

Evaluación de úlceras por presión mediante técnicas de Machine Learning

Alonso M. YUEN DELGADO

Facultad de Ingeniería, Universidad Peruana de Ciencias Aplicadas
Lima, 15088, Perú

Daniel JAUREGUI GONZALES

Facultad de Ingeniería, Universidad Peruana de Ciencias Aplicadas
Lima, 15088, Perú

Daniel SUBAUSTE

Facultad de Ingeniería, Universidad Peruana de Ciencias Aplicadas
Lima, 15088, Perú

Pressure ulcer evaluation using Machine Learning techniques

ABSTRACT: Due to the rise of artificial intelligence and its new trends in machine learning models, several software products have been proposed to benefit the healthcare field. However, it was identified that medical personnel use different tools to evaluate pressure ulcers and diagnose their severity, which present a low degree of reliability. Consequently, we propose a software module with the use of different machine learning techniques, concluding with positive results in the level of diagnosis and reliability. In this article, we propose a convolutional neural networks model that allows to diagnose bedsores by means of captured images and to consult the severity of it in a fast way. For the validations of our proposal, different images of bedsores obtained from sources available on the Internet were used and the classifications of wounds diagnosed by a medical specialist were corroborated, being our proposed model the one in charge of revalidating these results.

Keywords: machine learning, image processing, pressure ulcers, bedsores, convolutional neural networks

RESUMEN: Debido al auge de la inteligencia artificial y sus nuevas tendencias en los modelos de machine learning, se han propuesto varios productos de software para beneficiar al campo de la salud. Sin embargo, se identificó que el personal médico utiliza diversos instrumentos para evaluar las úlceras por presión y diagnosticar su gravedad, los cuales presentan un bajo grado de confiabilidad. En consecuencia, se plantea un módulo de software con el uso de diferentes técnicas de machine learning, concluyendo con resultados positivos a nivel de diagnóstico y fiabilidad. En este artículo, proponemos un modelo de redes neuronales convolucionales que permite diagnosticar las escaras mediante imágenes captadas y consultar la gravedad de ella de forma rápida. Para las validaciones de nuestra propuesta, se utilizaron diferentes imágenes de escaras obtenidas de fuentes disponibles en Internet y se corroborarán las clasificaciones de las heridas diagnosticadas por un médico especialista, siendo nuestro modelo propuesto el encargado de revalidar estos resultados.

Palabras Clave: machine learning, procesamiento de imágenes, úlceras por presión, escaras, redes neuronales convolucionales

1. INTRODUCCIÓN

Actualmente, cada vez se hace más notorio el uso de la inteligencia artificial en el campo de análisis de imágenes, monitoreo de pacientes y el apoyo a las decisiones clínicas tomados por el médico; no obstante, cabe resaltar que la “utilización” de estas herramientas servirá como **asistencia** para el personal médico pero no como reemplazo de ellos [1]. A pesar de esto, existe una preferencia a que estos últimos recurran a diferentes instrumentos de evaluación de las escaras. Aunque siguen en material de estudio, los resultados obtenidos suelen ser poco certeros. Como consecuencia, se observaron que los profesionales de la salud cuestionan los tratamientos a realizar [4]. Por otro lado, se encontraron resultados exitosos para los diagnósticos de etapas de escaras con nivel de detección de más del 70% para imágenes de úlceras por presión [2], también se experimentó con diferentes arquitecturas machine learning, donde se obtuvo el área de interés de la herida con un 90% de fiabilidad para su posterior diagnóstico [3].

De acuerdo con lo mencionado, se propone una solución que permita al equipo médico consultar rápidamente la gravedad en la cual se encuentra la escara y, en base a esto, el especialista en salud será capaz de brindar un tratamiento personalizado al paciente. Esto respalda las decisiones del médico al permitir la temprana detección de la herida y contribuye a la optimización de las terapias recomendadas.

Para los resultados, nuestro modelo propuesto logra validar los diagnósticos a través de imágenes de úlceras por presión de pacientes reales con las etapas confirmadas. En base a esto, se demuestra que nuestro modelo cumple con nuestros objetivos planteados.

