

Modelos de analítica de datos aplicado a la Detección de Úlceras por Presión en Pacientes Hospitalizados

Natalia Andrea González Medrano

Trabajo Dirigido

Tutores

**Ing. Pedro Antonio Aya Parra
Ing. Jefferson Steven Sarmiento Rojas**



**UNIVERSIDAD DEL ROSARIO
ESCUELA COLOMBIANA DE INGENIERÍA JULIO GARAVITO
PROGRAMA DE INGENIERÍA BIOMÉDICA
BOGOTÁ D.C**

AGRADECIMIENTOS

Principalmente le doy gracias a Dios por guiarme y por ser el pilar de mi vida. Quiero agradecerles a mis padres ya que sin ellos esto no podría ser posible, por darme su confianza y apoyo al querer estudiar esta carrera, gracias a ellos por estar pendientes de mí y tener paciencia a pesar de obstáculos presentados a lo largo de la carrera. Agradezco a mis hermanas mayores por su apoyo, por su ánimo, por estar en momentos de crisis y en momentos de felicidad.

Agradezco a mis directores de tesis el ingeniero **Pedro Antonio Aya Parra** y al ingeniero **Jefferson Steven Sarmiento** por las horas dedicadas a mi trabajo de grado, por estar siempre pendientes de mis consultas y dudas, gracias porque sin ello no podría optar el título de ingeniera Biomédica. Los aportes y la exigencia que depositaron en esta investigación me han engrandecido y beneficiado no solo para mi desempeño académico y profesional si no al crecer a nivel personal.

Por otra parte, también agradezco a mis compañeros de clase, Natalia Ochoa, Paula Acosta, Daniela Calvache, Clara Martinez, por su apoyo, por su amistad, por su ánimo, por estar siempre presente cuando se presentaba algún problema universitario, y porque a pesar de los inconvenientes externos, siempre nos hemos mantenido unidos.

TABLA DE CONTENIDO

1. INTRODUCCIÓN	8
1.1 Historia Úlceras por presión	8
1.2 Úlceras por presión.....	11
1.2.1 Factores según la posición	11
1.2.2 Factores de Riesgo.....	13
1.2.3 Complicaciones.....	14
1.3 Inteligencia Artificial en salud	15
1.3.1 Inteligencia artificial en el reconocimiento de imágenes	17
1.3.2 Inteligencia artificial en medicina oncológica	17
1.3.3 Inteligencia artificial en oftalmología.....	17
1.3.4 Inteligencia artificial en la farmacología.....	17
1.3.5 Inteligencia artificial para el tratamiento de la diabetes	18
2. OBJETIVOS	20
2.1. General	20
2.2. Específicos.....	20
3. METODOLOGÍA.....	21
3.1 Definición de la problemática	21
3.2 Adquisición de datos.....	22
3.3 Preprocesamiento de datos.....	23
3.4 Fase de detección y segmentación.....	24
3.5 Métodos para detección de úlceras por presión	25
3.5.1 Redes Neuronales Convolucionales (CNN)	26
4. RESULTADOS	34
4.1 Preprocesamiento de imágenes.....	34
4.1.2 Ajuste del tamaño de las imágenes:.....	34
4.1.3 División de imágenes para segmentación:.....	34
4.2 Fase de detección y segmentación.....	35
4.3 Métodos para detección de úlceras por presión	36
4.3.1 Método enfocado a segmentación de imágenes	36
4.3.2 Método enfocado a clasificación de imágenes.....	38
5. DISCUSIÓN	44
5.1 Método enfocado a segmentación de imágenes	44
5.2 Método enfocado a clasificación de imágenes	46

5.2.3 Conjunto 1	47
5.2.2 Conjunto 2	47
5.2.3 Conjunto 3	47
5.2.4 Conjunto 4	48
6. RECOMENDACIONES Y TRABAJOS FUTUROS	49
7. CONCLUSIONES.....	50
8. BIBLIOGRAFÍA	51
ANEXOS	53
Algoritmo “Resize Images”	53
Algoritmo “Segmentación imágenes”	54
Algoritmo “Visualizar segmentación”	55
Algoritmo “Detección de úlceras por presión”	56

LISTA DE TABLAS

Tabla 1. Escala de Norton.....	14
Tabla 2. Datos de la primera convolución.....	30
Tabla 3. Datos de la segunda convolución.....	31
Tabla 4. Datos de la tercera convolución.....	31
Tabla 5. Ejemplo archivo “.csv”.....	36
Tabla 6. Parámetros de entrenamiento.....	37
Tabla 7. Datos de entrenamiento.....	37
Tabla 8. Datos.....	38
Tabla 9. Paquetes de datos.....	39
Tabla 10. Modelos entrenados.....	39
Tabla 11. Matriz de confusión.....	39
Tabla 12. Resultado matriz de confusión Train.....	39
Tabla 13. Resultado matriz de confusión Test.....	40
Tabla 14. Modelos entrenados.....	40
Tabla 15. Matriz de confusión.....	40
Tabla 16. Resultado matriz de confusión Train.....	40
Tabla 17. Resultado matriz de confusión Test.....	41
Tabla 18. Modelos entrenados.....	41
Tabla 19. Matriz de confusión.....	41
Tabla 20. Resultado matriz de confusión Train.....	41
Tabla 21. Resultado matriz de confusión Test.....	42
Tabla 22. Modelos entrenados.....	42
Tabla 23. Matriz de confusión.....	42
Tabla 24. Resultado matriz de confusión Train.....	42
Tabla 25. Resultado matriz de confusión Test.....	43

LISTA DE FIGURAS

Figura 1. Fuerzas de presión	12
Figura 2. Fuerza de fricción.....	12
Figura 3. Posición Flower.....	12
Figura 4. Inteligencia artificial, Machine learning, deep learning	16
Figura 5. Modelo Redes Neuronales	19
Figura 6. Metodología, Clasificador de úlceras por presión.	21
Figura 7. Etapas clínicas de las úlceras por presión.	23
Figura 8. Segmentación imágenes úlceras por presión.	25
Figura 9. Píxeles en imagen.....	26
Figura 10. Imagen RGB	27
Figura 11. Imagen de entrada y matriz kernel	27
Figura 12. Capa oculta de neuronas.....	28
Figura 13. La imagen realiza una convolución	28
Figura 14. Muestreo SUBSAMPLING.....	29
Figura 15. Primera convolución	30
Figura 16. Segunda convolución.....	31
Figura 17. Arquitectura de una Red Neuronal Convolutiva	32
Figura 18. Estructura de una FCN	32
Figura 19. Parche de úlcera por presión.....	33
Figura 20. Arquitectura ResNet50.....	33
Figura 21. Imagen reduciendo el tamaño	34
Figura 22. Detección, delineado y máscara de la imagen	35
Figura 23. Imagen de entrada y salida de los modelos entrenados	38
Figura 24. Modelos de entrenamiento	45

LISTA DE ANEXOS.

Anexo 1. Algoritmo “Resize Images”.....	53
Anexo 2. Algoritmo “Segmentación imágenes”	54
Anexo 3. Algoritmo “Visualizar segmentación”	55
Anexo 4. Algoritmo “Detección de úlceras por presión”	56

1. INTRODUCCIÓN

En este trabajo se dará a conocer sobre que son y que causan las úlceras por presión (UPP), también se expondrá una medida para disminuir las úlceras por presión. En primera instancia, las úlceras por presión son lesiones en la piel de origen isquémico, con pérdida de sustancia cutánea producida por presión prolongada o fricción entre dos planos duros. Son un problema grave y frecuente en personas de edad avanzada, representan una de las principales complicaciones de las situaciones de inmovilidad y su manejo adecuado constituye un indicador de calidad asistencial. [1]

La incidencia y prevalencia de las UPP varía ampliamente dependiendo de su ubicación. Diversos estudios estiman que entre un 3-11% de los pacientes que ingresan en los hospitales desarrollan UPP y cerca del 70% de éstas se producen en las primeras dos semanas de hospitalización. La incidencia de UPP en la comunidad se cifra en 1,7% anual en edades comprendidas entre los 55-69 años y 3,3% entre 70-75 años. En las residencias asistidas oscila en torno al 9,5% en el primer mes de estancia, y hasta el 20,4% a los dos años. Los pacientes con UPP tienen una mortalidad hospitalaria del 23-27%, y el riesgo de muerte aumenta de 2 a 5 veces en las residencias asistidas. Por tanto, el mejor cuidado de las UPP es su prevención, estimándose que al menos el 95% de las mismas son evitables. [2][3]

Las UPP también representan problemas, no solo para las personas que la padece, sino también genera problemas en la sociedad y en el propio sistema de salud.

- **A nivel mundial**
 - Afectan en la calidad de vida.
 - Disminución de la autonomía y autoestima.
 - Riesgo elevado de complicaciones directas e indirectas en el estado de salud.
 - Potenciales estados invalidantes generadores de dependencia e institucionalización.
 - Aumento del riesgo de morir por esa causa y posibilidad de muertes prematuras.
- **Para la sociedad**
 - Incapacidad para la actividad laboral.
 - Atentado contra los derechos de sus ciudadanos al permitir en algunos casos que se produzcan (a sabiendas de cómo evitar la mayor parte de estas situaciones) o se prolonguen innecesariamente por una inadecuada atención.
- **Para el sistema de salud**
 - Elevado coste de su atención (recursos humanos y materiales; espacios asistenciales, hospitalizaciones e intervenciones, rehabilitación, etc.)
 - Posibles problemas de salud pública derivados de la diseminación de gérmenes multirresistentes.
 - Repercusiones legales, para instituciones y profesionales, por inadecuada o inexistente prevención y tratamiento. [4]

1.1 Historia Úlceras por presión

Como cualquier lesión o herida, existe una evolución para su tratamiento y proceso de sanación. En los distintos periodos de la historia, el cuidado de las personas ha ofrecido

una especial importancia al individuo que le impedía moverse y debía permanecer en cama durante largo tiempo. El estigma de las UPP como consecuencia menos deseada en esa situación ha sido uno de los problemas habituales en los cuidadores en cualquier civilización.

Las UPP, dentro de las heridas crónicas, van incluidas en la historia desde la antigüedad, del recorrido humano afectando a todos los individuos, durante todos los periodos históricos, porque estas lesiones no entienden de posiciones, sin distinción social ni de situaciones personales, por lo que nadie se ha librado de padecerlas.

La presencia de las enfermedades en la antigüedad se ven confirmados por los hallazgos paleopatológicos, contribuyendo a la comprensión de cómo la enfermedad. Al igual que todos los seres vivos, ha variado en el transcurso de los milenios desde el inicio de la vida el planeta. Para ser más claros, la paleopatología describe lesiones de los faraones en Egipto a partir de los restos bien conservados de momias que presentaban restos de superficies similares a escaras en nalgas y espalda, disimuladas durante el proceso de momificación con una fina piel de gacela.

Si bien, las UPP como lesión producida en procesos de enfermedad, no es uno de los temas principales de la paleopatología, sí que, a través de los textos narrativos de la historia, aparecen referencias sobre diferentes úlceras, tanto en la Biblia, como en papiros egipcios y textos griegos para la transmisión del conocimiento.

Existen diversos papiros egipcios que definen el abordaje de lesiones cutáneas según:

- Smith (1500 A.C.): libro procedente de Tebas, sobre las heridas, técnicas de vendaje, reducción entablillamiento y suturas, cuidados de la piel.
- Ebers (1550 A.C.): procedente de Tebas “cuidados de la piel, cabello, dientes, lengua”. Consideraciones sobre la salud, la vida y la enfermedad, usos del aceite de castor, de ricino y trementina.
- Hearst (1550 A.C.): procedente de Deir el Ballas “cuidado de quemaduras y cuidados tras el postramiento producido por las heridas”.
- Chester Beatty (1300 A.C.) hechizos relacionados con los cuidados.

Durante largos siglos la UPP ha sido denostada e infravalorada exceptuando excepciones como el alemán Fabricius Hildanus (1560-1634), (padre de la cirugía alemana y representante importante de la iatromecánica, movimiento que propone la aplicación de la física, más concretamente la mecánica y la matemática a la medicina), describió en el siglo XVI las características clínicas de las úlceras por presión, identificando factores naturales externos e internos como causas de interrupción de sangre y nutrientes de las UPP. [4]

Varios autores en el siglo XIX plasmaron en sus artículos la conexión de úlcera por presión con encamamiento y la relación que conlleva esta lesión con sufrimiento y aumento en la carga de trabajo:

- W. Heberden (Londres 1710-1801) autor de “Commentarii de morborum historia et curatione” afirma: “Deplora la condición desgraciada de los que, siendo postrados

en cama a través de accidente o por cuidados, han contraído úlceras de una clase muy dolorosa y peligrosa”.

- Jean Martin Charcot (París 1825-1893) autor de diferentes tratados definió la inevitabilidad de las úlceras por decúbito en pacientes encamados por lesiones neurológicas.

El último tercio del siglo XIX, Florence Nightingale, considerada iniciadora de la enfermería moderna, en su libro “Notas sobre Enfermería” (Notes on Nursing), reconoce de forma inequívoca la responsabilidad de las enfermeras en la prevención de UPP, manteniendo que éstas podían ser evitadas mediante unos buenos cuidados de enfermería: “Si un paciente tiene frío o fiebre, o está mareado, o tiene una escara, la culpa, generalmente, no es de la enfermedad, sino de la enfermería”.

