



UNIVERSIDAD AUTÓNOMA DE AGUASCALIENTES
CENTRO DE CIENCIAS DE LA SALUD

HOSPITAL GENERAL DE ZONA NO. 3, JESUS MARÍA;
AGUASCALIENTES

**“DESEMPEÑO DE REDES NEURONALES
CONVOLUCIONALES PARA LA IDENTIFICACIÓN DE
HALLAZGOS EN TOMOGRAFÍA DE PACIENTES CON
DIVERTICULITIS AGUDA EN EL HOSPITAL GENERAL DE
ZONA NO. 3, OOAD AGUASCALIENTES”**

**TESIS PRESENTADA POR YAIR HERNANDEZ CARLOS
PARA OBTENER EL GRADO DE
ESPECIALISTA EN CIRUGÍA
GENERAL**

**TUTOR
DR. JOSÉ LUIS BIZUETO MONROY**

**AGUASCALIENTES, AGUASCALIENTES
FEBRERO DE 2026**

DICTAMEN DE APROBACIÓN COMITÉ DE INVESTIGACIÓN

Dictamen de Aprobado

Comité Local de Investigación en Salud **101**.
H GRAL ZONA NUM 1

Registro COFEPRIS **17 CI 01 001 038**
Registro CONBIOÉTICA **CONBIOETICA 01 CEI 001 2018082**

FECHA **Miércoles, 05 de febrero de 2025**

Doctor (a) **JOSE LUIS BIZUETO MONROY**

P R E S E N T E

Tengo el agrado de notificarle, que el protocolo de investigación con título **DESEMPEÑO DE REDES NEURONALES CONVOLUCIONALES PARA LA IDENTIFICACIÓN DE HALLAZGOS EN TOMOGRAFÍA DE PACIENTES CON DIVERTICULITIS AGUDA EN EL HOSPITAL GENERAL DE ZONA NO. 3, OOAD AGUASCALIENTES** que sometió a consideración para evaluación de este Comité, de acuerdo con las recomendaciones de sus integrantes y de los revisores, cumple con la calidad metodológica y los requerimientos de ética y de investigación, por lo que el dictamen es **A P R O B A D O**:

Número de Registro Institucional

R-2025-101-008

De acuerdo a la normativa vigente, deberá presentar en junio de cada año un informe de seguimiento técnico acerca del desarrollo del protocolo a su cargo. Este dictamen tiene vigencia de un año, por lo que en caso de ser necesario, requerirá solicitar la reaprobación del Comité de Ética en Investigación, al término de la vigencia del mismo.

ATENTAMENTE



Doctor (a) **CARLOS ARMANDO SANCHEZ NAVARRO**
Presidente del Comité Local de Investigación en Salud No. 101

DICTAMEN DE APROBACIÓN COMITÉ DE ÉTICA



INSTITUTO MEXICANO DEL SEGURO SOCIAL
SEGURIDAD Y SOLIDARIDAD SOCIAL

"Dictamen de Reaprobación"

COOR CLINICA DE CIRUGIA, HOSP GRAL ZONA 3
Comité de Ética en Investigación **1018**

Viernes, 27 de junio de 2025

CONBIOETICA 01 CEI 001 2018082

DOCTOR (A) JOSE LUIS BIZUETO MONROY

P R E S E N T E

En atención a su solicitud de evaluación de documentos del protocolo de investigación con título: **DESEMPEÑO DE REDES NEURONALES CONVOLUCIONALES PARA LA IDENTIFICACIÓN DE HALLAZGOS EN TOMOGRAFÍA DE PACIENTES CON DIVERTICULITIS AGUDA EN EL HOSPITAL GENERAL DE ZONA NO. 3, OOAD AGUASCALIENTES**, y número de registro institucional **R-2025-101-008**; me permito informarle que el Comité de Ética en Investigación revisó y aprobó la solicitud de reaprobación del **27 de Junio de 2025 al 27 de Junio de 2026**

ATENTAMENTE

DOCTOR (A) AGUILAR MERCADO VIRGINIA VERONICA
Presidente del Comité de Ética en Investigación No. 1018