El presente documento está organizado de la siguiente manera. Sección 1: Introducción, se exhibe el contexto de nuestro proyecto y las consecuencias que causan las problemáticas. Sección 2: Trabajos relacionados, donde se presentan los antecedentes que motivaron a la creación del modelo de machine learning propuesto. Sección 3: Conceptos Preliminares, conoceremos los conceptos necesarios para el trabajo. Sección 4: Contribución principal, se introducen los detalles que aportaron el uso de nuestro producto. Sección 5: Experimentos, se detallan los pasos para la creación de nuestra solución y las pruebas de validación. Sección 6: Conclusiones, se exponen nuestras recomendaciones para un futuro trabajo.

2. TRABAJOS RELACIONADOS

Para la realización de los diagnósticos de úlceras por presión, los médicos pueden seguir su procedimiento tradicional, tratando directamente al paciente con cuestionarios y escalas [4]. Por ello, proponen diferentes soluciones que ayuden a constatar el diagnóstico de una úlcera ya realizada. En la presente sección, se mencionan diferentes trabajos relacionados que utilizan diferentes técnicas para lograr evaluar las úlceras por presión, de acuerdo a su gravedad, como también indicadores presentados en la herida. Estos estudios presentan diferentes arquitecturas para el procesamiento de imágenes, herramientas que emplean técnicas de machine learning, y, finalmente, las formas de detección de las escaras, así como el impacto que estas generan. En [7], los autores mencionan que existe un aumento en la estancia de las heridas con una complicada cicatrización, donde este conlleva una presión sobre los médicos para realizar los diagnósticos correspondientes. Por ello, los autores proponen cuatro arquitecturas de redes neuronales convolucionales, para la segmentación de las escaras para que la identificación de estas sean más precisas. Para ello, se preparó un conjunto de imágenes, donde se entrenaron dichas imágenes utilizando, SegNet, LinkNet, U-Net y U-Net-VGG16. Posteriormente, los resultados muestran que la arquitectura que logró una mayor precisión fue la U-Net-VGG16 con 0.989% de precisión y un AUC (Área bajo la curva) de 0.998%.

En [8], los autores explican que los métodos para el diagnóstico de las úlceras por presión son altamente invasivos para el paciente, ya que requieren contacto con la herida y estas no llegan a dar un resultado preciso. Por ello, se desarrolló una evaluación automática para el área de la herida, donde se evaluaron tanto sus dimensiones como sus características. Por consiguiente, se utilizó el método ASURA (Automatic Skin Ulcer Region Assessment framework), empleando un dataset de imágenes de úlceras para realizar el aumento de datos necesario para el aprendizaje del modelo. Además, se detallaron las medidas empleadas para garantizar la precisión del ASURA y estimar la densidad en píxeles por centímetros (cm). Todo ello, abarcó una gran presencia y automatización de la densidad de las imágenes para su posterior detección y evitar el constante contacto invasivo hacia la herida.

En [5], los autores implementan una solución de deep learning para una aplicación móvil donde los involucrados (médicos y enfermeros) puedan consultar las características presentadas de la herida y proveer un tratamiento generado por el modelo Inception-ResNet-V2, el cual es una variante de la red neuronal convolucional y junta las ventajas de la arquitectura Inception y las capas residuales de ResNet. Su arquitectura está diseñada para que los enfermeros puedan brindar los detalles de la escara, detectar eritemas y evaluar el tejido necrótico. Con estos datos, se genera un tratamiento personalizado al paciente. Los resultados de este modelo fueron satisfactorios, tanto que los especialistas que no tienen mayor conocimiento de la escara, puedan tratarlos de una manera rápida y eficaz. Esto demuestra que las redes neuronales es una herramienta adecuada para los diagnósticos de diferentes heridas de la piel, ya que a través de imágenes, se puede clasificar de manera correcta y precisa, de acuerdo, a la gravedad de esta.