Durante el Siglo XX y a consecuencia de las dos guerras mundiales, una gran cantidad de soldados heridos con lesiones medulares y que a su vez desarrollaron úlceras por presión, hizo que por primera vez se planteasen cuestiones y dudas sobre la afianzada “inevitabilidad” de estas lesiones, expuesta desde Charcot en el siglo XIX, y a las que se prestaba poca atención o se daban por supuestas en el estado general de los pacientes, practicando el “Nihilismo terapéutico” (negar intervenciones terapéuticas a personas mayores o dependientes fundamentándose en justificaciones del tipo: “como es mayor, ya no hay nada que hacer”, “ahora ya, qué se va a hacer...”, “ya no merece la pena”), mantenido en los siglos anteriores y continuado durante gran parte del siglo XX. [5]

La mejora en el abordaje preventivo y terapéutico de las UPP viene de la mano de diferentes entidades y asociaciones científicas que a finales del siglo XX iniciaran su andadura para el cuidado de las Úlceras por Presión y Heridas Crónicas.

En España, la creación en 1994 del Grupo Nacional para el Estudio y Asesoramiento en Úlceras por Presión y Heridas Crónicas (GNEAUPP), marca un antes y un después en la evolución del cuidado de estas lesiones. El GNEAUPP es un grupo interdisciplinar, independiente que aglutina a diferentes tipos de profesionales interesados en las UPP y las heridas crónicas que tiene como principales objetivos:

Acentuar el problema de las UPP y otras heridas crónicas en nuestro medio y concienciar a la sociedad ante estos importantes problemas de salud para conseguir disminuir su incidencia y prevalencia.

Colaborar, discutir y difundir el conocimiento científico que permita a los diferentes profesionales implicados en la atención a las UPP y otras heridas crónicas desarrollar una práctica asistencial integral basada en las últimas evidencias científicas contribuyendo al mejor desarrollo del estudio y de la investigación en la prevención y el tratamiento de las heridas crónicas. [5]

- Asesorar a pacientes, cuidadores familiares, profesionales, otros grupos científicos, empresas farmacéuticas y entidades públicas o privadas, españolas o extranjeras, haciendo visible lo que era invisible o se tapaba.
- Organizar jornadas, actos, conferencias y cualquier evento dirigido a la formación y divulgación entre los profesionales de la salud y la sociedad en general, de la

importancia de las heridas crónicas como problema de salud y los avances de la investigación en su prevención y tratamiento.

- Mejorar la salud y la calidad de vida de los pacientes con heridas crónicas y de sus cuidadores a través del fomento de los cuidados de prevención y de la mejora de los tratamientos dispensados.

Como refieren Soldevilla et al (2004), a pesar de todo, todavía “Las UPP siguen siendo hoy en día un problema importante que afecta a personas atendidas en todos los niveles asistenciales, especialmente ancianos, discapacitados, enfermos en situación terminal de su enfermedad, etc.; confiamos en que el avance en el conocimiento de las ciencias de la salud y de la dimensión real que obran las úlceras por presión en nuestro panorama, desbanque a este proceso de una subestimación y generen cambios rotundos, tanto en su dimensión clínica implicando a todos los profesionales del equipo interdisciplinar de atención de salud, como en otras dimensiones tales como la gestión de los responsables sanitarios y sociales”. [5]

1.2 Úlceras por presión

Para evitar y tratar las úlceras por presión, es necesario entender como y porque se genera este tipo de lesión. Como ya se ha dicho antes, se debe tener en cuenta que las úlceras por presión se producen como consecuencia de la presión tisular entre una prominencia ósea y la superficie externa durante un período prolongado.

La presión capilar máxima se cifra en torno a los 20 mm Hg, y la presión tisular media entre los 16-33 mm Hg. Presiones superiores ejercidas sobre un área concreta durante un tiempo prolongado desencadenan un proceso isquémico que, si no se revierte a tiempo, origina la muerte celular y su necrosis. En la formación de la UPP parece tener más importancia la continuidad en la presión que la intensidad de esta, ya que la piel puede soportar presiones elevadas, pero sólo durante cortos períodos de tiempo, por lo que se puede afirmar que la presión y el tiempo son inversamente proporcionales. [6]

1.2.1 Factores según la posición

Los principales factores que contribuyen a generar una úlcera por presión son:

1.2.1.1 Presión

Es la fuerza ejercida por unidad de superficie perpendicular a la piel; debido a la gravedad, provoca aplastamiento tisular que ocluye el flujo sanguíneo con posterior hipoxia de los tejidos y necrosis si continúa.

Representa el factor de riesgo más importante. [1]




Figura 1. Fuerzas de presión. [1]

1.2.1.2 Fricción

Es una fuerza tangencial que actúa paralelamente a la piel, produciendo roces por movimiento o arrastre. La humedad aumenta la fricción aparte de macerar la piel. [1]




Figura 2. Fuerza de fricción. [1]

1.2.1.3 De pinzamiento vascular

Combina los efectos de presión y fricción; por ejemplo, la posición de "Fowler" que provoca presión y fricción en sacro. [1]



Figura 3. Posición "Fowler". [1]

1.2.2 Factores de Riesgo

Es importante tener en cuenta cuales son los diferentes factores de riesgo que provoca a que se presente una úlcera por presión, entre ellas encontramos:

a) Fisiopatológicos

- Lesiones cutáneas: envejecimiento y patológicas.
- Trastornos del transporte de oxígeno: Insuficiencia vascular periférica, estasis venosa, trastornos cardiopulmonares.
- Déficit nutricionales: delgadez, obesidad, anemias, hipoproteinemias.
- Trastornos inmunológicos: cáncer, infección.
- Alteraciones del estado de conciencia: fármacos, confusión, coma.
- Déficit motor: ACV (accidente cerebrovascular), fracturas.
- Déficit sensoriales: pérdida de la sensibilidad térmica y dolor.
- Alteraciones de la eliminación: urinaria y fecal.

b) Derivados del tratamiento

- Inmovilidad impuesta por tratamiento.
- Tratamiento inmunosupresor: radioterapia, quimioterapia.
- Sondajes con fines diagnósticos o tratamiento.

c) Situacionales

- Falta de higiene.
- Arrugas en la ropa.
- Objetos de roce.
- Inmovilidad por dolor, fatiga.

d) Del entorno

- Falta o mala utilización del material de prevención.
- Desmotivación profesional por falta de formación y/o información específica.
- Sobrecarga de trabajo.
- Falta de criterios unificados en la planificación de las curas.
- Falta de educación sanitaria de cuidadores y pacientes.
- Deterioro de la propia imagen de la enfermedad. [7]

Con ello, se realiza una valoración clínica, acompañado de un personal de salud. Las úlceras por presión no cicatrizan a menos que las causas de fondo sean tratadas eficazmente. Una valoración general debe incluir la identificación y el tratamiento efectivo de la enfermedad, los problemas de salud, el estado nutricional, el grado de dolor y los aspectos psicosociales que puedan haber situado a la persona en riesgo de desarrollar UPP. Todos los pacientes deber ser evaluados mediante escalas de valoración de riesgo con el objetivo de iniciar cuanto antes las medidas de prevención. Este riesgo debe ser revalorado a intervalos periódicos y cuando se produce algún cambio en el nivel de actividad o movilidad. La escala de Braden y la escala de Norton mostrado en la Tabla 1, son los instrumentos más utilizados para identificar a los pacientes de edad avanzada con riesgo de desarrollar UPP. La escala de Braden tiene una sensibilidad del 83-100% y una especificidad del 64-77%; la escala de Norton tiene una sensibilidad del 73-92% y una especificidad del 61-94%. Otras escalas son: Waterlow, Arnell y las derivadas de Norton (la escala de Gosnell, de Ek, de Nova-4, de Emina y la de Norton modificada del Insalud). [2][3][8]

Tabla 1. Escala de Norton. [1]

Estado físico	Estado mental	Movilidad	Actividad	Incontinencia
4. Bueno	4. Alerta	4. Completa	4. Deambula	4. No
3. Aceptable	3. Apático	3. Algo limitada	3. Con ayuda	3. Ocasional
2. Deficiente	2. Confuso	2. Muy limitada	2. Silla de ruedas	2. Habitual
1. Muy deficiente	1. Estupor	1. Inmóvil	1. Encamado	1. Doble incontinencia

1.2.3 Complicaciones

Existen complicaciones las cuales pueden dividirse en complicaciones primarias y secundarias:

1.2.3.1 Complicaciones primarias:

- a) Locales: originadas por la progresión de la necrosis llegando a afectar a las articulaciones y originar fístulas y hemorragias graves. La infección se deberá sospechar en toda úlcera grado III y IV y en las superficiales con enrojecimiento de la piel en la zona que rodea la úlcera o la supuración de la herida. Los patógenos más frecuentes son gérmenes gramnegativos, anaerobios y staphilococo aureus meticilin resistente. La osteomielitis se debe sospechar ante úlceras de evolución tórpida, sepsis, leucocitosis sin otra causa o VSG mayor o igual a 120 mm/h. Otra de las complicaciones que puede condicionar el manejo y tratamiento es el dolor.
- b) Sistémicas: entre las que debemos destacar la anemia, sepsis, amiloidosis secundaria, endocarditis, tétanos, carcinoma de células escamosas, fístulas, complicaciones del tratamiento.

1.2.3.2 Complicaciones Secundarias:

Algunas son de origen económico, como la mayor estancia hospitalaria y el aumento del costo asistencial; y otras de tipo clínico, como el retardo en la recuperación y rehabilitación, las infecciones nosocomiales y la yatrogenia. [3]

El objetivo principal, es evitar la úlcera por presión, y obtener un correcto tratamiento para poder sobrellevar la lesión. Dentro de los cuidados de la piel, al tratar de mantener y mejorar la tolerancia tisular a la presión para prevenir una lesión. Se debe realizar:

- Inspección sistemática de la piel una vez al día por lo menos.
- Limpiar la piel con agua tibia y jabones neutros para minimizar la irritación y resequead de la piel.
- Minimizar los factores ambientales que producen sequedad de la piel (baja humedad < 40% y exposición al frío).
- Tratar la piel seca con agentes hidratantes.
- Evitar el masaje sobre las prominencias óseas.
- Evitar la exposición de la piel a la orina, materia fecal, transpiración y drenaje de la herida mediante el uso de pañales desechables que se cambiarán con frecuencia, hidratantes y barreras para la humedad.
- Reducir al mínimo la fricción y rozamiento mediante técnicas adecuadas de posición, transferencia y cambios de posición.

- Tratar la desnutrición y mejorar la movilidad.
- Ejercicios pasivos y activos que incluyen desplazamiento para disminuir la presión sobre prominencias óseas. [2][3]

Se pueden administrar algunas curas que dependen del estado de la lesión, la presencia o no de infección o de cavitación. Hay una gran variedad de productos en el mercado, y muchas veces es más decisiva y curativa la experiencia y conocimientos del personal que la realiza que el producto en sí. Hay que revisarla cada vez, aunque conviene mantener el mismo tipo de cura una o dos semanas antes de ver si ésta es efectiva o no, y valorar situaciones concomitantes que retrasen la buena evolución de la úlcera. [9]

Una herramienta que favorecería la detección de una úlcera por presión, y con ello prevenirla y/o tratarla, sería con inteligencia artificial, ya que, a partir de imágenes correspondientes a úlceras por presión, es posible implementar algoritmos de detección y clasificación de úlceras por presión, y con ello diagnosticar un posible cuidado ya mencionado en dicha lesión.

1.3 Inteligencia Artificial en salud

Se ha visto que la tecnología ha aportado herramientas en salud para prevenir, diagnosticar o tratar enfermedades o para rehabilitación o de cuidado a largo plazo. Así mismo, si hablamos de la inteligencia artificial en salud, se puede hablar de que ha sido una herramienta bastante útil para detección de enfermedades infecciosas, también usado en atención médica, en tratamiento de imágenes en salud, con el fin de analizar datos y recomendar tratamientos según sea el caso.

Por todas partes se habla de las ventajas que la inteligencia artificial (IA) puede suponer para el futuro de la vida cotidiana y, entre sus posibles aplicaciones, se hace mención del interés de los profesionales de la salud en aplicarla a la práctica clínica diaria. [10]

Con ello, la inteligencia artificial nace a partir de preguntarnos si era posible automatizar máquinas para que realizaran tareas intelectuales normalmente realizadas por humanos. A partir de esto surgen ramificaciones de la IA entre las cuales encontramos el *machine learning* y a su vez el *Deep learning*, éste último un subcampo del *machine learning*.




Figura 4. Inteligencia artificial, *Machine learning*, *deep learning*. [11]

La inteligencia artificial es un concepto donde se utilizan reglas programáticas, que son procesos difíciles de hacer, pero fáciles de explicar, por ejemplo, calcular una media, es un proceso fácil de explicar, pero tedioso de hacer una y otra y otra vez.

El *machine learning* se utiliza cuando no se conocen las reglas y se quiere llegar a ellas programáticamente, por ejemplo, se tiene la foto de un gato y se quiere llegar a las reglas que dicen porque eso es un gato, entonces se añaden un montón de fotos de perros, gatos, etc, se dice que foto corresponde a que animal y se espera que el computador aprenda las reglas por sí solo.

El *Deep Learning* es una forma de tratar las representaciones de los datos que pone énfasis en el aprendizaje a través de capas sucesivas, con lo cual se busca tener representaciones cada vez más significativas que nos permitan estar cerca de las salidas esperadas, es decir, a través de las capas se busca extraer progresivamente características de un valor más refinado, como es el caso de las redes neuronales. [12]

La inteligencia artificial es un área de las ciencias de la computación que se basa en el desarrollo de algoritmos “inteligentes”, con la capacidad de imitar las habilidades cognitivas del ser humano. Algunas de estas habilidades pueden ser: aprender a realizar nuevas actividades, comprender contextos y resolver problemas.

