander. La economía de este municipio gira en torno a la enfermedad de Hansen, apoyándose en subsidios del estado y empleos dentro de la institución para el tratamiento de la enfermedad ⁴⁶.

Figura 12. Localización de Contratación en el departamento de Santander. Tomado de⁴⁷.



Sanatorio de Contratación E.S.E.: El Sanatorio de Contratación E.S.E. es una institución que realiza seguimiento a pacientes de la enfermedad de Hansen. Según datos oficiales del programa Hansen 170 pacientes son tratados, de los cuales 53 residen dentro de la institución. Tiene como objetivo prestar el servicio de salud a los enfermos de Hansen, actuar como órgano consultor del Ministerio de protección social y promover el desarrollo científico y tecnológico en cuanto a la enfermedad de Hansen.

Características a implementar: Para conocer y definir las características a implementar, se estableció contacto con el personal de salud del Sanatorio de Contrata-

ción E.S.E. Posteriormente, se hizo caso a las demandas y requerimientos de los profesionales de la salud de esta institución y de médicos de la Universidad Industrial de Santander. De lo cual se obtuvo que las características óptimas a implementar son un procesamiento visual de la herida que permita estimar visualmente los límites de la misma y sirva de soporte para el análisis visual. Esto con el objetivo de lograr llevar un seguimiento del estado de la herida por medio de su tamaño, forma y otras características espaciales. Esto se realiza dado que los registros manuales realizados por los enfermeros pueden presentar ciertos desafíos en términos de uniformidad y continuidad, especialmente cuando se consideran las rotaciones del personal. La obtención de un análisis visual a través del uso de una herramienta automatizada de detección y seguimiento de úlceras cutáneas crónicas se convierte así en una prioridad, dado que permitiría un monitoreo más efectivo, confiable y preciso del estado de la herida, mejorando así la atención médica de los pacientes afectados.

5.3. ALGORITMO DE SEGMENTACIÓN Y SEGUIMIENTO DE HERIDAS

Objetivo específico No. 3. “Diseñar e implementar un algoritmo de inteligencia artificial para la segmentación y seguimiento de heridas crónicas en imágenes RGB.”

El algoritmo diseñado se compone de tres fases que se encargan de procesar la imagen y obtener información relevante de la herida. En la primera fase se usó una función para eliminar el fondo de la imagen y destacar únicamente la zona de la extremidad y de la piel, eliminando información irrelevante. La segunda fase consiste en la detección de las heridas sobre la imagen con el fondo eliminado, utilizando una arquitectura de red neuronal específica para esta tarea. Finalmente, en la tercera fase se lleva a cabo la segmentación binaria de la zona detectada, dividiendo la imagen en herida y no herida mediante una segunda red neuronal. Cada una de las fases se ha diseñado para trabajar de forma independiente, pero en conjunto proporcionan un modelo completo y preciso para el análisis de la herida. Los detalles de las funciones y arquitecturas usadas para cada fase se detallan a continuación:

1. **Eliminación de fondo:** Para llevar a cabo la tarea de eliminación de fondo, se empleó la función *rembg* proporcionada por el repositorio de Daniel Gatís ⁴⁸. Dicha función está diseñada específicamente para remover el fondo de diversas imágenes y se basa en una red neuronal pre-entrenada que utiliza la arquitectura U²-Net ⁴⁹. Esta última es una estructura en forma de U anidada de dos niveles que ha demostrado ser efectiva para capturar información local

⁴⁸ D. Gatís. *rembg*. <https://github.com/danielgatis/rembg>. 2023.

⁴⁹ Xuebin Qin et al. “U²-Net: Going deeper with nested U-structure for salient object detection”. En: *Pattern recognition* 106 (2020), pág. 107404.

y global en imágenes, remarcando los bloques residuales que proponen.

Cabe destacar que se optó por utilizar una función que no requiere de un proceso de aprendizaje, debido a la falta de conjuntos de datos que contengan imágenes de heridas médicas con el fondo ya eliminado. De esta manera, se buscó obtener un método que pudiera ser adaptado a diferentes tareas o conjuntos de datos sin la necesidad de contar con un conjunto de imágenes específicas para la eliminación del fondo.

2. **Detección de herida:** Para la fase de detección se utilizó la arquitectura YOLOv7⁵⁰ que cuenta con 36.9 millones de parámetros entrenables y se basa en el algoritmo You Only Look Once. Esta arquitectura se caracteriza por su capacidad de procesar imágenes de alta resolución en tiempo real, lo que la hace ideal para aplicaciones en tiempo real como la detección de heridas. Además, el enfoque de la arquitectura YOLOv7 trata la detección de objetos como un problema de regresión, en el que se predice un conjunto de coordenadas delimitadoras alrededor de los objetos detectados. Este aspecto lo hace diferente a otros enfoques que tratan la detección como un problema de clasificación⁵¹. Esto hace que el algoritmo sea más eficiente y preciso en la detección de objetos, incluyendo heridas en imágenes médicas. En resumen, la arquitectura YOLOv7 fue seleccionada para la fase de detección debido a su eficiencia, precisión y capacidad de procesar imágenes de alta resolución en tiempo real.

⁵⁰ Chien-Yao Wang, Alexey Bochkovskiy y Hong-Yuan Mark Liao. "YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors". En: *arXiv preprint arXiv:2207.02696* (2022).

⁵¹ Joseph Redmon et al. "You only look once: Unified, real-time object detection". En: *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016, págs. 779-788.