Otra solución novedosa sería a través de marcos de trabajo para la segmentación de imágenes, los cuales han mostrado buenos resultados. Uno de ellos es el [9], donde los autores presentan un marco de trabajo utilizando redes neuronales profundas (DNN),

MobileNet y un algoritmo personalizado para la detección de escaras. Esto tiene la finalidad de brindar las características de la herida. Este experimento tiene un resultado de un 94% de precisión, lo cual, el modelo determina la escara correctamente, sin embargo, la realización de la arquitectura acabó siendo compleja debido al uso de capas de preprocesamiento de la imagen, procesamiento, algoritmo customizado y al post procesamiento, además que no puede juzgar una imagen de escara con otras características adicionales (fondo de la imagen).

Por otro lado, se encuentran diferentes maneras de abordar los problemas de detección de escaras y brindar mejores resultados. Garcia-Zapirain et al. [6] desarrollaron un sistema automatizado para la segmentación de escaras de grado 3 y 4. Dicho sistema se encarga de extraer el ROI (área de interés) de una imagen a color convertido a dos tipos de imágenes (HSI, Desenfoque gaussiano), donde se reduce el impacto de los cambios de iluminación y otro para la disminución del ruido. Por último, se traslada a otro modelo CNN para la segmentación de tejidos Utilizando un modelo CNN 3D personalizado llamado DeepMedic, donde se extrae la imagen segmentada en diferentes etiquetas: el fondo de la imagen, escara necrótica, granulación y células muertas acumuladas en el exudado de la herida. Los resultados de estos experimentos son exitosos, ya que tiene un valor AUC de 95%, en otras palabras, su sistema es capaz de segmentar correctamente los tejidos con escaras.

3. CONCEPTOS PRELIMINARES

A partir de esta sección, los principales conceptos utilizados para el trabajo, tienen relación con las úlceras por presión y, principalmente, con la inteligencia artificial y su implementación, utilizando una de sus técnicas.

3.1. Úlceras por presión (UPP)

Este tipo de lesiones de piel son provocados por una presión constante sobre una prominencia ósea en un área del cuerpo humano. Una fuerza continua causa el impedimento del líquido linfático y aumento de los desechos debido al fluido intersticial, desarrollándose las úlceras por presión [11]. En nuestra sociedad, prevalecen con fuerza en los sistemas públicos de salud, encontrándose que los casos con más registros fueron en UCI y de pacientes en cirugía [12].

Para la clasificación de nuestra solución para las úlceras por presión, estamos enfocándonos en las pautas declaradas por la NPUAP (National Pressure Ulcer Advisory Panel) para la determinación de la gravedad de ella [2].

3.2. Redes Neuronales Convolucionales (CNN)

Son una clase de redes neuronales profundas en el campo de machine learning, son mayormente utilizadas para los campos de detección de objetos, clasificación de imágenes y reconocimiento, segmentación de clases, etc. Este tipo de herramienta se conforma de capas de convolución y clasificación para la extracción de características con el fin que pueda “aprender” y clasificar con un alto grado de precisión. [13]

Se encuentra diferentes arquitecturas para el uso de redes neuronales convolucionales que lograron un buen rendimiento en el desafío de reconocimiento visual de ImageNet (ILSVRC) como es la arquitectura VGG creado por ‘Visual Geometry Group’ en 2014 y el modelo ResNet propuesto en el año 2015, donde este último demostró buenos resultados respecto a las otras arquitecturas gracias a los “bloques residuales” que conforman en este modelo.[14]

3.3. Tensorflow

Tensorflow es una plataforma de Deep Learning de las principales en el mundo. Mantiene un modelo Open Source de Google, con una comunidad de desarrolladores que lo han posicionado como la herramienta líder en el sector de Deep Learning. Asimismo, esta plataforma tiene como fin el de construir y entrenar las redes neuronales, que permiten descifrar patrones y correlaciones usados por los usuarios para su uso respectivo. [10]

4. CONTRIBUCIÓN PRINCIPAL

4.1. Adquisición de datos

Para la recolección de muestras de úlceras por presión, se realizó una búsqueda de datasets relacionados con escaras etiquetadas por diferentes fuentes. Estas muestras se obtuvieron a partir de un conjunto de imágenes públicas llamadas “Pressure Injury Images Dataset” (PIID) que se encuentra conformado por un total de 1091 imágenes a color procesados a una resolución de 299x299 píxeles. Estos se encuentran clasificados en 4 etapas concordando con el protocolo correspondiente, Ver Tabla 1 [2]. Este dataset se encuentra publicado en el siguiente enlace: <https://github.com/FU-MedicalAI/PIID>