CARTA DE APROBACIÓN TRABAJO DE TESIS



CARTA DE APROBACIÓN DE TRABAJO DE TESIS

COMITÉ DE INVESTIGACIÓN Y ÉTICA EN INVESTIGACIÓN EN SALUD 101
HOSPITAL GENERAL DE ZONA No.1, AGUASCALIENTES

AGUASCALIENTES, AGS, 25 DE SEPTIEMBRE DE 2025

DRA. JANNETT PADILLA LÓPEZ
COORDINADOR AUXILIAR MÉDICO DE INVESTIGACIÓN EN SALUD
P R E S E N T E

Por medio de la presente le informo que la Residente de la Especialidad de Cirugía General del Hospital General de Zona No. 3 del Instituto Mexicano del Seguro Social de la Delegación Aguascalientes.

DR. YAIR HERNANDEZ CARLOS

Ha concluido satisfactoriamente con el trabajo de titulación denominado:

"DESEMPEÑO DE REDES NEURONALES CONVOLUCIONALES PARA LA IDENTIFICACIÓN DE HALLAZGOS EN TOMOGRAFÍA DE PACIENTES CON DIVERTICULITIS AGUDA EN EL HOSPITAL GENERAL DE ZONA NO. 3, OOAD AGUASCALIENTES"

Número de Registro: **R-2025-101-008** del Comité Local de Investigación y Ética en Investigación en Salud No. 101.

Elaborado de acuerdo con la opción de titulación: **TESIS**.

El **DR. YAIR HERNANDEZ CARLOS** asistió a las asesorías correspondientes y realizó las actividades apegadas al plan de trabajo, por lo que no tengo inconvenientes para que se proceda a la impresión definitiva ante el comité que usted preside, para que sean realizados los trámites correspondientes a su especialidad. Sin otro particular, agradezco la atención que sirva a la presente, quedando a sus órdenes para cualquiera aclaración.

ATENTAMENTE:

**DRA. ELIZABETH G.
HERNANDEZ INFANTE**

**COORDINADOR CLÍNICO DE
EDUCACIÓN E
INVESTIGACIÓN EN SALUD**

**DR. JOSE LUIS BIZUETO
MONROY**

PROFESOR TITULAR

**DR. JOSE LUIS BIZUETO
MONROY**

**ASESOR O DIRECTOR DE
TESIS**

CARTA CONCLUSIÓN TRABAJO DE TESIS



AGUASCALIENTES, AGS, 25 DE SEPTIEMBRE DE 2025

DR. SERGIO RAMIREZ GONZALEZ
DECANO DEL CENTRO DE CIENCIAS DE LA SALUD

P R E S E N T E

Por medio de la presente le informo que la Residente de la Especialidad de Cirugía General del Hospital General de Zona No. 3 del Instituto Mexicano del Seguro Social de la Delegación Aguascalientes.

DR. YAIR HERNANDEZ CARLOS

Ha concluido satisfactoriamente con el trabajo de titulación denominado:

“DESEMPEÑO DE REDES NEURONALES CONVOLUCIONALES PARA LA IDENTIFICACIÓN DE HALLAZGOS EN TOMOGRAFÍA DE PACIENTES CON DIVERTICULITIS AGUDA EN EL HOSPITAL GENERAL DE ZONA NO. 3, OOAD AGUASCALIENTES”

Número de Registro: **R-2025-101-008** del Comité Local de Investigación y Ética en Investigación en Salud No. 101.

Elaborado de acuerdo con la opción de titulación: **TESIS**.

El **DR. YAIR HERNANDEZ CARLOS**, asistió a las asesorías correspondientes y realizó las actividades apegadas al plan de trabajo, cumpliendo con la normatividad de investigación vigente en el Instituto Mexicano del Seguro Social.

Sin otro particular, agradezco a usted su atención, enviándole un cordial saludo.

ATENTAMENTE:

DRA. JANNETT PADILLA LÓPEZ

COORDINADOR AUXILIAR MEDICO DE INVESTIGACION EN SALUD

EVIDENCIA DE ENVÍO A REVISTA CIENTÍFICA

ANALES DE RADIOLOGÍA MÉXICO. SMRI



Órgano Oficial de la Sociedad Mexicana de Radiología e Imagen, A.C.