3. **Segmentación de herida:** La fase de segmentación de la imagen es implementada utilizando la arquitectura U-net ⁵². Esta arquitectura se compone de una serie de capas convolucionales, encargadas de extraer características de la imagen, y operaciones de reducción y aumento de dimensionalidad, que permiten obtener una segmentación precisa de la imagen. Una de las características más importantes de la arquitectura U-net son las conexiones de salto ("*skip connections*" en inglés), que conectan las capas de la red en una estructura en forma de U. Estas conexiones permiten que la información se transmita de manera directa desde las capas de la red que realizan la extracción de características a las capas encargadas de la reconstrucción de la imagen segmentada. La arquitectura U-net se utiliza con frecuencia en tareas de segmentación binaria, en particular en el área de imágenes médicas, debido a su capacidad para generar segmentaciones precisas y detalladas de las regiones de interés. Además, la arquitectura U-net permite el uso de imágenes de alta resolución y reduce significativamente la cantidad de datos necesarios para el entrenamiento, lo que la hace más eficiente y rápida que otras arquitecturas de redes neuronales convolucionales.

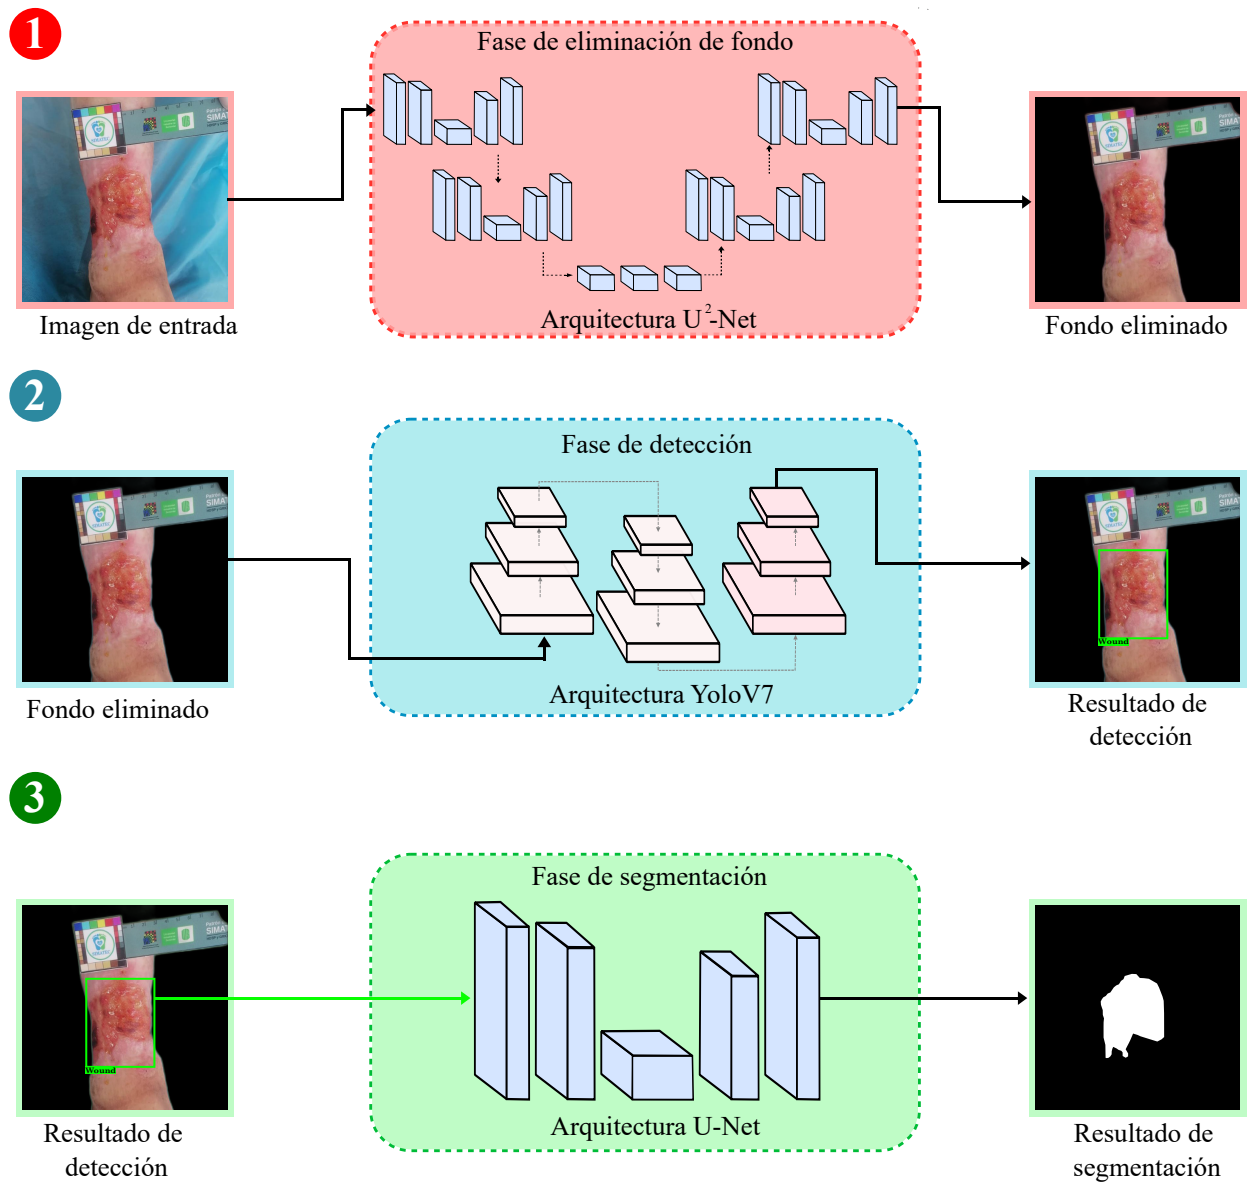
Específicamente, se usó la arquitectura U-net con 6 niveles de profundidad, en donde cada nivel cuenta con las cantidades de filtros convolucionales de [16, 32, 64, 128, 256, 512] respectivamente. En total, el modelo cuenta con 7,778,609 parámetros entrenables.

El algoritmo desarrollado fue implementado usando el lenguaje de Python y el framework para Machine Learning llamado Pytorch⁵³.