Tabla 1
DISTRIBUCIÓN DE MUESTRAS DE ÚLCERAS POR PRESIÓN POR ETAPAS

Etapas	Total de muestras
Etapas 1	230
Etapas 2	313
Etapas 3	275
Etapas 4	273
Total	1091

Luego, creamos un ambiente de trabajo con el lenguaje de programación Python 3.10.9 donde importamos los paquetes necesarios de Tensorflow 2.8 que viene con la API (Interfaz de Programación de Aplicaciones) de Keras. Esto nos ayuda a la implementación de un modelo base donde agregaremos una capa personalizada para la clasificación de las escaras.

4.2. Preprocesamiento de imágenes

Después de la adquisición de las muestras de úlceras por presión, se utilizó la técnica de aumento de datos para incrementar el número de muestras a través de las técnicas de aumento y disminución del brillo de la imagen, trasladando el contenido de la imagen; y volteando la imagen misma. Esto se realizó generándose 9 imágenes por muestra con un total de 11030 resultados, categorizados en 4 etapas. Ver Tabla 2.

Tabla 2
DISTRIBUCIÓN DE MUESTRAS DE ÚLCERAS POR PRESIÓN POR ETAPAS CON LA TÉCNICA DE AUMENTO DE DATOS

Etapas	Total de muestras
Etapas 1	2716
Etapas 2	2817
Etapas 3	2750
Etapas 4	2730
Total	11030

Concluido con la distribución de muestras, se procede a cargar los datos para el proceso de normalización, donde cada valor en coeficiente de RGB (Rojo, Verde, Azul) de la imagen conformado en un rango de [0,255], se transforma a un rango del 0 a 1. Después, se realizó la particiones de las imágenes para cada conjunto de entrenamiento y prueba con un porcentaje del 80% y 20% respectivamente del total de imágenes del Cuadro II. Además de eso, se estableció el valor del batch en 16 con las imágenes reescaladas a 224x224 píxeles [2].

4.3. Implementación del modelo CNN

Se utiliza, un modelo base de redes neuronales convolucionales ya precargada del paquete de Keras, siendo la arquitectura apropiada la de ResNet50v2; esto es debido a que se obtuvieron buenos resultados en precisión: 74.65%; y además que cuenta, a través de la matrix de confusión, un valor del “área bajo la curva” (AUC) de un 92%. Esto significa que esta arquitectura desempeña adecuadamente para la clasificación de escaras [2]. Asimismo, se utiliza la técnica de Transferencia de Aprendizaje para cargar los pesos del modelo base pre-entrenado de la base de datos de ImageNet[13] y se congelan estos pesos para que no puedan modificarse durante el proceso del entrenamiento; pero se actualizarán las últimas capas de la Figura 1.




Figura 1. Últimas capas del modelo CNN

Además del modelo base, se utiliza la operación de “GlobalAveragePooling2d” y con la técnica de “Dropout” configurado a un 20% para evitar el sobreajuste. Por otro lado, se establece un factor de aprendizaje de un 0.0001 y con un tamaño del “batch” de 16; y un total de 300 generaciones. Por último, se utiliza la técnica de detención temprana o **Early Stopping** con un valor de paciencia de 15 generaciones, monitoreando la métrica del “val_loss” que es la tasa de pérdida para el conjunto de datos de validación. Respecto a este último, significa que está monitoreándose este valor después de cada 15 generaciones y guarda el mejor modelo hasta ese momento, si no existe alguna mejora posible.