En este sentido, la inteligencia artificial en medicina consiste en la aplicación de algoritmos inteligentes para el desarrollo de nuevas soluciones en este sector. Considerando la creciente cantidad de datos relacionados con la salud, es posible implementar estos sistemas tecnológicos para procesar dicha información y desarrollar mecanismos capaces de hacer diagnósticos, recomendar tratamientos e, incluso, facilitar el diseño de nuevos fármacos. [13]

La inteligencia artificial también ha tenido impacto en algunas áreas de la salud. Gracias a los avances tecnológicos, el uso de la inteligencia artificial en medicina se ha extendido a muchas áreas del sector. Entre ellas, destacan las siguientes:

1.3.1 Inteligencia artificial en el reconocimiento de imágenes

El proyecto iFIND, desarrollado en el laboratorio BioMedIA del Imperial College en Londres, implementa la inteligencia artificial en medicina a través de algoritmos de *deep learning* para el análisis de las imágenes fetales. De esta forma, es posible estudiar cada parte del feto para detectar y atender posibles anomalías durante todo su desarrollo.

En este proceso intervienen sistemas de resonancia magnética en 3D del cerebro fetal y una evaluación automatizada y precisa de los ultrasonidos realizados. Así, se genera un diagnóstico automático y con alto nivel de fiabilidad. [13]

1.3.2 Inteligencia artificial en medicina oncológica

Diagnosticar a tiempo el cáncer de mama es uno de los retos en la Universidad de Valencia, en donde un grupo de expertos desarrolla algoritmos inteligentes para detectar el cáncer mediante el análisis de las mamografías. Según estos científicos, los diagnósticos emitidos por esta tecnología son confiables en un 89% y con el aval de un radiólogo, este porcentaje incrementa a un 93%.

Este proyecto de inteligencia artificial en medicina nace con la finalidad de evitar falsos positivos y de detectar la enfermedad en una etapa temprana. [13]

1.3.3 Inteligencia artificial en oftalmología

En Silicon Valley, la ingeniera Lily Peng ha implementado el *deep learning* para detectar enfermedades oftalmológicas. Este proceso se realiza con una fotografía del ojo que permite identificar enfermedades como el glaucoma. Este sistema realiza una búsqueda exhaustiva entre millones de patrones de padecimientos similares, hasta dar con el correcto en un corto periodo de tiempo.

Así, con el uso de la inteligencia artificial en medicina, el análisis de información visual para la detección de enfermedades es una tarea mucho más práctica y certera. [13]

1.3.4 Inteligencia artificial en la farmacología

Anaxomics, empresa española de biotecnología, ha descubierto a través de la inteligencia artificial en medicina que cierta combinación de fármacos promueve considerables mejoras en los pacientes con Esclerosis Lateral Amiotrófica (ELA).

Este descubrimiento se desarrolló al procesar, mediante redes neuronales artificiales, la información de más de 5.400 fármacos disponibles. Con ello, la investigadora principal del proyecto, Mireia Coma, señala:

"Hemos descubierto varias combinaciones de medicamentos ya existentes que pueden ser usados conjuntamente contra enfermedades diferentes de aquellas para las que habían sido desarrollados."

Por otro lado, Google Brain, equipo de investigación de inteligencia artificial de Google, ha descubierto la manera de desarrollar nuevos medicamentos implementando la inteligencia artificial en medicina.

Estos científicos han creado un sistema que detecta la cristalización de las proteínas con un rango de confiabilidad del 94%. Mediante la observación de la cristalización de las proteínas, es posible saber qué reacción puede generar una molécula en una determinada célula. [13]

1.3.5 Inteligencia artificial para el tratamiento de la diabetes

PEPPER es un proyecto realizado por el Centro de Investigación Biomédica en Red de Fisiopatología de la Obesidad y la Nutrición (CIBEROBN) y el Instituto de Investigación Biomédica de Girona (IDIBGI). Estos organismos, a través de la IA, desarrollaron un dispositivo portátil capaz de asesorar a los pacientes de forma personalizada, en el control de la administración de sus medicinas y el consumo de alimentos.

Como resultado, el índice glucémico de las personas que implementaron el sistema mejoró considerablemente, lo que convierte a PEPPER en una herramienta de IA en medicina que resulta efectiva para el tratamiento de la diabetes tipo 1.

Según la Encuesta Nacional de Salud de España (ENSE), hasta el 2017 el país vio un incremento de enfermedades crónicas como hipertensión arterial (19,8%), obesidad (17,4%) y diabetes (7,8%). Por lo que, el uso de inteligencia artificial en medicina a través de herramientas como aplicaciones móviles, *wearables* o tecnologías más sofisticadas en los centros de salud, son las mejores alternativas para disminuir o controlar este alto índice de enfermedades.

De igual forma, la empresa de consultoría Frost & Sullivan asevera que, para el 2021, la inversión de inteligencia artificial en medicina superará los 5.900 millones de euros. Estas proyecciones permiten vislumbrar un avance significativo para los próximos años, capaz de promover más y mejores tecnologías en el área de la salud. [13]

En el *Deep Learning* el aprendizaje se da a partir de modelos conocidos como redes neuronales artificiales, los cuales son estructuras a capas conectadas unas a otras, donde el nombre de red neuronal viene de la neurobiología y su comparación con el cerebro, si bien estos modelos se inspiran en este, las redes neurales no son modelos del cerebro, pues no se tiene la certeza de como éste funciona, es por esto que muchas personas están dejando a un lado la terminología que hace referencia a aspectos biológicos.




Figura 5. Modelo Redes Neuronales. [12]

En la Figura 5 se puede ver un esquema general de una red profunda, la cual se puede pensar como una multiestación de operaciones de destilación de información, donde ésta va a través de diferentes filtros y se retorna altamente purificada, es decir, se va obteniendo a través de capas, diferentes características que harán más refinadas las representaciones y, por ende, se acercarán más a las salidas buscadas. [12]

Este estudio propone construir un algoritmo con *Deep learning*, creando un modelo de aprendizaje automático a partir de una base de datos de imágenes, el cual sea capaz de identificar estas imágenes correspondientes a úlceras por presión en pacientes hospitalizados y detectar en qué etapa se encuentra. Esto con el fin de disminuir esta lesión y fomentar un diagnóstico por parte del personal de salud, y con ello acortar su tiempo de hospitalización y mejorar la calidad de vida de los pacientes.

2. OBJETIVOS

2.1. General

Desarrollar algoritmos de analítica de datos utilizando modelos de clasificación aplicados al procesamiento de imágenes de úlceras por presión en pacientes con este tipo de lesión.

2.2. Específicos

1. Construir algoritmos de clasificación a través de *Deep Learning* que permitan la identificación de patrones a partir de imágenes de úlceras por presión.
2. Implementar métodos de detección de patrones a partir de los datos obtenidos de las imágenes de úlceras por presión.
3. Validar el modelo de clasificación a partir de dos métodos de algoritmos de aprendizaje automático usando Redes Neuronales.
4. Analizar los parámetros de los algoritmos, identificando su efectividad a través de los resultados obtenidos.

3. METODOLOGÍA

A continuación, se muestra paso a paso como se desarrolló la metodología en el presente trabajo de investigación, para lograr un clasificador de úlceras por presión.

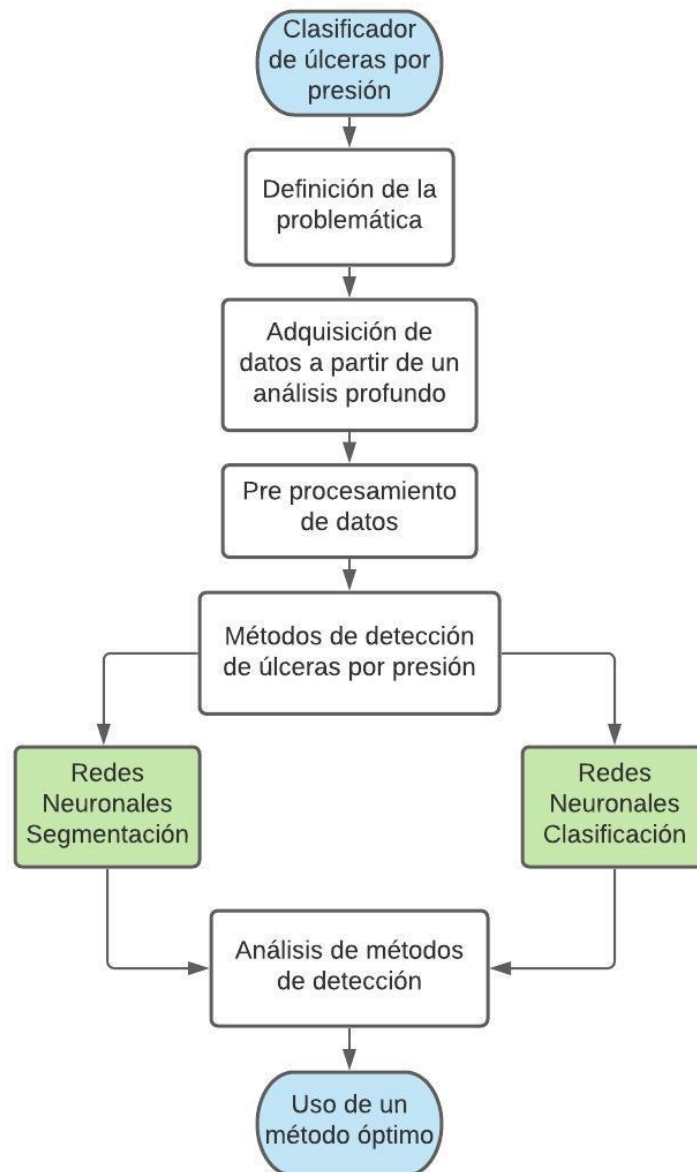


Figura 6. Metodología, Clasificador de úlceras por presión.

3.1 Definición de la problemática

Las úlceras por presión tienen un impacto negativo en la calidad de vida de los pacientes, ya que contribuyen al dolor y el sufrimiento durante su proceso de hospitalización. Esto implica que los pacientes prolonguen su hospitalización, aumentando

no solo la carga laboral del personal asistencial, sino también aumentando los costos para el sistema de salud. Las úlceras por presión requieren para su cicatrización de períodos muy prolongados de tiempo, ya que cicatriza por segunda intención, en un proceso que elimina y reemplaza el tejido dañado. [14]

El reconocimiento temprano de una posible úlcera por presión, puede contribuir a la mejora de la calidad de vida de los pacientes hospitalizados, como así un tratamiento adecuado y efectivo para este tipo de lesión.

3.2 Adquisición de datos

Para lograr obtener datos necesarios a manipular, es importante tener en cuenta cuales son los factores que generan a que se presente una úlcera por presión en un paciente hospitalizado. Existen factores de riesgo que contribuyen al desarrollo de las úlceras por presión que son causadas ya sea por la presión ejercida en un paciente debido a la gravedad, por fricción ejercida en el paciente produciendo roces o movimientos en una zona húmeda, o de pinza vascular, combinando los efectos de la fricción y presión.

A partir de ello, se procede a obtener una valoración clínica, acompañado del personal de enfermería, siendo profesionales capaces de dar un diagnóstico que incluye:

- **Localización y numero de lesiones:** Los trocánteres, el sacro, glúteos y talones son las localizaciones más frecuentes.
- **Estado:** Correspondiente a su aspecto físico presentado en la Figura 7.
 - **Etapa I:** eritema cutáneo que no palidece. En paciente de piel oscura observar edema, induración, decoloración, calor local.
 - **Etapa II:** úlcera superficial que tiene aspecto de abrasión, ampolla o cráter superficial. Pérdida de piel de espesor parcial que involucra la epidermis, dermis o ambas.
 - **Etapa III:** pérdida total del grosor de la piel que implica lesión o necrosis del tejido subcutáneo, que puede extenderse hacia abajo, pero no por la fascia subyacente.
 - **Etapa IV:** pérdida total del grosor de la piel con destrucción extensa, necrosis del tejido o lesión en músculo, hueso o estructura de sostén. En este estado, como en el III, pueden presentarse lesiones con caverna, tunelizaciones o trayectos sinuosos. [1]
- **Área:** registrar el diámetro de las lesiones circulares y las longitudes perpendiculares mayores de las lesiones irregulares.
- **Profundidad:**
 - **Grado I:** afecta epidermis y deja expuesta dermis subyacente.
 - **Grado II:** afecta toda la piel hasta la grasa subcutánea.
 - **Grado III:** llega hasta la fascia profunda.
 - **Grado IV:** la necrosis abarca músculo y llega a afectar articulaciones y hueso.

- **Secreción de la úlcera:** estimar la cantidad, identificar el grado de olor y purulencia. [3]



Figura 7. Etapas clínicas de las úlceras por presión. [15]

Ya con la identificación de estos parámetros, se procede a la adquisición de una base de datos de imágenes correspondientes a úlceras por presión, identificando su respectiva etapa según la gravedad de la lesión.

Los datos se obtienen en imágenes pertenecientes a la localización de la lesión en los pacientes hospitalizados, consiguiendo una aprobación para la manipulación de estas imágenes relacionadas con úlceras por presión. Con ello, se obtuvo un total de 1000 imágenes para la elaboración de esta investigación.

3.3 Preprocesamiento de datos

En este trabajo se usó un entorno de ejecución en Google Colaboratory, siendo una plataforma que permite escribir y ejecutar código en lenguaje de Python en un navegador, sin configuración requerida, con acceso gratuito a GPU, y con la facilidad para compartir código con estudiantes o profesores.

A partir de la obtención de la base de datos, se procedió a realizar un preprocesamiento de cada una de las imágenes, previo a usar técnicas de identificación y clasificación de cada una de ellas correspondientes a úlceras por presión.