⁵² Olaf Ronneberger, Philipp Fischer y Thomas Brox. "U-net: Convolutional networks for biomedical image segmentation". En: *International Conference on Medical image computing and computer-assisted intervention*. Springer. 2015, págs. 234-241.

⁵³ Adam Paszke et al. "Pytorch: An imperative style, high-performance deep learning library". En:

Figura 13. Esquema de aprendizaje profundo propuesto compuesto de 3 fases, en la primera fase, se elimina el fondo de la imagen, dejando solo la extremidad del paciente en cuestión. En la segunda fase, se utiliza la arquitectura YOLOv7 para detectar la presencia de heridas en las imágenes médicas. Finalmente, se utiliza la arquitectura U-net para separar la zona herida de la no herida en la imagen.



5.4. EVALUACIÓN DEL ALGORITMO DISEÑADO

Objetivo específico No. 4. “Evaluar el algoritmo diseñado en términos de precisión, tiempo y costo computacional, a través de simulaciones ejecutadas en el conjunto de datos construido en el objetivo 1.”

El entrenamiento del algoritmo diseñado se realizó en tres etapas, las cuales estudian el rendimiento y la influencia de cada uno de los procesos incluidos en el esquema propuesto. Para la evaluación del algoritmo de aprendizaje profundo, se tomó un enfoque de validación cruzada de K iteraciones o conocida en inglés como “*K-fold cross-validation*”, en donde se usaron K=10 iteraciones para el conjunto de 164 imágenes. Adicionalmente, la arquitectura U-net, usada para la segmentación binaria, fue pre-entrenada durante 150 épocas, con una tasa de aprendizaje de 1×10^{-4} , un tamaño de lote de 8 y con dimensiones de 640×640 para cada imagen, este pre-entrenamiento fue realizado con el conjunto de datos de heridas crónicas causadas por diabetes provenientes de Polonia llamado *WoundsDB*⁵⁴.

5.4.1. ALGORITMO DE ELIMINACIÓN DE FONDO (E) La eliminación de fondo se aplica como una función común de Python que presenta diversos parámetros que influyen en el resultado final. En concreto, existen cuatro parámetros principales: “model”, “alpha matting”, “alpha matting foreground threshold” y “alpha matting background threshold”.

El parámetro “model” se refiere a la selección de un modelo pre-entrenado para la tarea de eliminación de fondo, siendo la opción utilizada en este caso el mo-

Advances in neural information processing systems 32 (2019).

⁵⁴ Jan Maria Juszczak et al. “Wound 3D Geometrical Feature Estimation Using Poisson Reconstruction”. En: *IEEE Access* 9 (2021), págs. 7894-7907. DOI: 10.1109/ACCESS.2020.3035125.

delo “u2net”. Este parámetro es importante ya que existen distintos modelos pre-entrenados enfocados en la eliminación de fondos de diferentes objetos en imágenes, como siluetas humanas o prendas de ropa. El modelo seleccionado está entrenado para casos de uso general, es decir, es adecuado para eliminar fondos de diferentes tipos de objetos en imágenes, sin especializarse en un tipo específico. La Figura 14 muestra la eliminación de fondo usando los parámetros predeterminados. La técnica de “alpha matting” se utiliza para diferenciar los objetos de primer plano y fondo en una imagen. Los parámetros “alpha matting foreground threshold” y “alpha matting background threshold” representan los umbrales que se utilizan para establecer si un objeto pertenece al primer plano o al fondo. Estos parámetros fueron explorados, llevando a encontrar que el parámetro “alpha matting foreground threshold” tenía una mayor influencia en el resultado final, a comparación del parámetro “alpha matting background threshold”, el cual no presentó una influencia remarcable. En aquellos casos en los que la herida no era reconocida, se pudo corregir la imagen modificando este parámetro, lo que permitió obtener mejores resultados. Este parámetro tiene un valor por defecto de 240, pero en los casos en los que el fondo fue eliminado incorrectamente, se ajustó a 0 para corregir la imagen. Algunos ejemplos de este caso se muestran en la Figura 15.

Figura 14. Ejemplos de eliminación de fondo usando los parámetros predeterminados.

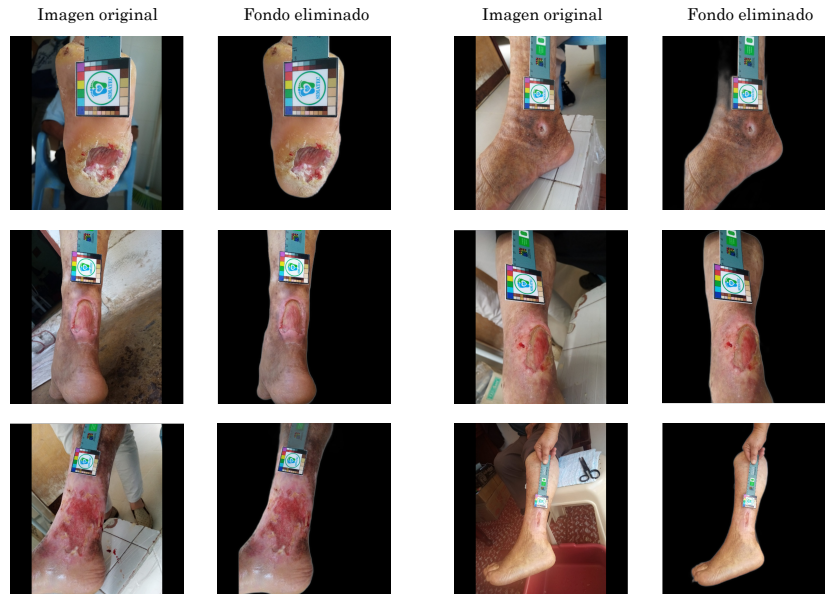
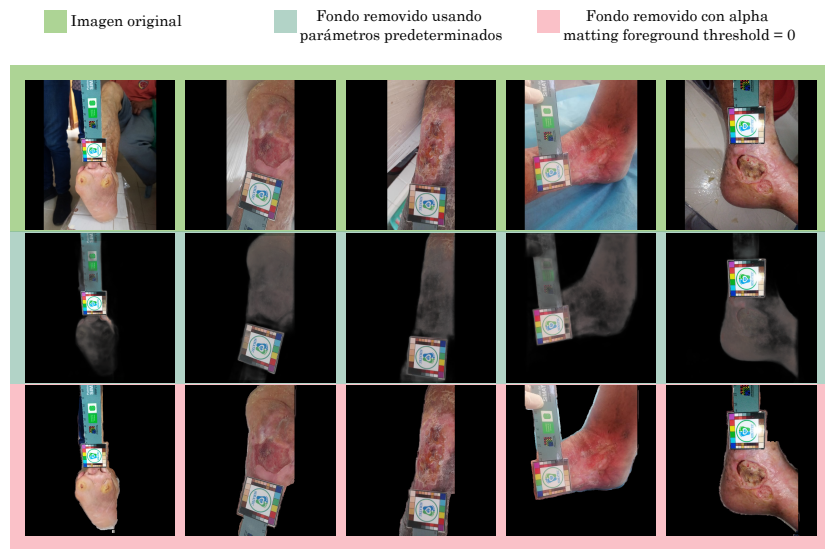