5. EXPERIMENTOS Y RESULTADOS

5.1. Protocolos de experimentación

En esta sección, se discute sobre los experimentos y los resultados del sistema de clasificación desarrollado. En primer lugar, el proceso se realiza en un entorno virtual donde utilizamos las herramientas de Tensorflow 2.8 junto con al API de Keras y

el lenguaje de programación Python 3.10. Los experimentos se desarrollaron en una computadora local con una GTX 1650 GPU de 4GB VRAM, 8GB RAM 3200Mhz junto con un Intel Core I5 11320H. Debido a que contamos con una tarjeta gráfica, podemos hacer uso de ella para minimizar las cargas de trabajo y aumentar la productividad y desarrollo, tanto de la implementación como experimentos.

Para un sistema de clasificación de este tipo, la medición de rendimiento se basa en las métricas clásicas de la **precisión**, **recall** y **f1-score** que se sustenta del desarrollo de clasificación del sistema en un conjunto de pruebas. Como también, se utiliza los valores de **Verdaderos positivos (VP)**, **Verdaderos negativos (VN)**, **Falsos Positivos (FP)** y **Falsos Negativos (FN)**.

5.2. Adquisición de datos de prueba

Se recolectó una serie de muestras de úlceras por presión obtenidas de la base de datos de “Medetec” [15] y algunos de “Google Images” y se logró obtener un conjunto de pruebas de 100 muestras sin clasificar. Debido a esto, se solicitó a infectólogos y dermatólogos a realizar el proceso de clasificar las escaras mediante la visualización de estas en un cuestionario, cuyas opciones eran las etapas que presentaba cada herida. Asimismo, para los experimentos con el sistema de clasificación, cada muestra del conjunto se normalizó para que el modelo pueda interpretarlas mejor y se reescaló a los tamaños adecuados (224x224 píxeles). En la siguiente Figura 2, se muestra un ejemplo del dataset de pruebas.




Figura 2. Muestra del conjunto de datos

5.3. Resultados

Posteriormente, cada muestra se valida con el modelo de CNN y, finalmente, se obtiene la matriz de confusión, donde se visualizan las predicciones realizadas por esta solución. Además, a partir de esto, se calcula las métricas de la precisión, recall, f1-score de nuestro sistema de clasificación. En la siguiente Figura 3, podemos observar la matriz normalizada y visualizar la cantidad de muestras que se clasificaron correctamente.

Utilizamos el paquete de scikit-learn[16] para el desarrollo de la matriz de confusión, como también de las métricas que vamos a brindar.

En nuestro conjunto de pruebas, aunque la información esté desbalanceada, el sistema logró re-validar las muestras de úlceras por presión, clasificando correctamente las etapas verdaderas.

	1	2	3	4
1	9 (1.00)	0 (0.00)	0 (0.00)	0 (0.00)
2	5 (0.17)	20 (0.69)	1 (0.03)	3 (0.10)
3	1 (0.05)	1 (0.05)	9 (0.47)	8 (0.42)
4	1 (0.02)	2 (0.05)	3 (0.07)	37 (0.86)
	1	2	3	4
	predicted label			

Figura 3. Matriz de confusión del sistema desarrollado en datos de prueba

Analizando la Figura 3 se observa que se encuentra un pequeño margen de error debido a que un rango de [1-5] muestras se clasificaron incorrectamente. En términos cuantitativos, la exactitud del sistema de clasificación fue de un 75% del total de muestras.

A continuación, se presentan las ecuaciones de las métricas que se visualizarán.

$$Precision = \frac{VP}{(VP + FP)} \quad (1)$$

$$Recall = \frac{VP}{(VP + FN)} \quad (2)$$

$$F1 - score = 2 * \frac{Precision + Recall}{Precision * Recall} \quad (3)$$

$$Exactitud = \frac{(VP + VN)}{VP + VN + FP + FN} \quad (4)$$

En la Tabla 3, se visualizan los valores para cada métrica por diferente tipo de etapa. Para la Etapa 1, se obtuvo una precisión del 56%, sin embargo, se tiene un alto Recall; por lo tanto, para F1-Score, se tiene un 72% que el sistema clasifica respecto para este tipo de etapa. Para la etapa 2, visualizamos una alta precisión, con un 87%, pero con un Recall de 69%; por lo tanto, se tiene un valor de f1-score, 77%. Dado que nuestro modelo estará enfocado en el dominio médico, se obtuvieron buenos resultados; no obstante, es mejorable, ya que se debe

de enfocar a la maximización de la precisión del sistema. Esto mejorará en una próxima versión del sistema con el modelo CNN con más datos de entrenamiento, análisis y ajustes de los hiperparámetros para el desarrollo y realización de pruebas con el mismo conjunto de datos obtenidos.