- **Ajuste del tamaño de las imágenes:** Se debe tener en cuenta que las imágenes tienen longitudes diferentes, para ser empleadas, es requisito que estas imágenes presenten un mismo tamaño sin afectar sus características. Para ello se procede a realizar un cambio de tamaño en las imágenes por medio del comando “*resize image aspect ratio*”.
- **Clasificación de las imágenes:** La base de datos correspondiente a un total de 1000 imágenes, se clasifica en sus diferentes etapas, a partir de los parámetros anteriormente mencionados. El proceso de clasificación fue supervisado por una enfermera jefe con experiencia en este campo, esto para que obtenga precisión y fiabilidad en su distribución. Con ello se obtiene un total de 178 imágenes de úlceras en etapa 1, 147 en etapa 2, 128 en etapa 3 y 547 imágenes en etapa 4.
- **División de imágenes para segmentación:** Antes de realizar una segmentación de imágenes para un posterior entrenamiento, se divide la base de datos en dos grupos.
 - **Train files:** Se obtiene un grupo para el entrenamiento del modelo correspondiente al 70% de las imágenes de la base de datos a implementar, con un total de 700 imágenes en las que se incluyen imágenes en las diferentes etapas al azar
 - **Test files:** Se obtiene un grupo para la verificación del algoritmo de entrenamiento y observar su eficacia, correspondiente al 30% de las imágenes de la base de datos a implementar, con un total de 300 imágenes donde se incluyen imágenes en las diferentes etapas al azar.

3.4 Fase de detección y segmentación

Como ya se mencionó anteriormente, se va a emplear el primer grupo “Train files” para entrenar dos diferentes modelos de detección de imágenes de úlceras por presión a partir de una segmentación de las imágenes de úlceras por presión.

- **Detección e identificación de la lesión:** Se obtiene una identificación de la lesión en el área afectada, teniendo en cuenta los factores de riesgo correspondiente a la etapa en la que se encuentra, la forma y el tamaño.
- **Segmentación de imágenes:** LabelBox es una plataforma que permite obtener la etiqueta de una determinada sección de distintas imágenes como punto de entrada, obteniendo una imagen en blanco y negro de la sección etiquetada como punto de salida.

La Segmentación es la técnica de tratamiento digital de imágenes que permite extraer información de los objetos, a partir de un proceso de clasificación por pixel, asignando una

categoría a cada píxel de la imagen analizada [16]. La Segmentación es dada a partir de dos tareas complementarias: el reconocimiento y la delineación. El reconocimiento consiste en la tarea de alto nivel de determinación a grandes rasgos de la ubicación del objeto a examinar. La delineación consiste en la tarea de bajo nivel de determinación precisa de la extensión espacial del objeto y su composición. En cualquier caso, estos dos pasos suelen ser esenciales, y se realiza esta distinción para entender cómo se realiza la Segmentación digital. [16]

Uno de los casos más elementales de segmentación es la umbralización, un tipo particular de segmentación por color, la cual cuenta con solo dos categorías: claro y oscuro. Cada píxel se clasifica como claro u oscuro comparando su intensidad con una intensidad de referencia dada denominada umbral. [17]

Como se mencionó anteriormente, una vez sea detectada la lesión en la imagen original como se observa en la Figura 8 (a), se procede a la etapa de segmentación de las imágenes, produciendo un delineado de la zona afectada. De esta manera se obtiene un mapeado de la sección afectada en la piel como se observa en la figura Figura 8 (b) a partir de un reconocimiento asistido por el hombre, y como resultado se obtiene una máscara de esta sección como se observa en la Figura 8 (c) para el posterior entrenamiento.



Figura 8. Segmentación imágenes úlceras por presión. a) Imagen original, b) Etiqueta de la sección afectada, c) Máscara de la sección afectada.

Se puede observar la arquitectura del modelo de segmentación, obteniendo como el producto la máscara de la sección afectada en las dos categorías mencionadas (claro y oscuro). A partir de esta imagen de salida es posible implementar métodos para realizar un reconocimiento de la zona afectada en imágenes correspondientes a úlceras por presión.

3.5 Métodos para detección de úlceras por presión

Existen variedad de métodos para realizar la detección de úlceras por presión. En esta investigación, se utilizan dos métodos basados en algoritmos utilizando inteligencia artificial, siendo una tecnología similar al modelo de la red neuronal del cerebro y utiliza múltiples

capas de información, que incluyen algoritmos, coincidencia de patrones, reglas, *deep learning* y computación cognitiva, para aprender a comprender los datos. [18]

3.5.1 Redes Neuronales Convolucionales (CNN)

Las redes neuronales artificiales se usaron como un método para lograr la detección de la lesión a identificar. Las redes neuronales convolucionales consisten en múltiples capas de filtros convolucionales de una o más dimensiones. Después de cada capa, por lo general se añade una función para realizar un mapeo causal no-lineal.

Como cualquier red empleada para clasificación, al principio estas redes tienen una fase de extracción de características, compuesta de neuronas convolucionales, luego hay una reducción por muestreo y al final se tienen neuronas de perceptrón más sencillas para realizar la clasificación final sobre las características extraídas.

La fase de extracción de características se asemeja al proceso estimulante en las células de la corteza visual. Esta fase se compone de capas alternas de neuronas convolucionales y neuronas de reducción de muestreo. Según progresan los datos a lo largo de esta fase, se disminuye su dimensionalidad, siendo las neuronas en capas lejanas mucho menos sensibles a perturbaciones en los datos de entrada, pero al mismo tiempo siendo estas activadas por características cada vez más complejas.

Las Redes neuronales Convolucionales, CNN aprenden a reconocer una diversidad de objetos dentro de imágenes, pero para ello necesitan “entrenarse” previamente con una cantidad importante de datos. [19]

- Píxeles y muestras

Para comenzar, la red toma como entrada los píxeles de una imagen. Si se tiene una imagen con apenas 28x28 píxeles de alto y ancho, equivale a utilizar 784 neuronas. Y eso es si se tiene 1 color (escala de grises). Si se tuviera una imagen a color, se necesitarían 3 canales RGB (*red, green, blue*) y por lo tanto se usarían $28 \times 28 \times 3 = 2352$ neuronas. Estas neuronas constituyen una capa de entrada. [19]



Una imagen...

		0.6	0.6		
	0.6			0.6	
	0.6	0.6	0.6	0.6	
	0.6			0.6	

...es una matriz de píxeles.
El valor de los píxeles va de 0 a 255 pero se normaliza para la red neuronal de 0 a 1

Figura 9. Píxeles en imagen. [19]

- Pre-Procesamiento

Antes de alimentar la red, como entrada hay que normalizar los valores entre 0 y 1, y para ello se divide entre 255 debido a que los colores de los pixeles tienen valores en un rango de 0 a 255.




Figura 10. Imagen RGB. [19]

- Convoluciones

Aquí comienza el “procesado distintivo” de las Redes Convolucionales, en otras palabras, “convoluciones”. Estas consisten en tomar «grupos de pixeles cercanos» de la imagen de entrada e ir operando matemáticamente (producto escalar) contra una pequeña matriz que se llama kernel. Suponiendo que éste kernel tenga un tamaño de 3x3 pixeles, se logra visualizar todas las neuronas de entrada (de izquierda-derecha, de arriba-abajo) y así se genera una nueva matriz de salida, que en definitiva será una nueva capa de neuronas ocultas.

En caso de que la imagen sea una imagen a color, el kernel tendría un tamaño de 3x3x3 es decir: un filtro con 3 kernels de 3x3; luego esos 3 filtros se suman y conformarán 1 salida (cómo si fuera 1 solo canal). [19]




Figura 11. Imagen de entrada y matriz kernel. [19]

- **Filtro: Conjunto de Kernels**

A estas imágenes se les aplica un conjunto de kernels los cuales se llamarán filtros. En una primera convolución se podrían tener 32 filtros, con lo cual se obtendrían 32 matrices de salida, cada una de 28x28x1 dan un total de las 25.088 neuronas para la primera capa oculta de neuronas.




Figura 12. Capa oculta de neuronas. [19]

A medida que se va desplazando el kernel y se va obteniendo una nueva imagen filtrada por el kernel. En esta primera convolución, se obtendrían 32 imágenes filtradas nuevas. Estas imágenes nuevas, estarían dibujando ciertas características de la imagen original. Esto ayudará para distinguir un objeto de otro (por ej. Si se encuentra una úlcera o no). [19]

- **Función de activación**

La función de activación más utilizada para este tipo de redes neuronales es la llamada Rectifier Linear Unit (“ReLU”) y consiste en una función:

$$f(x) = \max(0, x) \tag{1}$$

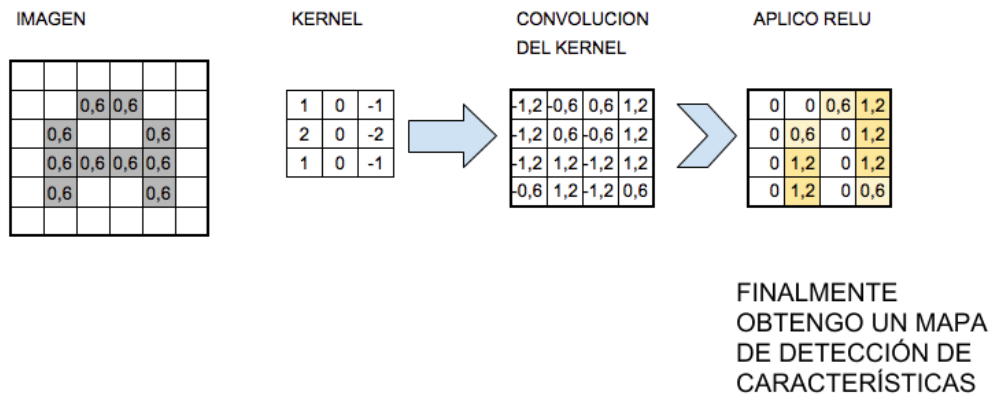


Figura 13. La imagen realiza una convolución con un kernel y aplica la función de activación “ReLU”. [19]


- **Muestreo (subsampling)**

En este paso se toma una muestra de las neuronas más representativas antes de hacer una nueva convolución.

Se observa que con una imagen blanco y negro de 28x28 pixeles, se tiene una primera capa de entrada de 784 neuronas y luego de la primera convolución se obtiene una capa oculta de 25.088 neuronas, que presentan finalmente 32 mapas de características de 28x28 ((28 x 28) x 32).

Es necesario reducir el tamaño de la próxima capa de neuronas para obtener un rendimiento óptimo del algoritmo y evitar que la imagen pierda su resolución. Para reducir el tamaño se hace un muestreo preservando las características más importantes que detectó cada filtro.

Hay diversos tipos de muestreo (*subsampling*), el más utilizado es: *Max-Pooling*. [19]



SUBSAMPLING:

Se aplica Max-Pooling de 2x2 y se reduce la salida a la mitad

Figura 14. Muestreo SUBSAMPLING. [19]

- Muestreo con *Max-Pooling*

Se utiliza la técnica de "*Max-pooling*" con un tamaño de 2x2. Esto quiere decir que se recorre cada imagen con las características obtenidas, pero en lugar de tomar 1 píxel, se tomará con una matriz 2x2 (2 de alto por 2 de ancho = 4 pixeles) y se irá preservando el valor más alto de entre esos 4 pixeles, quedando una imagen reducida a la mitad. [19]

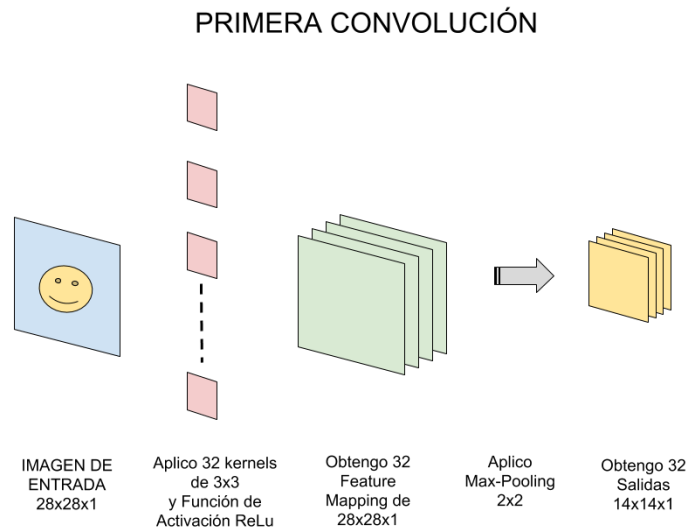


Figura 15. Primera convolución. [19]

La Figura 15 representa la primera convolución: consiste de una entrada, un conjunto de filtros, se genera un mapa de características y se realiza el submuestreo.

Tabla 2. Datos de la primera convolución. [19]

Imagen de entrada	Se aplica Kernel	Se obtiene <i>Feature Mapping</i>	Se aplica <i>Max-Pooling</i>	Se obtiene Primera Convolución
28x28x1 = 784 neuronas	32 filtros de 3x3	28x28x 32 kernel = 25.088 neuronas	de 2x2	14x14x32 = 6.272 neuronas

La primera convolución es capaz de detectar características primitivas como líneas ó curvas. A medida que hagamos más capas con las convoluciones, los mapas de características serán capaces de reconocer formas más complejas, y el conjunto total de capas de convoluciones podrá reconocer. [19]

- Convoluciones subsecuentes

Ahora se realiza una segunda convolución de esta manera:

SEGUNDA CONVOLUCIÓN (y sucesivas)

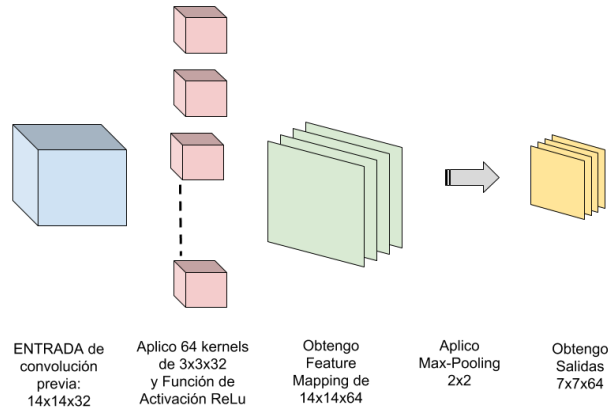


Figura 16. Segunda convolución. [19]

Tabla 3. Datos de la segunda convolución. [19]

Imagen de entrada	Se aplica Kernel	Se obtiene <i>Feature Mapping</i>	Se aplica <i>Max-Pooling</i>	Se obtiene Salida de Convolución
14x14x32 = 6272 neuronas	64 filtros de 3x3	14x14x64 = 12544 neuronas	de 2x2	7x7x64 = 3136 neuronas

La tercera convolución comenzará en tamaño 7x7 pixeles y luego del *Max-Pooling* quedará en 3x3 con lo cual se podría hacer sólo una convolución más.