Figura 15. Eliminación de fondo alterando el parámetro de alpha matting foreground threshold. La primera fila muestra la imagen original, seguida de la eliminación de fondo usando los parámetros predeterminados y la tercera fila muestra la eliminación de fondo fijando el valor de alpha matting foreground threshold a 0.



5.4.2. ALGORITMO DE DETECCIÓN (D) La arquitectura YoloV7, usada para la detección, se entrena única e individualmente para cada grupo de la validación cruzada, este se entrenó durante 500 épocas, con un tamaño de lote de 16 y los parámetros establecidos por defecto por parte de los autores de la arquitectura YoloV7.

5.4.3. ALGORITMO DE SEGMENTACIÓN (S) El modelo de segmentación fue entrenado en 3 fases, estos 3 entrenamientos tuvieron el objetivo de evaluar y verificar el impacto de cada uno de los pasos propuestos en la metodología. La función de pérdida utilizada fue la entropía cruzada binaria, conocida en inglés como “Binary Cross Entropy”.

- **Fase S:** Esta fase consta del entrenamiento individual de la arquitectura U-Net, sin las tareas de eliminación de fondo y detección. Para esta fase, el entrenamiento se ejecutó por 200 épocas, con una tasa de aprendizaje de 1×10^{-4} , un tamaño de lote de 8 y con dimensiones de 640×640 para cada imagen.
- **Fase D+S:** Para esta fase el entrenamiento fue realizado incorporando la red de detección pre-entrenada junto con la red de segmentación. En esta fase, la red de detección es fijada y no se entrena, sólo se ejecuta su inferencia, mientras que la red de segmentación sí es entrenada. Esta fase se ejecutó por 200 épocas, con una tasa de aprendizaje de 1×10^{-4} , un tamaño de lote de 8 y con dimensiones de 640×640 para cada imagen.
- **Fase E+D+S:** Para el esquema completo se incorporan la función de eliminación de fondo, seguida de la inferencia de la red de detección, la cual no es entrenada y se finaliza con la red de segmentación, que será la única con parámetros entrenables. La cual se entrenó por 200 épocas, con una tasa de

aprendizaje de 1×10^{-4} , un tamaño de lote de 8 y con dimensiones de 640×640 para cada imagen.

Durante el entrenamiento de cada una de las 3 fases expuestas anteriormente, se usó un esquema de aumento de datos que presenta operaciones de rotaciones horizontales, verticales y entre 0 y 180 grados.

5.4.4. EVALUACIÓN En la evaluación del algoritmo en cada etapa expuesta, se usaron las métricas definidas previamente, cada cantidad muestra el promedio y la desviación estándar de las 10 ejecuciones correspondientes a los 10 grupos del esquema de validación cruzada. Adicionalmente, se evaluó el rendimiento temporal en el entrenamiento e inferencia del modelo desarrollado, así como el uso de recursos durante el entrenamiento como la memoria de la tarjeta gráfica. Esto se realizó para cada fase.

El Cuadro 1 muestra el rendimiento temporal promedio y el consumo máximo de recursos de la memoria de la tarjeta gráfica utilizada durante el proceso de entrenamiento, este rendimiento es evaluado en los 3 casos en donde cada etapa es incluida. El entrenamiento del algoritmo propuesto, para todas las fases se realizó en un equipo que cuenta con 13 Gigabytes (GB) de memoria de acceso aleatorio (RAM), un procesador Intel(R) Xeon(R) con una frecuencia de 2.20 GigaHertz (GHz) y una tarjeta gráfica NVIDIA Tesla T4 con memoria gráfica de acceso aleatorio (VRAM) de 15 GB, las cuales son las especificaciones de los equipos brindados por la plataforma de Google Colaboratory.

A nivel de resultados cuantitativos, el Cuadro 2 muestra los resultados de inferencia obtenidos, en donde cada columna muestra el rendimiento del algoritmo al incluir cada etapa propuesta, representando segmentación (S), detección (D) y la eliminación de fondo (E).

Cuadro 1. Consumo del algoritmo en entrenamiento en términos del tiempo empleado por época y memoria gráfica utilizada en cada fase, cada uno de estos mostrado en una columna respectivamente.

Fase	Tiempo por época (s)	Memoria de GPU utilizada (GB)
S	12.9	4.5
D+S	20.3	5.2
E+D+S	265.4	5.2


Cuadro 2. Resultados individuales del algoritmo desarrollado, en donde se estudia el aporte de cada etapa propuesta, representada por las 3 columnas, indicando segmentación (S), detección (D) y eliminación de fondo (E).