Tabla 3
RESULTADOS DEL SISTEMA DE CLASIFICACIÓN OBTENIDOS

Etapas	Precisión	Recall	F1-score
1	0.5625	1.0000	0.7200
2	0.8696	0.6897	0.7692
3	0.6923	0.4737	0.5625
4	0.7708	0.8605	0.8132

Por último, en los trabajos mencionados, se resalta el valor del AUC donde es la capacidad que tiene el sistema de distinguir entre las diferentes etapas. De acuerdo al sistema propuesto, nuestro sistema tiene un valor AUC del 83 %, esto significa que es capaz de distinguir entre las etapas de úlceras por presión y clasificar de manera correcta.

Adicionalmente, se visualiza una matriz de confusión (Ver Figura 4) para las muestras del validación utilizadas durante el proceso de entrenamiento, donde se obtuvo una precisión de más del 90%.




Figura 4. Matriz de confusión del sistema desarrollado en datos de validación

6. CONCLUSIONES

Como parte de las conclusiones, hemos propuesto la implementación de un sistema de clasificación basado en la herramienta de “Deep Learning” que son las redes neuronales convolucionales (CNN) para el diagnóstico de etapas de úlceras por presión (UPP). Por ello, se utilizó RestNet50v2 como parte de la arquitectura del CNN y se validó los resultados obtenidos con un conjunto de 100 muestras clasificadas, donde el modelo

propuesto logró re-validar correctamente los diagnósticos de los médicos en un 75% de exactitud. Esto se realizó, como consecuencia a la utilización de técnicas como son el aumento de datos, transferencia de aprendizaje por el uso del dataset de “ImageNet” para RestNet50v2 y por último, congelar el modelo base donde se entrena las últimas capas del sistema para retornar los resultados del diagnóstico. Por ello, se obtiene la matriz de confusión del sistema de clasificación, donde se concluye que, para cada etapa, se logra evaluar las muestras satisfactoriamente. Por otro lado, de acuerdo a los valores de cada métrica (precisión, recall y f1-score), evidencia que el modelo es mejorable, ya que se debe aumentar los resultados de precisión en las etapas 1 y 3, debido al contexto que está enfocado nuestra investigación. Para el trabajo a futuro, se proyectará el proceso de mejora en el modelo propuesto con el aumento de datos de entrenamiento, el establecimiento de hiperparámetros adecuados para el proceso de este último; y, finalmente, la inclusión de un posible modelo “You Only Look Once” (YOLO) [17] para la detección de este tipo de heridas, donde se obtendrá el área de interés de la lesión y aumentar las evaluaciones de precisión en el sistema de clasificación propuesto.