Tabla 4. Datos de la tercera convolución. [19]

Imagen de entrada	Se aplica Kernel	Se obtiene <i>Feature Mapping</i>	Se aplica <i>Max-Pooling</i>	Se obtiene Salida de Convolución
7x7x64= 3.136 neuronas	128 filtros de 3x3	7x7x128= 6272 neuronas	de 2x2	3x3x128 = 768 neuronas

- **Conectar a una red neuronal**

Para terminar, se tomará la última capa oculta a la que se hizo *subsampling*, conectando a una nueva capa de neuronas, generando una nueva capa oculta de neuronas tipo *feedforward*.

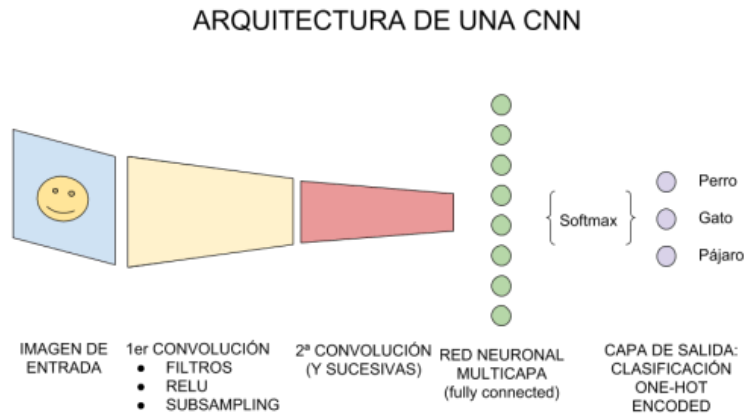


Figura 17. Arquitectura de una Red Neuronal Convolutiva. [19]

A esta nueva capa oculta tradicional, se aplicó una función llamada Softmax que conecta contra la capa de salida final, la cual tendrá la cantidad de neuronas correspondientes con las clases que se está clasificando.

3.5.1.1 Método enfocado a segmentación de imágenes

En este método se trabajó con Redes Neuronales con una arquitectura implementada en segmentación para una red neuronal, la cual consiste en tres bloques. Una red de codificadores conectada a una red de decodificadores, mediante una capa convolutiva 1x1. Esta estructura de red se ve representada en la Figura 18. La primera parte corresponde al codificador, el cual obtiene un mapa de características, dada una imagen de entrada. El segundo bloque es la capa convolutiva de 1x1. Este bloque consiste en sustituir la capa de neuronas completamente conectadas o Fully Connected de la CNN por una capa convolutiva de kernel 1x1. Permite generar una clasificación de la imagen, a la vez que se preserva la información espacial. La red de decodificadores se encarga de recuperar los detalles de los objetos, proyectando las características obtenidas (baja resolución) en el espacio de píxeles. Finalmente, mediante la proyección de las características, obtenemos una clasificación de los píxeles (alta resolución). [20]




Figura 18. Estructura de una FCN (Fully Convolutional Network). [20]

En este proceso, se encuentra un problema de pérdida de resolución de los mapas de características de salida, debido a las capas convolucionales y de submuestreo,

provocando bordes borrosos en las imágenes de salida. Para recuperar la resolución de los mapas de características en la red de decodificadores de estos modelos, se utilizan capas de muestreo ascendente y deconvolución, y con ello aumentar el número de parámetros de entrenamiento.

3.5.1.2 Método enfocado a clasificación de imágenes

En este método, se usa un parche de la imagen en donde se encuentra la lesión, como lo indica la Figura 19, como imagen de entrada, etiquetando a que etapa pertenece la úlcera por presión para el posterior entrenamiento y con ello obtener una mejor presión.

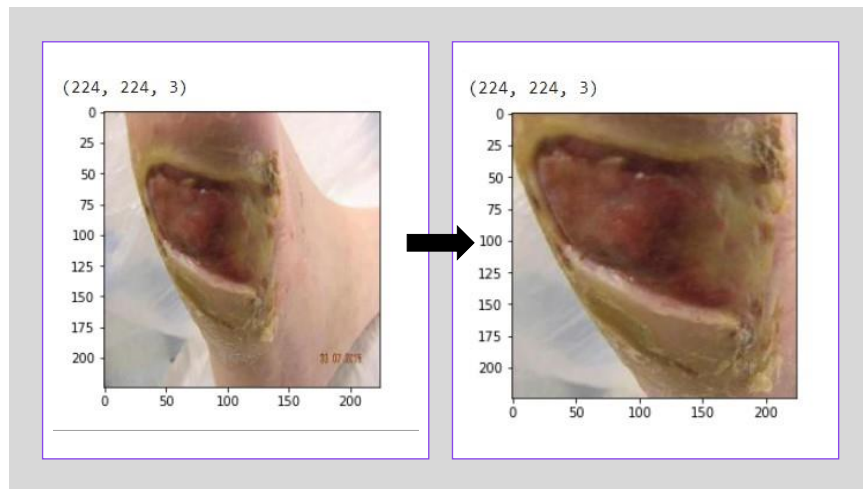


Figura 19. Parche de úlcera por presión.

Este método se entrena con el modelo *ResNet50*, modelo de Red Neuronal Convolutiva fue introducido por Microsoft en 2015. No siempre al obtener mayor número de capas en las redes neuronales produce una mejor detección, ya que se va perdiendo la resolución de la imagen. Lo que sucede con *ResNet*, es que a medida que el número de capas crece, puede seguir bajando el error que comete la capa. No hay una pérdida aceptable de rendimiento. Así que, se puede crear redes más profundas sin realmente hacerlas menos eficaces en el conjunto de entrenamiento. [21]

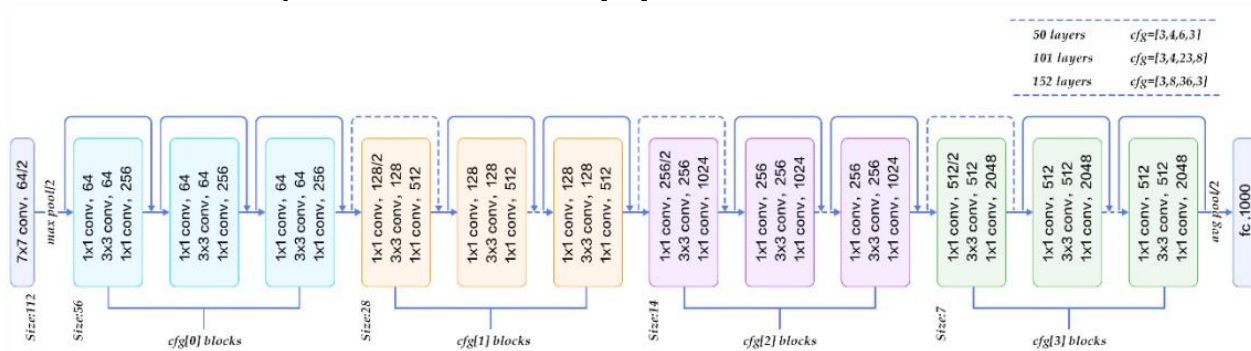


Figura 20. Arquitectura ResNet50. [21]

4. RESULTADOS

En el presente apartado se da a conocer los resultados adquiridos con relación a la metodología planteada. El procesamiento y análisis de las imágenes se dio a través de la plataforma Google Colaboratory, éste permite escribir y ejecutar código de Python en un navegador, sin configuración requerida, con acceso gratuito a GPU, y con la facilidad para compartir código con estudiantes o profesores.

Se presenta los datos en el preprocesamiento de las imágenes, y con ello los diferentes métodos de detección de imágenes, con la herramienta de Redes Neuronales por segmentación y por clasificación de úlceras por presión.

4.1 Preprocesamiento de imágenes

4.1.2 Ajuste del tamaño de las imágenes:

Para el ajuste del tamaño de las imágenes, se determinó un ancho y una base de las imágenes de 224x224 pixeles para poseer una mejor precisión al momento de entrenar el modelo, se ha demostrado que el modelo de Redes Neuronales ofrece un mejor rendimiento con las imágenes de entrada a un tamaño de 224 pixeles, ya que la capa oculta de neuronas se incrementa aportando más información al entrenamiento. Teniendo en cuenta el concepto "*resize image aspect ratio*" para no alterar su aspecto de la imagen original, como se observa en la Figura 21.

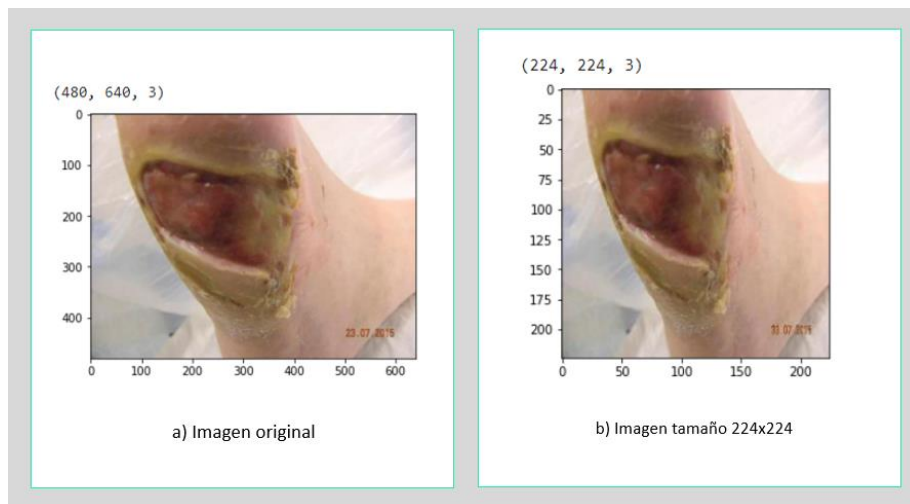


Figura 21. a) Imagen original de la base de datos. b) Imagen a un tamaño de 224x224 con "*Resize image aspect ratio*".

4.1.3 División de imágenes para segmentación:

Previo a la segmentación, se dividió la base de datos en dos grupos para el entrenamiento y el posterior análisis de los modelos de entrenamiento.

- **Train files:** Se obtiene un grupo para el entrenamiento del modelo correspondiente al 70% de las imágenes de la base de datos a

implementar, con un total de 700 imágenes en las que se incluyen imágenes en las diferentes etapas al azar

- **Test files:** Se obtiene un grupo para la verificación del algoritmo de entrenamiento y observar su eficacia, correspondiente al 30% de las imágenes de la base de datos a implementar, con un total de 300 imágenes donde se incluyen imágenes en las diferentes etapas al azar.

4.2 Fase de detección y segmentación

A partir de la figura 22, muestra como el grupo “Train files” se realizó una identificación del área afectada, teniendo en cuenta los factores de riesgo, y posterior a ello, se realizó un delineado alrededor de la lesión, obteniendo como el producto la máscara de la sección afectada en las dos categorías (claro y oscuro).

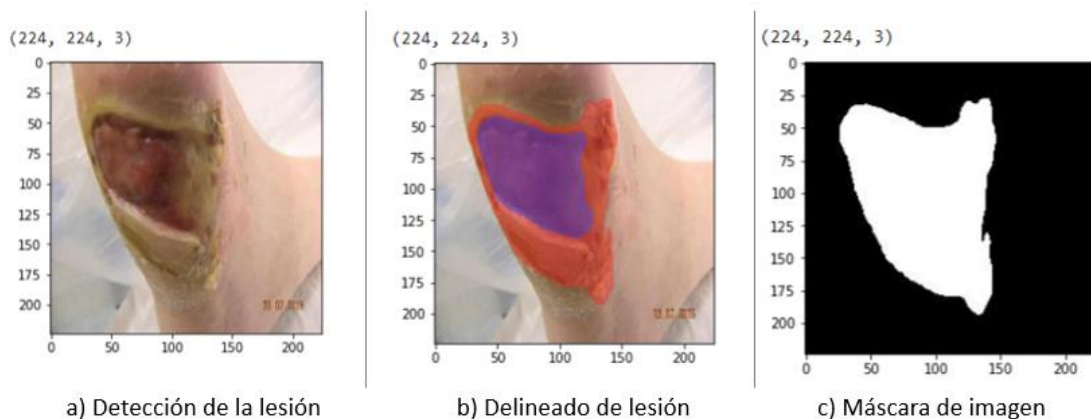


Figura 22. a) Detección de la lesión, b) Delineado de la lesión, c) Máscara de la imagen.

En la Figura 22, se puede observar el proceso en el cual fue obtenida la máscara de la imagen original. Esta máscara fue obtenida a través de un delineado hecho en la plataforma LabelBox, la cual además de permitir tener un delineado de la lesión, también permitió etiquetar la lesión según la etapa en la que se encontrara. Esta tarea de delineado y clasificación de imágenes fue monitoreado y revisado por los presentes tutores del proyecto para asegurar que fuera un trabajo con éxito.

Este conjunto de imágenes fue descargado en un archivo “.csv” tal como se muestra en la tabla 5, ya que es una de las formas en las que LabelBox ofrece para obtener las imágenes a través de un enlace electrónico. El archivo “.csv” ofrecía características como lo son el nombre de la imagen, fechas de creación, enlace electrónico de la imagen, entre otras. Al archivo “.csv” se extrajeron las siguientes características que se consideraron importantes para el análisis y ejecución de sus imágenes:

- Link de acceso de proyección de primera máscara de la imagen.