Fases (→)	S	D+S	E + D + S (Propuesto)
Métricas (↓)			
Precisión (%)	79.9±3.73	80.2±6.11	82.3±3.59
Exhaustividad (%)	77.1±4.62	86.1±3.02	85.7± 3.01
Valor-f1 (%)	75.9±4.42	79.5±4.46	82.1±2.98
Tiempo de inferencia (ms)	5.2 ± 1.7	26.9±1.8	954.5±321.3

Los dos cuadros permiten observar la alta influencia temporal al incluir la función de eliminación de fondo, por otro lado, se resalta que el entrenamiento del modelo consume recursos de memoria a una cantidad aceptable, haciéndolo sencillo de entrenar. A nivel cuantitativo, el Cuadro 2 permite observar la influencia de cada fase incluida en el algoritmo, en donde se confirma que la incorporación del algoritmo de detección y de eliminación de fondo apoyan a la eliminación de información irrelevante, enfocándose en la herida y permitiendo así un mayor puntaje en las métricas en cuestión. Por otro lado, el tiempo de inferencia del algoritmo en cada una de sus fases, es bajo, representando un alto potencial para ser desarrollado como una herramienta que funcione en tiempo real. Finalmente, el rendimiento visual del

algoritmo con datos de evaluación se muestra en la Figura 16, en donde se muestran múltiples ejemplos del resultado dado por el algoritmo propuesto para distintas imágenes de heridas, en cada fila se muestra la imagen original, la máscara real y las segmentaciones obtenidas por el esquema usando solo la segmentación, la detección y la segmentación y el enfoque de 3 pasos propuesto, organizados por columnas respectivamente. Adicionalmente, se muestra una estimación visual de la cantidad de TP, FP, FN y TN para cada imagen. Finalmente, cada imagen es acompañada de los resultados cuantitativos en las métricas definidas.

Figura 16. Resultados visuales del algoritmo propuesto para cada fase, segmentación (S), detección y segmentación (D+S) y el esquema de 3 pasos propuesto, eliminación de fondo, detección y segmentación (E+D+S).



5.5. COMPARACIÓN CON EL ESTADO DEL ARTE

Objetivo específico No. 5. “Comparar la herramienta computacional diseñada en este trabajo con otros métodos del estado del arte.”

En esta sección se evalúa el desempeño del algoritmo propuesto en comparación con varias arquitecturas de aprendizaje profundo presentes en el estado del arte: VGG16⁵⁵, SegNet⁵⁶, MobileNetV2⁵⁷, arquitectura U-net y CO2DNet⁹. La evaluación se lleva a cabo mediante una comparación cuantitativa utilizando las métricas de precisión, exhaustividad y valor-f1, que miden la capacidad del algoritmo para detectar y segmentar las heridas en imágenes médicas.

- **VGG16:** Es una arquitectura de red neuronal convolucional desarrollada por el Visual Geometry Group (VGG) en la Universidad de Oxford. El “16” en su nombre se refiere a que utiliza 16 capas, incluyendo 13 capas convolucionales y 3 capas completamente conectadas, como se observa en la Figura 17. Todas las capas convolucionales utilizan filtros de tamaño 3x3 y un relleno de 1 píxel. Después de cada capa convolucional, se aplica una función de activación ReLU. Esta arquitectura también utiliza capas de reducción de dimensión espacial de los mapas de características. Esta arquitectura fue modificada, quitando las capas completamente conectadas y


⁵⁵ Manu Goyal et al. “Fully convolutional networks for diabetic foot ulcer segmentation”. En: *2017 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*. 2017, págs. 618-623. DOI: 10.1109/SMC.2017.8122675.

⁵⁶ Changhan Wang et al. “A unified framework for automatic wound segmentation and analysis with deep convolutional neural networks”. En: *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. 2015, págs. 2415-2418. DOI: 10.1109/EMBC.2015.7318881.

⁵⁷ Chuanbo Wang et al. “Fully automatic wound segmentation with deep convolutional neural networks”. En: *Scientific reports* 10.1 (2020), pág. 21897.


dejándola completamente como una red convolucional para la segmentación binaria de heridas.

Figura 17. Arquitectura original del modelo VGG16. Tomado de⁵⁸.



- **SegNet:** Es una arquitectura completamente convolucional que usa operaciones de reducción de dimensionalidad. Adicionalmente, usa filtros de tamaño 9x9, 5x5 y 7x7 para extraer las características de las imágenes y obtener los mapas de segmentación binarios, como se observa en la Figura 18.

Figura 18. Arquitectura del modelo SegNet. Tomado de⁵⁹.



- **MobileNetV2:** Es una arquitectura de red neuronal convolucional diseñada específicamente para aplicaciones en dispositivos móviles y sistemas con recursos computacionales limitados. Fue desarrollada por Google. La arquitectura se basa en una

estructura llamada bloque de inversión residual lineal. Este bloque utiliza una combinación de capas de convolución 1x1 y 3x3 para reducir el costo computacional y la cantidad de parámetros de la red, al tiempo que mantiene un rendimiento adecuado.

- **Arquitectura U-net:** La arquitectura U-net fue la implementada en la etapa de segmentación individual (S), la cual fue detallada en la sección 5.3.

- **CO2DNet:** Es un enfoque de dos pasos que utiliza redes neuronales convolucionales (CNN) para detectar y segmentar heridas en imágenes médicas. En el primer paso, se utiliza una red YOLO, específicamente la arquitectura YOLOv4 para detectar las heridas en la imagen. En el segundo paso, se utiliza una red de segmentación basada en la arquitectura U-net para segmentar la herida detectada. Este método tiene la ventaja de ser capaz de detectar y segmentar heridas en imágenes médicas de alta resolución con precisión y eficiencia. Además, el enfoque de dos pasos permite una mejor separación entre las áreas de herida y no herida en la imagen, lo que mejora la precisión de la segmentación. El método también se ha validado en un estudio de caso en Colombia, lo que sugiere que es aplicable a una amplia gama de contextos clínicos.