7. REFERENCIAS

- [1] Bohr, A., & Memarzadeh, K. (2020). The rise of artificial intelligence in healthcare applications. Elsevier eBooks, 25-60. <https://doi.org/10.1016/b978-0-12-818438-7.00002-2>
- [2] Ay, Betul, et al. “Deep transfer learning-based visual classification of pressure injuries stages”. Neural Computing and Applications (2022): 1-12.
- [3] Ohura, N., Mitsuno, R., Sakisaka, M., Terabe, Y., Morishige, Y., Uchiyama, A., Okoshi, T., Shinji, I., & Takushima, A. (2018). Convolutional neural networks for wound detection: the role of artificial intelligence in wound care. American Journal of Critical Care.
- [4] Dolores López, M. F., & Pancorbo Hidalgo, P. L. (2018). Instrumentos de medición de los conocimientos sobre prevención de úlceras por presión: revisión de la literatura. Scielo, 30(2), 98-106. <https://scielo.isciii.es/pdf/geroko/v30n2/1134-928X-geroko-30-02-98.pdf>
- [5] Liu, T. J., Christian, M., Chu, Y. C., Chen, Y. C., Chang, C. W., Lai, F., & Tai, H. C. (2022). A pressure ulcers assessment system for diagnosis and decision making using convolutional neural networks. Journal of the Formosan Medical Association. <https://doi.org/10.1016/j.jfma.2022.04.010>
- [6] Garcia-Zapirain, B., Elmogy, M., El-Baz, A., & Elmaghraby, A. (2018). Classification of pressure ulcer tissues with 3D convolutional neural network. Medical & Biological Engineering & Computing, 56(12), 2245-2258. <https://doi.org/10.1007/s11517-018-1835-y>
- [7] Ohura, N., Mitsuno, R., Sakisaka, M., Terabe, Y., Morishige, Y., Uchiyama, A., Okoshi, T., Shinji, I., & Takushima, A. (2019). Convolutional neural networks for wound detection: the role of artificial intelligence in wound care. Journal of Wound Care, 28(Sup10), S13-S24. <https://doi.org/10.12968/jowc.2019.28.sup10.s13>
- [8] Chino, D. Y. T., Scabora, L. C., Cazzolato, M. T., Jorge, A., Traina-Jr, C., & Traina, A. J. M. (2020). Segmenting skin ulcers and measuring the wound area using deep convolutional networks. Computer Methods and Programs in Biomedicine, 191, 105376. <https://doi.org/10.1016/j.cmpb.2020.105376>
- [9] Li, F., Wang, C., Liu, X., Peng, Y., & Jin, S. (2018). A Composite Model of Wound Segmentation Based on Traditional Methods and Deep Neural Networks. Compu-

- tational Intelligence and Neuroscience, 2018, 4149103. <https://doi.org/10.1155/2018/4149103>
- [10] Buhigas, J. (2018, 14 febrero). Todo lo que necesitas saber sobre TensorFlow, la plataforma para Inteligencia Artificial de Google – Puentes Digitales. Puentes Digitales. Recuperado 3 de septiembre de 2022, de <https://puentesdigitales.com/2018/02/14/todo-lo-que-necesitas-saber-sobre-tensorflow-la-plataforma-para-inteligencia-artificial-de-google/>
- [11] Boyko, T. v., Longaker, M. T., & Yang, G. P. (2018). Review of the Current Management of Pressure Ulcers. In *Advances in Wound Care* (Vol. 7, Issue 2, pp. 57–67). <https://doi.org/10.1089/wound.2016.0697>
- [12] Flores-Lara, Y., Rojas-Jaimes, J., & Jurado-Rosales, J. (2020). Frecuencia de úlceras por presión y los factores asociados a su presentación, en pacientes de un hospital nacional de Lima, Perú. *Revista Medica Herediana*, 31(3), 164–168. <https://doi.org/10.20453/rmh.v31i3.3805>
- [13] Liu, T. J., Christian, M., Chu, Y. C., Chen, Y. C., Chang, C. W., Lai, F., & Tai, H. C. (2022). A pressure ulcers assessment system for diagnosis and decision making using convolutional neural networks. *Journal of the Formosan Medical Association*, 121(11), 2227–2236. <https://doi.org/10.1016/J.JFMA.2022.04.010>
- [14] He, K., Zhang, X., Ren, S., Sun, J. (2015). Deep Residual Learning for Image Recognition. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2016–December, 770–778. <https://doi.org/10.1109/CVPR.2016.90>
- [15] Thomas, S. (2014, 6 febrero). PRESSURE ULCER IMAGES. Medetec. Recuperado el 6 de mayo del 2023 de <http://www.medetec.co.uk/slide%20scans/pressure-ulcer-images-b/index.html>
- [16] Rédac, T. (2022, September 1). Scikit-Learn: Descubre la biblioteca de Python dedicada al Machine Learning. *Formation Data Science — DataScientest.com*. <https://datascientest.com/es/scikit-learn-decubre-la-biblioteca-python>
- [17] Ultralytics. (s. f.). Comprehensive Guide to Ultralytics YOLOv5. Ultralytics YOLOv8 Docs. <https://docs.ultralytics.com/yolov5/>