Yair ▾

AUTOR ▾

ARTÍCULOS

10▾

items/página

Buscar...

CÓDIGO	TÍTULO	ESTADO
ARM/0079/25	Desempeño de Redes Neuronales Convolucionales en la caracterización de hallazgos en tomografía de pacientes con diverticulitis aguda.	Pendiente de validación 

Mostrando registros del 1 al 1 de un total de 1 registros

Anterior

1

Siguiente

ANALES DE RADIOLOGÍA MÉXICO. SMRI



Órgano Oficial de la Sociedad Mexicana de Radiología e Imagen, A.C.



PERMANYER MÉXICO

www.permayer.com

Estimado/a Dr/Dra Yair,

Gracias por su interés en nuestra publicación. Le confirmamos que el artículo "[Desempeño de Redes Neuronales Convolucionales en la caracterización de hallazgos en tomografía de pacientes con diverticulitis aguda.](#)" ([ARM/0079/25](#)) se ha registrado correctamente en nuestro sistema.

El Comité Editorial de Revista Anales de Radiología con todo gusto revisará su manuscrito y en breve nos comunicaremos con Usted.

Muchas gracias y saludos cordiales,

El Editor

Revista Anales de Radiología



online

Manuscript Submission

Temístocles 315, Dept. 404. - Col Polanco, Del. Miguel Hidalgo

México D.F., 11560 | ana.gutierrez@permayer.com

TESIS TESIS TESIS TESIS TESIS

En cumplimiento con el Art. 136 fracción II, inciso g) del Reglamento General de Posgrado que a la letra señala: autorización de la persona titular del Decanato del Centro de Ciencias de la Salud.

AGRADECIMIENTOS

El presente trabajo representa la culminación del esfuerzo realizado día con día por todas las personas que me apoyaron a lo largo del camino de mi desarrollo profesional, desde el primer día en que pisé un aula de la escuela de medicina, hasta el día de hoy que continúo en el camino de convertirme en el especialista que me propuse al iniciar esta aventura.

En primer lugar quiero agradecer a mi familia: a mi madre, Lorena, quien con su amor incondicional ha sido mi mayor refugio en los momentos difíciles y la mejor cómplice al momento de celebrar los triunfos, gracias por estar conmigo en la distancia con cada llamada y en la cercanía con cada visita y recepción en casa con tus abrazos y palabras de aliento. Gracias a ti he podido sentir el confort y amor como si estuviera en casa.

A mi padre, Jorge Luis, por su sacrificio día a día, trabajando sin descanso durante más de treinta años para poder brindarnos a mi hermana y a mí una educación de calidad y las oportunidades para formarnos como personas de bien.

A Saachie, mi hermana menor y compañera de vida, quien ha sido mi mejor amiga y confidente en cada una de las aventuras que hemos tenido a través de nuestro crecimiento juntos. Gracias por enseñarme a ser una mejor persona y a mostrarme cada vez el mundo de una forma diferente.

A Sofía, ya que sin ella el desarrollo y éxito de este trabajo no hubiera sido posible, gracias por creer en este proyecto y por brindarme a través de todos estos años tu amistad, por ser una inspiración y un ejemplo de las increíbles cosas que se pueden lograr con dedicación, esfuerzo y constancia. Espero algún día en el futuro cercano poder “salvar al mundo” junto a ti como te lo propuse desde el día que te conocí.

Al Dr. José Luis Bizueto, mi profundo agradecimiento, porque pese a las adversidades siempre ha sido un firme pilar y respaldo en la formación de nosotros como cirujanos y como personas, por dedicarnos su valioso tiempo, por su compromiso y pasión por la enseñanza que nos brinda día a día desde el inicio y hasta el día de hoy.

DEDICATORIA

A mis pacientes, por su confianza y enseñanza, por permitirme formar parte de sus momentos de mayor vulnerabilidad. En cada uno de ustedes encontré una lección de humanidad, paciencia y resiliencia, así como el verdadero significado de la responsabilidad, la empatía y el compromiso que implica ejercer la cirugía.