- Link de acceso de proyección de la segunda máscara de la imagen (si se obtuvo más de una máscara).
- Link de acceso de proyección de una tercera máscara de la imagen (si obtiene más de una máscara)
- Nombre original de la imagen.
- Etiqueta que muestra en qué etapa se encuentra la imagen.

Tabla 5. Ejemplo archivo ".csv".

Mask 1	Mask 2	Mask 3	External ID	Stage
https://api.labelbo..	schemald	schemald	100015.jpg	Etapa 1
https://api.labelbo..	https://api.labelbo..	schemald	100076.jpg	Etapa 2
https://api.labelbo..	https://api.labelbo..	https://api.labelbo..	100122.jpg	Etapa 3

Posterior a ello, se extrajo el link de acceso a las máscaras obtenidas de cada imagen y se descargaron dichas imágenes a través de Google Colab. Al extraer las imágenes, se etiquetaron de manera consecutiva, de tal forma que fuera clara y ordenada su respectivo nombre con el que fue guardada cada una de las imágenes. Las imágenes correspondientes a las imágenes originales se guardaron (“#_nombre_de_la_imagen.jpg”), y las imágenes equivalentes a la máscara de la imagen se guardó (“#_mask_nombre_de_la_imagen.jpg”).

4.3 Métodos para detección de úlceras por presión

Dentro de los métodos utilizando inteligencia artificial a implementar, se encuentra el modelo de Redes Neuronales Convolucionales por segmentación y por detección de etapas de úlceras por presión.

4.3.1 Método enfocado a segmentación de imágenes

Después de la detección y segmentación de la lesión, se utilizó el modelo de clasificación de la lesión. CNN tiene un modelo profundo representativo para generar directamente características jerárquicas profundas a partir de las imágenes sin procesar de entrada.

Para este modelo se utilizó un modelo de aprendizaje por transferencia Vgg19, usando 19 capas convolucionales. Después de ello se definen distintos parámetros de entrenamiento observados en la Tabla 6 para identificar cuál modelo presenta un mejor rendimiento en su entrenamiento.

Tabla 6. Parámetros de entrenamiento.

Modelos	Batch size	Epochs	Verbose	Validation split	Optimizador
Modelo 1	16	100	1	0.1	Adam
Modelo 2	32	100	1	0.1	Adam
Modelo 3	16	200	1	0.1	Adam
Modelo 4	32	200	1	0.1	Adam
Modelo 5	16	300	1	0.1	Adam
Modelo 6	32	300	1	0.1	Adam

Se evalúa la calidad del modelo mediante una métrica especial llamada índice Jaccard. El índice o coeficiente Jaccard es un coeficiente que mide el nivel de semejanza entre dos conjuntos a comparar, en el contexto de imágenes, es una métrica que se utiliza para ver la comparación de píxeles de la predicción del modelo con respecto a su máscara. Su rango de valores discurre entre 0 y 1, tomando el 0 como semejanza nula, por el contrario, el 1 para este caso, no es justamente el índice Jaccard, sino una modificación de este. [22]

Cada modelo fue entrenado con respecto a sus debidos parámetros, lo ideal del modelo es la pérdida "Loss" se reduzca, esto debido a que la pérdida evalúa la desviación entre las predicciones realizadas por la red neuronal y los valores reales de las observaciones utilizadas durante el aprendizaje. Cuanto menor es su resultado, más eficiente es la red neuronal. Reducir al mínimo la desviación entre el valor predicho y el valor real para una observación dada, se hace ajustando los distintos pesos de la red neuronal. [23]

También es necesario obtener una exactitud "iou_score" alta, ya que éste mide el porcentaje de casos en el que el modelo ha acertado. La tabla 7 exhibe los resultados obtenidos.

Tabla 7. Datos de entrenamiento.

Modelos	Loss	iou score	Índice Jaccard
Modelo 1	0.0890	0.5006	0.5648
Modelo 2	0.0810	0.5452	0.5671
Modelo 3	0.0693	0.5985	0.5949
Modelo 4	0.0150	0.9009	0.9255
Modelo 5	0.1229	0.3967	0.6255
Modelo 6	0.0114	0.9274	0.6372

A partir de la imagen de entrada, se obtuvo el valor de salida de cada uno de los modelos, observando que modelo presenta una mejor precisión al momento de indicar en donde se encuentra la lesión, esto se puede observar en la Figura 23.

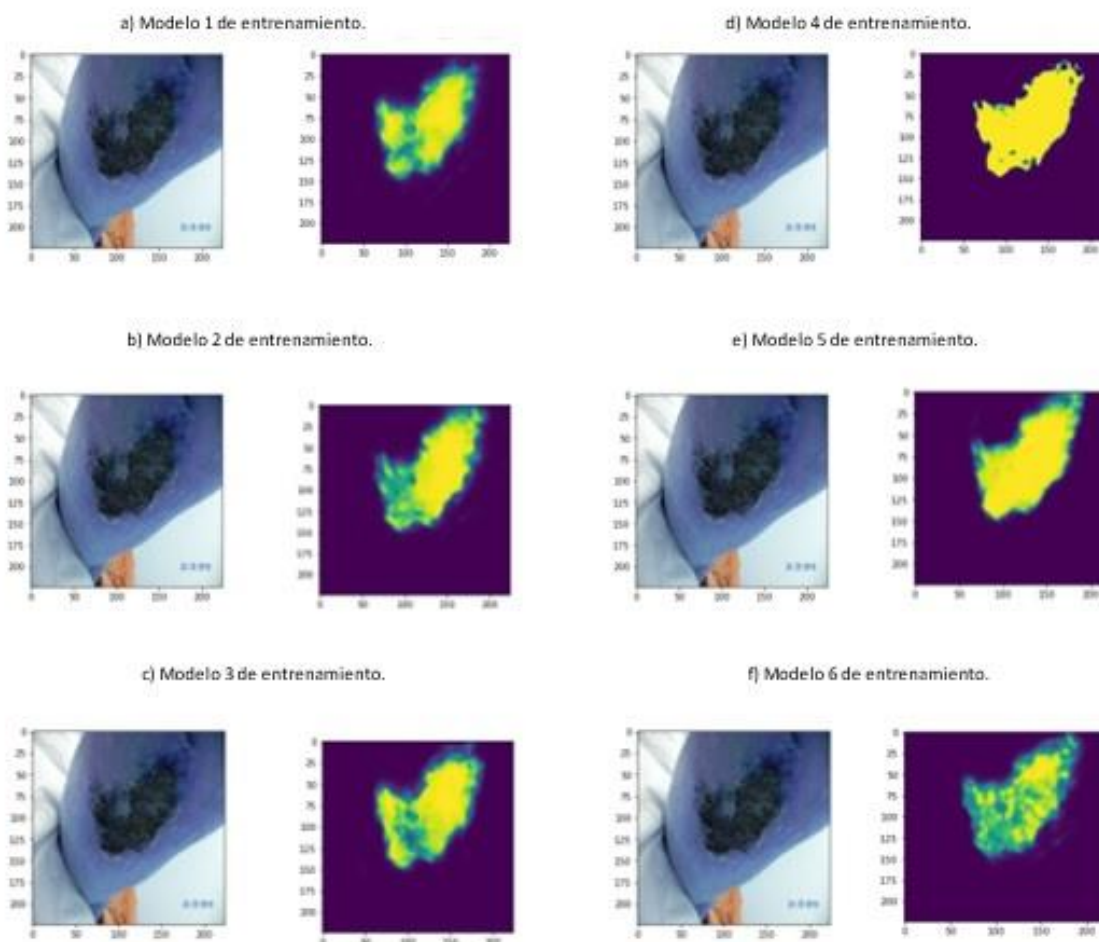


Figura 23. Imagen de entrada y salida de los modelos entrenados.

4.3.2 Método enfocado a clasificación de imágenes

Este método enfocado a la clasificación de úlceras por presión se busca identificar en qué etapa se encuentra la lesión a partir de modelo *ResNet-50* de redes neuronales. Como se mencionó anteriormente, se obtuvo una base de datos de 1000 imágenes de las diferentes etapas, la cual se dividió en dos conjuntos (*Train* y *Test*). Para esta sección se utilizó el conjunto "*Train*" correspondiente al 70% de imágenes de la base de datos, la tabla 8 muestra la cantidad de imágenes correspondiente a cada etapa del conjunto de datos "*Train*":

Tabla 8. Datos.

Etapas 1	Etapas 2	Etapas 3	Etapas 4
40	95	95	468

Se obtuvo un set de entrenamiento al identificar las 4 etapas, pero dado de que la etapa 1 se compone de un set de datos de 40 imágenes, siendo bastante pequeña en comparación con las demás etapas, se realizó un análisis de las imágenes correspondientes con esta

etapa y se observo que no se alcanzaba a identificar una lesión de ulcera por presión en la piel, ya que las imágenes no aportaban información al algoritmo, por ello se decidió eliminar los datos pertenecientes a la etapa 1.

Dado que la etapa 4 se compone de 468, existe una inconsistencia, con respecto a la etapa 2 y etapa 3 que se componen de 95 imágenes cada una. Lo ideal para entrenar un algoritmo es que la entrada de cada clase tenga los mismos pesos, por ello se decidió separar los datos de la etapa 4 en 4 conjuntos con 117 imágenes cada uno.

Tabla 9. Paquetes de datos.

Datos	Etapa 2	Etapa 3	Etapa 4
Conjunto 1	95	95	117
Conjunto 2	95	95	117
Conjunto 3	95	95	117
Conjunto 4	95	95	117

De los 4 paquetes de datos, se extrajeron datos como lo es la pérdida y la validación del entrenamiento, y las matrices de confusión para observar su comportamiento.

4.3.2.1 Conjunto 1

Se obtuvieron 3 modelos de entrenamiento con diferentes parámetros, y como resultado el parámetro de interés del modelo siendo pérdida (*Loss*) y validación (*Accuracy*):

Tabla 10. Modelos entrenados.

Parámetros	Modelo 1	Modelo 2	Modelo 3
Batch size	8	16	32
Epochs	200	200	200
Optimizador	Adam	Adam	Adam
Loss	1.0304	0.9299	0.8494
Accuracy	0.4286	0.5224	0.5918

Al analizar los diferentes modelos con sus parámetros, se observó que el modelo óptimo según su entrenamiento fue el modelo 3, obteniendo su comportamiento en la matriz de confusión observando la tabla 11.

Tabla 11. a) Matriz de confusión Train, b) Matriz de confusión Test.

	Etapa 2	Etapa 3	Etapa 4
Etapa 2	63	13	0
Etapa 3	25	51	0
Etapa 4	34	11	48

	Etapa 2	Etapa 3	Etapa 4
Etapa 2	10	5	4
Etapa 3	5	12	2
Etapa 4	4	9	11

La tabla 12 y 13, muestra lo valores de las métricas finales obtenidas.

Tabla 12. Resultado matriz de confusión Train.

Etapa	Total de datos	Datos Clasificados	Accuracy	Precision	Recall	F1 Score
2	122	76	64.9%	0.83	0.52	0.64
3	75	76	78.78%	0.67	0.78	0.72
4	48	93	74.69%	0.52	1.0	0.68

Tabla 13. Resultado matriz de confusión Test.

Etapa	Total de datos	Datos Clasificados	Accuracy	Precision	Recall	F1 Score
2	19	19	48.39%	0.53	0.30	0.38
3	19	19	54.84%	0.26	0.26	0.26
4	17	24	58.06%	0.17	0.40	0.24

4.3.2.2 Conjunto 2

Se obtuvieron 3 modelos de entrenamiento con diferentes parámetros, y como resultado el parámetro de interés del modelo siendo pérdida (*Loss*) y validación (*Accuracy*):

Tabla 14. Modelos entrenados.

Parámetros	Modelo 1	Modelo 2	Modelo 3
Batch size	8	16	32
Epochs	200	200	200
Optimizador	Adam	Adam	Adam
Loss	1.2926	0.9919	0.9746
Accuracy	0.4082	0.4612	0.4367

Al analizar los diferentes modelos con sus parámetros, se observó que el modelo óptimo según su entrenamiento fue el modelo 2, obteniendo su comportamiento en la matriz de confusión obtenido en la tabla 15.

Tabla 15. a) Matriz de confusión Train, b) Matriz de confusión Test.

	Etapa 2	Etapa 3	Etapa 4
Etapa 2	34	31	11
Etapa 3	29	39	8
Etapa 4	28	25	40

	Etapa 2	Etapa 3	Etapa 4
Etapa 2	8	6	5
Etapa 3	6	9	4
Etapa 4	5	8	11

La tabla 16 y 17, muestra lo valores de las métricas finales obtenidas.

Tabla 16. Resultado matriz de confusión Train.

Etapa	Total de datos	Datos Clasificados	Accuracy	Precision	Recall	F1 Score
2	91	76	59.59%	0.45	0.37	0.41
3	95	76	62.04%	0.51	0.41	0.46
4	59	93	70.61%	0.43	0.68	0.53

Tabla 17. Resultado matriz de confusión Test.

Etapa	Total de datos	Datos Clasificados	Accuracy	Precision	Recall	F1 Score
2	19	19	59.68%	0.42	0.36	0.39
3	23	19	51.61%	0.32	0.26	0.29
4	20	24	59.68%	0.33	0.47	0.39

4.3.2.3 Conjunto 3

Se obtuvieron 3 modelos de entrenamiento con diferentes parámetros, y como resultado el parámetro de interés del modelo siendo pérdida (*Loss*) y validación (*Accuracy*):

Tabla 18. Modelos entrenados.