La comparación cuantitativa se realizó usando las métricas definidas y los resultados se observan en el Cuadro 3. Se concluye que el método propuesto presenta un rendimiento mayor a los enfoques presentados en el estado del arte, apoyando el uso de las funciones para procesar y eliminar información irrelevante de las imágenes como lo son la eliminación de fondo y la detección de las heridas.

Cuadro 3. Comparación de resultados cuantitativos de segmentación con métodos del estado del arte y basados en aprendizaje profundo en el conjunto de datos CO2Wounds.

Métodos	(↑) Métricas (media±desviación estándar)		
	Valor-f1	Precisión	Exhaustividad
VGG16	50.6±7.25	68.7±12.7	53.9±8.71
SegNet	46.4±5.45	68.4±11.4	51.5±7.17
MobileNetV2	54.1±7.72	65.9±12.5	70.7±12.6
Arquitectura U-net	75.9±4.42	79.9±3.73	77.1±4.62
CO2Dnet	80.3±2.83	84.5±4.51	81.9±4.71
Propuesto	82.1±2.98	82.3±3.59	85.7±3.01

6. CONCLUSIONES

Un enfoque basado en aprendizaje profundo para la evaluación y seguimiento de heridas crónicas ha sido presentado. El trabajo propuesto incluye 3 pasos que son: eliminación de fondo, detección y segmentación de heridas, donde se utilizan redes neuronales profundas con transferencia de aprendizaje y esquemas de aumento de datos para evitar el sobreajuste y mejorar el rendimiento.

Además, se ha construido un nuevo conjunto de datos de heridas crónicas de lepra (CO2Wounds) padecidas por pacientes que residen en un país en vías de desarrollo. Este nuevo conjunto de datos tiene como objetivo proporcionar más variabilidad en los conjuntos de datos de heridas crónicas disponibles actualmente, para permitir trabajos futuros en este contexto.

Los resultados experimentales validan la estrategia propuesta, con un valor-f1 del 82.1 %, una precisión del 82.3 % y una exhaustividad del 85.7 % sobre el conjunto de datos CO2Wounds. Estos resultados superan a los de los métodos de segmentación del estado del arte evaluados (VGG16, SegNet, MobileNetV2, arquitectura U-net y CO2DNet).

Los trabajos futuros pueden aprovechar el patrón de calibración con fines de calibración de color, con el objetivo de considerar las variaciones de color de la piel y las úlceras. Adicionalmente, se puede tomar como referencia real para el cálculo de medidas como área y perímetro, apoyando la asistencia a un mayor nivel. Además, se podría considerar un enfoque en donde se analicen las distintas capas de la piel, como la epidermis, dermis e hipodermis, con el objetivo de que el análisis de las heridas contemple los tejidos subyacentes y la información debajo de la superficie de la piel que pueda apoyar la cicatrización de las heridas.

7. TRABAJO FUTURO

En investigaciones futuras, se plantea la posibilidad de utilizar el patrón de calibración como una herramienta para calibrar el color y lograr una estandarización de los niveles de color obtenidos de diferentes dispositivos móviles. El objetivo de dichas investigaciones sería analizar si la utilización de esta herramienta mejoraría el rendimiento en la segmentación de imágenes al manejar de manera más eficaz los problemas causados por diferentes niveles de iluminación y diferentes cámaras. Adicionalmente, se plantea la posibilidad de adquirir un conjunto de datos mediante otra modalidad de adquisición, como la luz estructurada (Structured light), con el objetivo de evaluar no solo la herida en la superficie (2D), sino también aspectos de profundidad (3D). El objetivo sería analizar si esta modalidad de adquisición proporciona una vista global más completa del desarrollo de las heridas.

BIBLIOGRAFÍA

- Alcaldía Municipal de Contratación en Santander. CONTRATACIÓN, SU HISTORIA.*
[Sitio web]. [Consultado: 6 de Marzo de 2023]. Disponible en: <http://www.contratacion-santander.gov.co/municipio/contratacion-su-historia> (vid. págs. 46, 47).
- Bisong, Ekaba. “Google Colaboratory”. En: *Building Machine Learning and Deep Learning Models on Google Cloud Platform: A Comprehensive Guide for Beginners*. Berkeley, CA: Apress, 2019, págs. 59-64. DOI: 10.1007/978-1-4842-4470-8_7 (vid. pág. 33).
- Bowers, Steven y Eginia Franco. “Chronic wounds: evaluation and management”. En: *American family physician* 101.3 (2020), págs. 159-166 (vid. págs. 11, 19, 22).
- Chauhan, VS, SS Pandey y VK Shukla. “Management of plantar ulcers in Hansen’s disease”. En: *The international journal of lower extremity wounds* 2.3 (2003), págs. 164-167 (vid. pág. 11).
- DAHW Deutsche Lepros- und Tuberkulosehilfe, GERHARD ARMAUER HANSEN: Descubridor del patógeno de la lepra.* [Sitio web]. [Consultado: 12 de Enero de 2023]. Disponible en: <https://www.dahw.de/organisation/geschichte/vorbilder/gerhard-armauer-hansen.html>. (vid. pág. 20).
- DATASMARTS. Jesús. Redes Neuronales Convolucionales en Profundidad.* [Sitio web]. [Consultado: 12 de Enero de 2023]. Disponible en: <https://datasmarts.net/es/redes-neuronales-convolucionales-en-profundidad/> (vid. pág. 26).

Eichelmann, K et al. "Leprosy. An update: definition, pathogenesis, classification, diagnosis, and treatment". En: *Actas Dermo-Sifiliográficas (English Edition)* 104.7 (2013), págs. 554-563 (vid. pág. 21).

Eming, Sabine A, Paul Martin y Marjana Tomic-Canic. "Wound repair and regeneration: mechanisms, signaling, and translation". En: *Science translational medicine* 6.265 (2014), 265sr6-265sr6 (vid. pág. 18).

Etufugh, Chukwuemeka N. y Tania J. Phillips. "Venous ulcers". En: *Clinics in Dermatology* 25.1 (2007), págs. 121-130. DOI: <https://doi.org/10.1016/j.clinidermatol.2006.09.004> (vid. pág. 19).