Parámetros	Modelo 1	Modelo 2	Modelo 3
Batch size	8	16	32
Epochs	200	200	200
Optimizador	Adam	Adam	Adam
Loss	1.0986	0.9948	0.9717
Accuracy	0.3918	0.4327	0.4531

Al analizar los diferentes modelos con sus parámetros, se observó que el modelo óptimo según su entrenamiento fue el modelo 2, obteniendo su comportamiento en la matriz de confusión observado en la tabla 19.

Tabla 19. a) Matriz de confusión Train, b) Matriz de confusión Test.

	Etapa 2	Etapa 3	Etapa 4
Etapa 2	56	0	20
Etapa 3	56	10	10
Etapa 4	48	0	45

	Etapa 2	Etapa 3	Etapa 4
Etapa 2	12	3	4
Etapa 3	15	1	3
Etapa 4	17	0	7

La tabla 20 y 21, muestra lo valores de las métricas finales obtenidas.

Tabla 20. Resultado matriz de confusión Train.

Etapa	Total de datos	Datos Clasificados	Accuracy	Precision	Recall	F1 Score
2	160	76	43.39%	0.74	0.35	0.47
3	10	76	73.06%	0.13	1.0	0.23
4	75	93	16.68%	0.48	0.60	0.54

Tabla 21. Resultado matriz de confusión Test.

Etapa	Total de datos	Datos Clasificados	Accuracy	Precision	Recall	F1 Score
2	44	19	37.1%	0.63	0.27	0.38
3	4	19	66.13%	0.053	0.25	0.087
4	14	24	61.29%	0.29	0.50	0.37

4.3.2.4 Paquete 4

Se obtuvieron 3 modelos de entrenamiento con diferentes parámetros, y como resultado el parámetro de interés del modelo siendo pérdida (*Loss*) y validación (*Accuracy*):

Tabla 22. Modelos entrenados.

Parámetros	Modelo 1	Modelo 2	Modelo 3
Batch size	8	16	32
Epochs	200	200	200
Optimizador	Adam	Adam	Adam
Loss	1.0458	1.2120	1.2475
Accuracy	0.3959	0.3918	0.3959

Al analizar los diferentes modelos con sus parámetros, se observó que el modelo óptimo según su entrenamiento fue el modelo 1, obteniendo su comportamiento en la matriz de confusión observado en la tabla 23.

Tabla 23. a) Matriz de confusión Train, b) Matriz de confusión Test.

	Etapa 2	Etapa 3	Etapa 4
Etapa 2	4	3	69
Etapa 3	1	1	74
Etapa 4	1	0	92

	Etapa 2	Etapa 3	Etapa 4
Etapa 2	0	0	19
Etapa 3	0	0	19
Etapa 4	0	0	24

La tabla 24 y 25, muestra lo valores de las métricas finales obtenidas.

Tabla 24. Resultado matriz de confusión Train.

Etapa	Total datos	de	Datos Clasificados	Accuracy	Precision	Recall	F1 Score
2	6		76	69.8%	0.053	0.67	0.098
3	4		76	68.16%	0.013	0.25	0.025
4	235		93	41.22%	0.99	0.39	0.56

Tabla 25. Resultado matriz de confusión Test.

Etapa	Total datos	de	Datos Clasificados	Accuracy	Precision	Recall	F1 Score
2	0		19	69.35%	0.0	0.0	0.0
3	0		19	69.35%	0.0	0.0	0.0
4	62		24	38.71%	1.0	0.39	0.56

En general, se observan que hay resultados coherentes con los modelos presentados en la matriz de confusión con respecto a cada etapa en las que se presenta la ulcera por presión. También se indica en algunos modelos que se presentan datos aleatorios en los que seguramente se debe a que el grupo de datos de entrenamiento no fue apto para su entrenamiento.

5. DISCUSIÓN

En el presente apartado, se analizarán los datos obtenidos de los métodos para detección de úlceras por presión con Redes Neuronales Convolucionales, por el método de segmentación y de clasificación de úlceras correspondientemente.

5.1 Método enfocado a segmentación de imágenes

En esta sección, se obtiene resultados de 6 modelos con diferentes parámetros, con el fin de encontrar un modelo óptimo al momento de entrenar la Red Neuronal. En la tabla 6 se obtienen los parámetros de cada modelo de entrenamiento, y por consiguiente la tabla 7 muestra los resultados obtenidos.

Entrenar un modelo simplemente significa aprender valores correctos para todas las ponderaciones y las ordenadas al origen de los ejemplos etiquetados. En un aprendizaje supervisado, el algoritmo de un aprendizaje automático construye un modelo al examinar varios ejemplos e intentar encontrar un modelo que minimice la pérdida. [24]

La pérdida es un número que indica qué tan incorrecta fue la predicción del modelo. Si la predicción del modelo es perfecta, la pérdida es cero; de lo contrario, la pérdida es mayor. El objetivo de entrenar un modelo es encontrar un conjunto de ponderaciones y ordenadas al origen que, en promedio, tengan pérdidas bajas. [24] en la columna 2 de la tabla 7 se observa la pérdida de cada uno de los modelos entrenados, identificando que el modelo 6 obtuvo una pérdida de 0.0114, una pérdida bastante buena muy cercana a cero.

Las métricas de pérdida y validación son buenos indicadores para ver el progreso del entrenamiento. El valor de validación mostrado en la columna 3 de la tabla 7, indica una suposición de cómo se va entrenando el modelo, se puede ver que a medida que se va realizando cada entrenamiento en cada época, va aumentando su valor hasta llegar al máximo. Con ello podemos identificar que nuevamente el modelo 6 muestra un buen resultado con el valor más alto de 0.9274

Adicionalmente se evalúa la calidad del modelo bajo la métrica índice Jaccard. El índice Jaccard es una de las formas más simples de calcular y averiguar la exactitud de un modelo de clasificación de aprendizaje automático. Este coeficiente de similitud Jaccard es una estadística utilizada para comprender las similitudes entre los conjuntos de muestras. Cuanto mayor sea el índice Jaccard, mayor será la precisión del clasificador. [25]

El cálculo del índice Jaccard se formula con aquellas imágenes segmentadas que superen un valor de 0,65; en caso contrario la segmentación será nula o fallida. Para este caso, el índice de Jaccard presentado en la tabla 7 columna 4, muestra que el modelo 4 obtuvo un valor bastante alto, obteniendo una segmentación aceptada.

Visualmente se puede ver el resultado de cada modelo en la Figura 24. Las métricas indican que los modelos más aceptados corresponden a el modelo 4 y modelo 6, visualmente observado en la Figura 24 d (modelo 4) y f (modelo 6). Se observa que el modelo más aceptado corresponde al modelo 6, ya que a diferencia del modelo 4, el modelo 6 identifica

el tejido afectado y descarta el tejido sano, demostrando que no siempre tener un índice de Jaccard alto, sea la mejor opción.

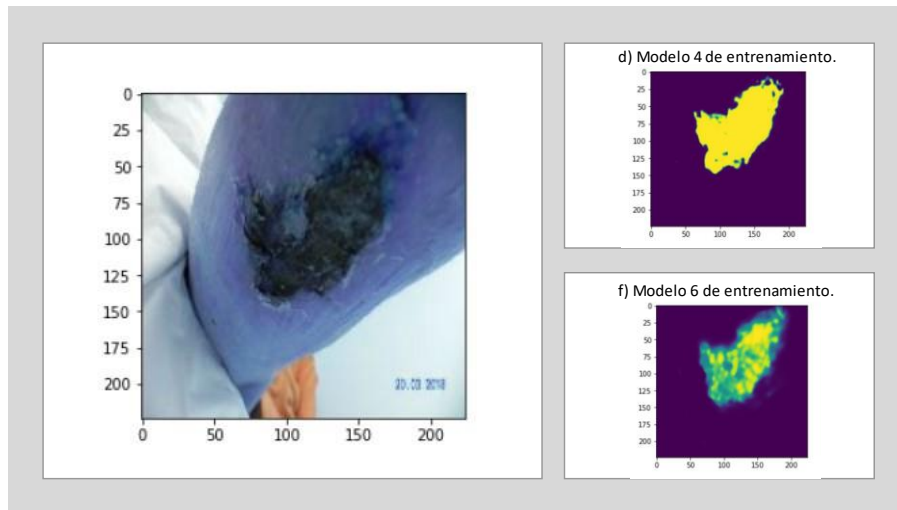


Figura 24. Modelos de entrenamiento.

Para entender un poco más a fondo el concepto y porque se realizan los cambios de parámetros, se explica de la siguiente manera: cada neurona tiene diferentes pesos (W) y un parámetro (b) que es igual entre las neuronas de una misma capa. En cada ciclo (*epoch*) todos los datos de entrenamiento pasan por la red neuronal para que esta aprenda sobre ellos, si existen 10 ciclos y 1000 datos, cada ciclo los 1000 datos pasarán por la red neuronal. Si se especifica el parámetro *batch size* cada ciclo (*epoch*) tendrá más ejecuciones internas, estas ejecuciones se llaman iteraciones, si se tiene un *batch size* de 100, se tendrán 10 iteraciones para completar un ciclo, en cada iteración se ejecutan los algoritmos de *forwardpropagation* y *backpropagation*, de esta manera la red neuronal actualiza más veces los parámetros W y b . Esta variable también es un hiperparámetro. [26]

El *batch size* es el número de datos que tiene cada iteración de un ciclo (*epoch*), esto es útil porque la red neuronal actualiza los parámetros W y b más veces, también cuando se tienen grandes cantidades de datos se necesitan computadoras con más memoria y la red neuronal tarda más en ejecutar cada ciclo, si se dividen los ciclos en iteraciones con un número de datos más pequeño ya no es necesario cargar todos los datos en la memoria al mismo tiempo y la red neuronal se entrena más rápido. [26]

Con los resultados mostrados, se puede concluir que entre más alto sea el *batch size* y entre más épocas de entrenamiento, el modelo ya a presentar un mejor rendimiento, ya que con más épocas de entrenamiento hay mayor posibilidad de encontrar un entrenamiento más aceptable, y un *batch size* más alto se tienen más iteraciones y se obtiene un periodo de entrenamiento más corto.

5.2 Método enfocado a clasificación de imágenes

Para este método, se usaron 4 paquetes de datos mostrados en la tabla 9. En este método se eliminaron los datos de la etapa 1, ya que al realizar un experimento se encontraba que casi ningún dato se presentaba con etapa 1, ya que esta etapa es difícil de identificar por lo que no se presenta aun el tejido dañado.

De cada paquete de entrenamiento se obtuvo 3 resultados, con el mismo número de épocas, pero esta vez cambiando el *batch size* con el fin de encontrar un entrenamiento óptimo. De cada entrenamiento se analizó cual tenía un mejor resultado según la pérdida y la validación de cada paquete. De cada paquete, el modelo con mejores resultados se analizó su comportamiento al introducir imágenes propias con las que se entrenó el modelo (*Train*) y con imágenes externas que el modelo no conocía (*Test*), y con respecto a ello se obtuvo una matriz de confusión tanto para *Train* como para *Test*, obteniendo parámetros la precisión (*Precision*), sensibilidad (*Recall*), exactitud (*Accuracy*) y puntuación (*F1 Score*) para cada clase (etapa en la que se encuentra la úlcera por presión).

Una **matriz de confusión** es una representación matricial de los resultados de las predicciones de cualquier prueba binaria que se utiliza a menudo para describir el rendimiento del modelo de clasificación sobre un conjunto de datos de prueba cuyos valores reales se conocen. [25] Cada predicción puede ser uno de cuatro resultados, basado en cómo coincide con el valor real:

- **Verdadero Positivo (TP):** Predicho Verdadero y Verdadero en realidad.
- **Verdadero Negativo (TN):** Predicho Falso y Falso en realidad.
- **Falso Positivo (FP):** Predicción de verdadero y falso en la realidad.
- **Falso Negativo (FN):** Predicción de falso y verdadero en la realidad.

La matriz de confusión es relativamente sencilla de comprender, y a partir de ella se obtiene parámetros como lo son:

- **Exactitud:** La exactitud representa el porcentaje de predicciones correctas frente al total. Por tanto, es el cociente entre los casos bien clasificados por el modelo (verdaderos positivos y verdaderos negativos, es decir, los valores en la diagonal de la matriz de confusión), y la suma de todos los casos.
Sin embargo, cuando un conjunto de datos es poco equilibrado, no es una métrica útil. Por ejemplo, si lo que intentamos predecir es una enfermedad rara, y nuestro algoritmo clasifica a todos los individuos como sanos, podría ser muy preciso (incluso un 99%), pero también, totalmente inútil. Por ello, en estos casos se suele recurrir a otras métricas, como la sensibilidad (o *recall*), que representa la habilidad del modelo de detectar los casos relevantes, y que veremos un poco más adelante. [27]
- **Precisión:** La precisión, se refiere a lo cerca que está el resultado de una predicción del valor verdadero. Por tanto, es el cociente entre los casos positivos bien clasificados por el modelo y el total de predicciones positivas. [27]

- **Sensibilidad:** La sensibilidad (o *recall*) representa la tasa de verdaderos positivos. Es la proporción entre los casos positivos bien clasificados por el modelo, respecto al total de positivos. [27]
- **Puntuación F1:** La puntuación F1 es la media armónica de la precisión y sensibilidad, donde la puntuación de la F1 alcanza su mejor valor en 1 (precisión y sensibilidad perfectas) y el peor en 0. [25]

5.2.3 Conjunto 1

El resultado de este primer paquete mostrado en la tabla 10, muestra que el modelo 3 fue efectivo, con un *batch size* alto. La pérdida presentada fue de 0.8494 con una exactitud de 0.5918. la tabla 11 muestra la matriz de confusión obtenida al entrenar el modelo con datos de *Train* y *Test*.

Se observa en la tabla 11, que su diagonal tiende a tener números mayores que en las otras casillas, lo cual es bueno y es coherente ya que estos valores corresponden a un verdadero positivo, pero aún existen datos que difieren a como se debería comportar el modelo. La tabla 12 y 13 muestra el resultado de los parámetros del modelo en cada etapa. Se puede observar que la precisión para ambos casos es mayor en la en el conjunto de entrenamiento *Train* que en el conjunto *Test*. Por otro lado, se observa que los valores para ambos casos, presenta resultados buenos para la etapa 2, observando que para el modelo fue más sencillo identificar las úlceras en etapa 2, y por datos más cercanos a cero para el caso de la etapa 4, fue más complejo reconocer la lesión en esta fase.

5.2.2 Conjunto 2

El resultado de este paquete previsto en la tabla 14, muestra que el modelo 2 fue positivo, con una pérdida de 0.9919 y una exactitud de 0.4612, obtenido con un *batch size* de 16. Este presenta buenos resultados, pero no tan buenos como los obtenidos en el paquete 1.

Se observa en la tabla 15, que su diagonal tiende a tener números mayores que en las otras casillas, presentando verdaderos positivos, pero se muestran datos que difieren con números altos en otras casillas mostrando falsos positivos y negativos, y ni un solo verdadero positivo, lo cual no es bueno para el modelo de aprendizaje. La tabla 16 y 17 muestra el resultado de los parámetros del modelo en cada etapa. Se puede observar que en general, existen valores bajos de precisión, lo cual quiere decir que el modelo es más exacto que preciso. También se observa que la sensibilidad (*Recall*), obtiene valores muy bajos, queriendo decir que el modelo de entrenamiento es poco sensible.

5.2.3 Conjunto 3

El resultado de este paquete previsto en la tabla 18, muestra que el modelo 2 fue positivo, con una pérdida de 0.9948 y una exactitud de 0.4327, obtenido con un *batch size* de 16. Este presenta buenos resultados, pero no tan buenos como los obtenidos en el paquete 1.

Se observa en la tabla 19, que su diagonal tiende a tener números difieren y se presentan altos números en generando falsos positivos para la etapa 2, y falsos negativos para la

etapa 4, siendo estos valores más altos que lo que debería presentarse en la diagonal principal siendo los verdaderos positivos. Esto no es bueno para el modelo de aprendizaje. La tabla 20 y 21 muestra el resultado de los parámetros del modelo en cada etapa. Se puede observar que en general, existen valores muy desequilibrados para cada modelo. Esto se puede observar ya que se presenta buena precisión para la etapa 2 pero también una muy baja para la etapa 3, lo cual también sucede en la columna de sensibilidad y de F1 score, estando este muy cercano a cero.

5.2.4 Conjunto 4

El resultado de este paquete previsto en la tabla 22, muestra que el modelo 1 fue el más eficiente, con una pérdida de 1.2120 y una exactitud de 0.3918, obtenido con un batch size de 8. Este presenta no presenta muy buenos resultados, ya que, dentro de los conocidos, es el modelo que presenta alta pérdida y baja exactitud.

Se observa en la tabla 23, que su diagonal tiende a tener números muy bajos en la diagonal principal para la etapa 2 y 3, y una muy alta para la etapa 4. Estos datos difieren presentando falsos positivos para la etapa 4, y muy pocos verdaderos positivos para las otras etapas. Esto quiere decir que el modelo presento datos desequilibrados los cuales afectaron el entrenamiento del modelo. Para ambos grupos de Train y Test se presenta una precisión casi nula, a excepción del modelo 4, una sensibilidad casi nula, y un F1 score inaceptable, ya que es cero o muy cercana a cero.

6. RECOMENDACIONES Y TRABAJOS FUTUROS

Como continuación a este trabajo, existen proyectos en los cuales seguir implementando el modelo de Redes Neuronales Convolucionales para detección de imágenes. Este trabajo presenta una herramienta practica para la clasificación y detección de úlceras por presión. Como recomendaciones diría que el algoritmo puede presentar mejores resultados al obtener una base de datos más amplia de úlceras por presión para presentar mejores resultados.

Por otra parte, este trabajo se puede complementar adquiriendo un aplicativo web, donde se implemente los algoritmos de detección propuestos, brindando así una herramienta útil para que el personal de salud pueda implementar en alguna clínica u hospital.

7. CONCLUSIONES

El uso de una tecnología como el *Deep Learning*, está generando un impacto en cuanto a la creación de nuevas herramientas que se presentan en multitud de campos. En el ámbito de la medicina, su potencial es aún mayor, ya que los resultados obtenidos tienen en muchos casos una calidad y precisión mayor a la que el ser humano puede llegar a proporcionar. Estas herramientas no tratan de sustituir en ningún caso la presencia humana en áreas como la medicina, sino ofrecer herramientas de ayuda a los especialistas.

Los métodos de Redes Neuronales de entrenamiento proporcionaron buenos resultados en ambos modelos, con ello fue necesario adquirir varios modelos de entrenamiento con el fin de encontrar un modelo aceptable.

Para el caso del método de segmentación, se concluye que con un *batch size* alto, y un número de épocas alto, se puede adquirir un modelo que identifique en qué zona se encuentra la úlcera por presión. Para el caso del método por clasificación, obteniendo el modelo 1 del paquete 1 eficiente, con buenos resultados, concluyendo nuevamente que el entrenamiento presenta un mejor resultado cuando se entrena con un *batch size* alto.

Es necesario tener en cuenta que, para el entrenamiento por clasificación, se deben tener un balance en los datos a clasificar, ya que esto puede presentar un desequilibrio para la interpretación de los datos. Es necesario tener en cuenta que los datos con los que se va a entrenar el modelo sean aceptables, ya que esto también puede presentar una alteración en el resultado de los datos.

En general, el trabajo obtuvo buenos resultados al adquirir varios modelos de entrenamiento, con el fin de analizar su comportamiento con diferentes parámetros de entrenamiento. Cabe resaltar que el modelo puede adquirir mejoras en su entrenamiento con una base de datos más amplia.

La inteligencia artificial aporta múltiples herramientas en el ámbito clínico, este trabajo expone que, a partir de algoritmos de procesamiento de imágenes, se puede aportar una herramienta bastante útil en detección de imágenes.

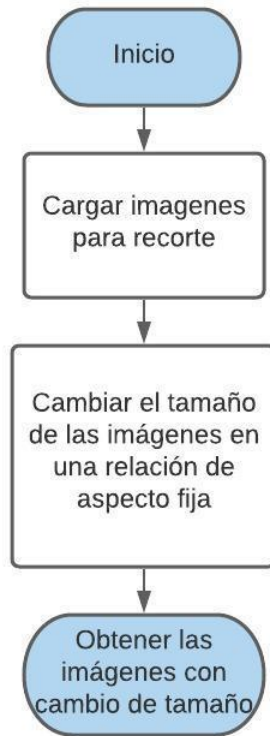
8. BIBLIOGRAFÍA

- [1] B. Estevan and C. Alio, "Úlceras por presión," *Geriatrka*, vol. 12, no. 5, pp. 58–62, 1996.
- [2] "tratado_de_geriatria[1]-Flip eBook Pages 751 - 782| AnyFlip | AnyFlip." <http://anyflip.com/iwaf/sjfb/basic/751-782> (accessed May 02, 2021).
- [3] C. Pedro Gil Gregorio, D. Paloma González García, J. Gutiérrez Rodríguez, and C. Verdejo Bravo, *MANUAL DEL RESIDENTE EN GERIATRÍA COMITÉ EDITORIAL*. 2011.
- [4] F. Pedro Garcia Fernandez and J. Javier Soldevilla Agreda, "TERESA SEGOVIA GÓMEZ," 2012.
- [5] "Heridas y Úlceras por Presión | Cursos Enfermería | Salusplay." <https://www.salusplay.com/apuntes/heridas-cronicas-y-ulceras-por-presion> (accessed May 02, 2021).
- [6] "GNEAUPP - Grupo Nacional para el Estudio y Asesoramiento en Úlceras por Presión y Heridas Crónicas." <https://gneaupp.info/> (accessed May 02, 2021).
- [7] U. por, "Guía de cuidados enfermeros."
- [8] C. Verdejo Bravo, "Management of heart failure in the elderly. Who and where? Vision of geriatrics," *Revista Espanola de Geriatria y Gerontologia*, vol. 37, no. 1. Ediciones Doyma, S.L., pp. 5–12, Jan. 01, 2002, doi: 10.1016/s0211-139x(02)74767-7.
- [9] G. Ruiz-Rozas, M. Mateo, H. Ballestar, P. Monferrer, M. Forés, and L. Tudela, "As Guías de Fisterra Úlceras por presión."
- [10] R. GOMIS, "Inteligencia artificial en medicina," Sep. 05, 2019. <https://cienciasdelasalud.blogs.uoc.edu/inteligencia-artificial-en-medicina/> (accessed May 02, 2021).
- [11] "La diferencia entre Inteligencia Artificial, Machine Learning y Deep Learning | by SPOT | Medium." https://medium.com/@spot_blog/la-diferencia-entre-inteligencia-artificial-machine-learning-y-deep-learning-cc415f20e63a (accessed May 02, 2021).
- [12] "S12_Keras intro y analisis tensorial.ipynb - Colaboratory." https://colab.research.google.com/github/jdamaster/machineLearningDiplomat/blob/master/S12_Keras_intro_y_analisis_tensorial.ipynb#scrollTo=BTDmhfQ31dI5 (accessed May 02, 2021).
- [13] "Inteligencia artificial en medicina: casos reales de éxito." <https://blog.enzymeadvisinggroup.com/inteligencia-artificial-en-la-medicina> (accessed May 02, 2021).
- [14] I. - Ministerio de Sanidad and S. Sociales Igualdad, *Guía para la Prevención y Manejo de las UPP y Heridas Crónicas*. .
- [15] J. E. Valdivia-Silva, R. Salazar, and B. Malpartida, "Educación Médica continua Inflammation in the pathogenesis of pressure ulcers and their detection by new technologies," 2017.
- [16] I. García, F. Tutoras, D. Carmen, S. Gotarredona, D. Begoña, and A. Piñero, "Aportaciones a la Segmentación y Caracterización de Imágenes Médicas 3D."
- [17] "Segmentación (procesamiento de imágenes) - Wikipedia, la enciclopedia libre." [https://es.wikipedia.org/wiki/Segmentaci3n_\(procesamiento_de_im3genes\)](https://es.wikipedia.org/wiki/Segmentaci3n_(procesamiento_de_im3genes)) (accessed May 02, 2021).
- [18] "Inteligencia Artificial en la Medicina | Machine Learning - Colombia | IBM."

- <https://www.ibm.com/co-es/watson-health/learn/artificial-intelligence-medicine> (accessed May 02, 2021).
- [19] "Redes neuronales convolucionales son un tipo de redes neuronales." <https://www.juanbarrios.com/redes-neurales-convolucionales/> (accessed May 02, 2021).
- [20] Q. Shan, Z. Li, J. Jia, and C. K. Tang, "Fast image/video upsampling," *ACM Trans. Graph.*, vol. 27, no. 5, Dec. 2008, doi: 10.1145/1409060.1409106.
- [21] "(No Title)." <https://academica-e.unavarra.es/xmlui/bitstream/handle/2454/37479/Memoria.pdf?sequence=1&isAllowed=y> (accessed May 07, 2021).
- [22] C. S. Gotarredona, "Implementación basada en aprendizaje profundo (Deep Learning) para la segmentación de lesiones pigmentadas de la piel Portada," 2020.
- [23] "Inteligencia artificial fácil Machine Learning y Deep Learning prácticos - Funciones de pérdida (Loss function)." <https://www.ediciones-eni.com/open/mediabook.aspx?idR=8dd2ca32769cb24b49648b15ef8e777e> (accessed May 11, 2021).
- [24] "Estudio detallado del AA: Entrenamiento y pérdida." <https://developers.google.com/machine-learning/crash-course/descending-into-ml/training-and-loss?hl=es> (accessed May 09, 2021).
- [25] "Métricas De Evaluación De Modelos En El Aprendizaje Automático." <https://www.datasource.ai/es/data-science-articles/metricas-de-evaluacion-de-modelos-en-el-aprendizaje-automatico> (accessed May 10, 2021).
- [26] "Conceptos básicos sobre redes neuronales." <https://vincentblog.xyz/posts/conceptos-basicos-sobre-redes-neuronales> (accessed May 10, 2021).
- [27] "Cómo interpretar la matriz de confusión: ejemplo práctico - Think Big Empresas." <https://empresas.blogthinkbig.com/como-interpretar-la-matriz-de-confusion-ejemplo-practico/> (accessed May 10, 2021).

ANEXOS

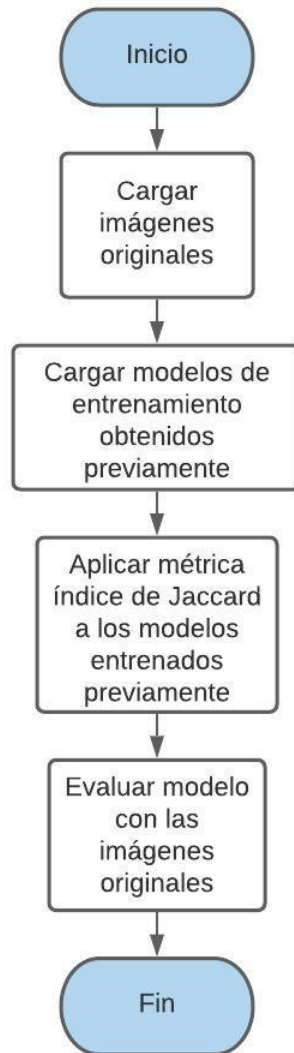
Algoritmo "Resize Images"



Algoritmo "Segmentación imágenes"



Algoritmo “Visualizar segmentación”



Algoritmo “Detección de úlceras por presión”