Fauzi, Mohammad Faizal Ahmad et al. "Computerized segmentation and measurement of chronic wound images". En: *Computers in biology and medicine* 60 (2015), págs. 74-85 (vid. pág. 12).

Field, Charles K. y Morris D. Kerstein. "Overview of wound healing in a moist environment". En: *The American Journal of Surgery* 167.1, Supplement (1994). A Symposium: Wound Infection and Occlusion-Separating Fact from Fiction, S2-S6. DOI: [https://doi.org/10.1016/0002-9610\(94\)90002-7](https://doi.org/10.1016/0002-9610(94)90002-7) (vid. pág. 22).

Gatis, D. *rembg*. <https://github.com/danielgatis/rembg>. 2023 (vid. pág. 49).

Golovko, VA. "Deep learning: an overview and main paradigms". En: *Optical memory and neural networks* 26.1 (2017), págs. 1-17 (vid. pág. 23).

Google, *Contenido de usuario de google: Sanatorio de Contratación E.S.E.* [Sitio web]. [Consultado: 12 de Enero de 2023]. Disponible en: <https://lh5.googleusercontent.com/p/XMpUkpVL0gWY7YQ=w600-h321-p-k-no>. (vid. pág. 21).

- Goyal, Manu et al. "Fully convolutional networks for diabetic foot ulcer segmentation". En: *2017 IEEE international conference on systems, man, and cybernetics (SMC)*. IEEE. 2017, págs. 618-623 (vid. pág. 13).
- Goyal, Manu et al. "Fully convolutional networks for diabetic foot ulcer segmentation". En: *2017 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*. 2017, págs. 618-623. DOI: 10.1109/SMC.2017.8122675 (vid. pág. 61).
- Grzybowski, Andrzej et al. "Gerhard Henrik Armauer Hansen (1841-1912)—The 100th anniversary of the death of the discoverer of *Mycobacterium leprae*". En: *Clinics in Dermatology* 31.5 (2013). Nails and the Clinician, págs. 653-655. DOI: <https://doi.org/10.1016/j.clinidermatol.2012.10.001> (vid. pág. 19).
- Gu, Jiuxiang et al. "Recent advances in convolutional neural networks". En: *Pattern recognition* 77 (2018), págs. 354-377 (vid. pág. 26).
- Guimarães, Heloísa Cristina Quatrini Carvalho Passos et al. "Evidencias científicas sobre las úlceras de piernas como secuela de la lepra". En: 2019 (vid. pág. 21).
- Gupta, Shivani et al. "Chronic wounds: Magnitude, socioeconomic burden and consequences". En: *Wounds Asia* 4 (2021), págs. 8-14 (vid. pág. 11).
- Hsu, Jui-Tse et al. "Chronic wound assessment and infection detection method". En: *BMC medical informatics and decision making* 19.1 (2019), págs. 1-20 (vid. pág. 12).
- Juszczuk, Jan Maria et al. "Wound 3D Geometrical Feature Estimation Using Poisson Reconstruction". En: *IEEE Access* 9 (2021), págs. 7894-7907. DOI: 10.1109/ACCESS.2020.3035125 (vid. pág. 53).

- Kręcichwost, Michał et al. "Chronic wounds multimodal image database". En: *Computerized Medical Imaging and Graphics* 88 (2021), pág. 101844 (vid. pág. 13).
- Las Heras, Kevin et al. "Chronic wounds: Current status, available strategies and emerging therapeutic solutions". En: *Journal of Controlled Release* 328 (2020), págs. 532-550 (vid. págs. 11, 18).
- Leaper, David J et al. "Extending the TIME concept: what have we learned in the past 10 years?*"". En: *International Wound Journal* 9.s2 (2012), págs. 1-19. DOI: <https://doi.org/10.1111/j.1742-481X.2012.01097.x>. eprint: <https://onlinelibrary.wiley.com/doi/pdf/10.1111/j.1742-481X.2012.01097.x> (vid. pág. 22).
- LeCun, Yann, Yoshua Bengio y Geoffrey Hinton. "Deep learning". En: *nature* 521.7553 (2015), págs. 436-444 (vid. pág. 23).
- Lillicrap, Timothy P et al. "Backpropagation and the brain". En: *Nature Reviews Neuroscience* 21.6 (2020), págs. 335-346 (vid. pág. 24).
- Mathew, Amitha, P Amudha y S Sivakumari. "Deep learning techniques: an overview". En: *International conference on advanced machine learning technologies and applications*. Springer. 2020, págs. 599-608 (vid. pág. 24).
- McEwen, Matthew y Tejesh Patel. "Hansen Disease (Leprosy)". En: *Mayo Clinic Proceedings* 95 (nov. de 2020), págs. 2555-2556. DOI: 10.1016/j.mayocp.2020.09.001 (vid. pág. 19).
- Medium. Khuyen, Le. *An overview of VGG16 and NiN models*. [Sitio web]. [Consultado: 15 de Mayo de 2023]. Disponible en: <https://medium.com/mllearning-ai/an-overview-of-vgg16-and-nin-models-96e4bf398484> (vid. pág. 62).

Medium. Kunar, Aditya. *Object Detection with SSD and MobileNet*. [Sitio web]. [Consultado: 12 de Enero de 2023]. Disponible en: <https://adityakunar.medium.com/object-detection-with-ssd-and-mobilenet-aeedc5917ad0> (vid. pág. 28).

Medium. Ronaghan, Stacey. *Deep Learning: Overview of Neurons and Activation Functions*. [Sitio web]. [Consultado: 12 de Enero de 2023]. Disponible en: <https://srnghn.medium.com/deep-learning-overview-of-neurons-and-activation-functions-1d98286cf1e4> (vid. pág. 25).

Minaee, Shervin et al. "Image segmentation using deep learning: A survey". En: *IEEE transactions on pattern analysis and machine intelligence* (2021) (vid. pág. 27).

Monroy, Brayan et al. "Two-step Deep Learning Framework for Chronic Wounds Detection and Segmentation: A Case Study in Colombia". En: *2021 XXIII Symposium on Image, Signal Processing and Artificial Vision (STSIVA)*. IEEE. 2021, págs. 1-6 (vid. págs. 12, 13, 18, 61).

Niri, Rania et al. "Multi-View Data Augmentation to Improve Wound Segmentation on 3D Surface Model by Deep Learning". En: *IEEE Access* 9 (2021), págs. 157628-157638 (vid. pág. 12).

Ochoa, Jesús E. "El lazareto de Boyacá: lepra, medicina, iglesia y Estado 1869-1916. Cómo Colombia fue convertida en la primera potencia leprosa del mundo y Boyacá!, en una inmensa leprosería: Abel Fernando Martínez M". es. En: *Revista Facultad Nacional de Salud Pública* 26 (ene. de 2008), págs. 100 -100 (vid. pág. 20).

Olsson, Maja et al. "The humanistic and economic burden of chronic wounds: A systematic review". En: *Wound Repair and Regeneration* 27.1 (2019), págs. 114-125 (vid. págs. 11, 18).

- Organization, World Health et al. "Global leprosy update, 2013; reducing disease burden". En: *Weekly Epidemiological Record= Relevé épidémiologique hebdomadaire* 89.36 (2014), págs. 389-400 (vid. pág. 21).
- O'Shea, Keiron y Ryan Nash. "An introduction to convolutional neural networks". En: *arXiv preprint arXiv:1511.08458* (2015) (vid. pág. 26).
- Paszke, Adam et al. "Pytorch: An imperative style, high-performance deep learning library". En: *Advances in neural information processing systems* 32 (2019) (vid. pág. 51).
- Qin, Xuebin et al. "U2-Net: Going deeper with nested U-structure for salient object detection". En: *Pattern recognition* 106 (2020), pág. 107404 (vid. pág. 49).
- Ramachandram, Dhanesh et al. "Fully Automated Wound Tissue Segmentation Using Deep Learning on Mobile Devices: Cohort Study". En: *JMIR mHealth and uHealth* 10.4 (2022), e36977 (vid. pág. 12).
- Redmon, Joseph et al. "You only look once: Unified, real-time object detection". En: *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016, págs. 779-788 (vid. pág. 50).
- Ronneberger, Olaf, Philipp Fischer y Thomas Brox. "U-net: Convolutional networks for biomedical image segmentation". En: *International Conference on Medical image computing and computer-assisted intervention*. Springer. 2015, págs. 234-241 (vid. pág. 51).
- Shinnick, Thomas M. "Chapter 11 Hansen disease". En: *Microbiology*. Ed. por E. Edward Bittar y Neville Bittar. Vol. 9. Principles of Medical Biology. Elsevier, 1998,

- págs. 167-174. DOI: [https://doi.org/10.1016/S1569-2582\(97\)80148-1](https://doi.org/10.1016/S1569-2582(97)80148-1) (vid. pág. 20).
- Steed, David L et al. "Guidelines for the treatment of diabetic ulcers". En: (2006) (vid. pág. 19).
- Stojadinovic, Alexander et al. "Topical advances in wound care". En: *Gynecologic oncology* 111.2 (2008), S70-S80 (vid. pág. 18).
- Tkachenko, Maxim et al. *Label Studio: Data labeling software*. Open source software available from <https://github.com/heartexlabs/label-studio>. 2020-2022 (vid. pág. 41).
- Towards Data Science*. Korstanje, Joos. *The F1 score*. [Sitio web]. [Consultado: 13 de Enero de 2023]. Disponible en: <https://towardsdatascience.com/the-f1-score-bec2bbc38aa6> (vid. pág. 36).
- Towards Data Science*. Pramoditha, Rukshan. *The Concept of Artificial Neurons (Perceptrons) in Neural Networks*. [Sitio web]. [Consultado: 12 de Enero de 2023]. Disponible en: <https://towardsdatascience.com/the-concept-of-artificial-neurons-perceptrons-in-neural-networks-fab22249cbfc> (vid. pág. 24).
- Wang, Changhan et al. "A unified framework for automatic wound segmentation and analysis with deep convolutional neural networks". En: *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. 2015, págs. 2415-2418. DOI: 10.1109/EMBC.2015.7318881 (vid. págs. 61, 62).

- Wang, Chien-Yao, Alexey Bochkovskiy y Hong-Yuan Mark Liao. “YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors”. En: *arXiv preprint arXiv:2207.02696* (2022) (vid. pág. 50).
- Wang, Chuanbo et al. “Fully automatic wound segmentation with deep convolutional neural networks”. En: *Scientific reports* 10.1 (2020), págs. 1-9 (vid. pág. 27).
- “Fully automatic wound segmentation with deep convolutional neural networks”. En: *Scientific reports* 10.1 (2020), pág. 21897 (vid. pág. 61).
- Wikipedia. Contratación*. [Sitio web]. [Consultado: 10 de Marzo de 2023]. Disponible en: <https://es.wikipedia.org/wiki/Contrataci%C3%B3n> (vid. pág. 47).
- Yarkony, Gary M. “Pressure ulcers: A review”. En: *Archives of Physical Medicine and Rehabilitation* 75.8 (1994), págs. 908-917. DOI: [https://doi.org/10.1016/0003-9993\(94\)90117-1](https://doi.org/10.1016/0003-9993(94)90117-1) (vid. pág. 19).
- Yazdanpanah, Leila, Morteza Nasiri y Sara Adarvishi. “Literature review on the management of diabetic foot ulcer”. En: *World journal of diabetes* 6.1 (2015), pág. 37 (vid. pág. 12).
- Zou, Zhengxia et al. “Object detection in 20 years: A survey”. En: *arXiv preprint arXiv:1905.05055* (2019) (vid. pág. 27).