Gracias por ser mi mayor fuente de aprendizaje y motivación.



ÍNDICE

1.	ÍNDICE DE TABLAS	3
2.	ÍNDICE DE GRAFICAS E IMÁGENES	3
3.	RESUMEN.....	4
4.	ABSTRACT.....	6
5.	INTRODUCCIÓN	8
6.	ANTECEDENTES CIENTÍFICOS	9
A.	DIAGRAMA PRISMA.....	11
7.	MARCO TÉORICO	12
A.	MODELOS Y TEORÍAS	12
III.	CLASIFICACIÓN DE LA ENFERMEDAD DIVERTICULAR:.....	15
IV.	APLICACIÓN DE IMAGEN EN EL ABORDAJE TERAPÉUTICO DE DIVERTICULITIS.....	15
8.	MARCO CONCEPTUAL:.....	18
9.	JUSTIFICACIÓN:	20
10.	PLANTEAMIENTO DEL PROBLEMA.....	21
A.	MAGNITUD Y FRECUENCIA.....	21
B.	CAUSAS PROBABLES DEL PROBLEMA.....	22
C.	SOLUCIONES POSIBLES Y PREGUNTAS SIN RESPUESTA	22
11.	PREGUNTA DE INVESTIGACIÓN:	22
12.	OBJETIVOS.....	23
A.	OBJETIVO GENERAL	23
B.	OBJETIVOS ESPECÍFICOS.....	23
13.	HIPÓTESIS	24
14.	MATERIAL Y MÉTODOS	24
A.	TIPO DE ESTUDIO:.....	24
B.	CRITERIOS DE SELECCIÓN.....	24
C.	CRITERIOS DE EXCLUSIÓN.....	24
D.	CRITERIOS DE ELIMINACIÓN	24
E.	DISEÑO DEL ESTUDIO	25
F.	TAMAÑO DE LA MUESTRA.....	25
H.	FUENTE DE DATOS.....	27
I.	ANÁLISIS ESTADÍSTICO:.....	28
15.	DESCRIPCIÓN DE VARIABLES Y OPERACIONALIZACIÓN DE VARIABLES.....	29
16.	PROCESAMIENTO Y ANÁLISIS DE DATOS.....	31
A.	PROCEDIMIENTO PARA RECOLECCION.....	31
17.	INSTRUMENTOS UTILIZADOS:.....	33
18.	ANÁLISIS DE DATOS	34

19. CONSIDERACIONES ÉTICAS..... 34

20. RECURSOS FINANCIEROS Y FACTIBILIDAD 37

 RECURSOS HUMANOS.....37

 FACTIBILIDAD37

21. MARCO ANALÍTICO..... 38

 A. PROCESAMIENTO DE DATOS38

22. RESULTADOS..... 39

 ENTRENAMIENTO Y VALIDACIÓN.....39

23. DISCUSIONES..... 51

24. CONCLUSIONES 53

FUENTES BIBLIOGRÁFICAS..... 54

ANEXOS 56

 A. CRONOGRAMA DE ACTIVIDADES56

 B. CARTA DE CONSENTIMIENTO.57

 C. RESULTADO DEL CHECKLIST GUÍA CLAIM PARA PUBLICACIÓN DE INVESTIGACIONES DE INTELIGENCIA ARTIFICIAL EN IMAGEN.....59

 D. EJEMPLIFICACIÓN DE LA APLICACIÓN 2D EN MAPA BINARIO.....61

 E. MANUAL OPERACIONAL DIAGRAMA DE FLUJO PARA LA APLICACIÓN RADIOMICA EN EL ANÁLISIS DE IMÁGENES.61

 F. CÓDIGO PYTHON DE ALGORITMO DESARROLLADO PARA EL ANÁLISIS DE IMÁGENES (RED NEURONAL).....62

 G. EPOCAS DE ENTRENAMIENTO ALGORITMO64

1. ÍNDICE DE TABLAS

Tabla 1. Frecuencia de imágenes clasificadas manualmente como con hallazgos con y sin diverticulitis	41
Tabla 2. Frecuencia de imágenes clasificadas por algoritmo como con hallazgos con y sin diverticulitis.	41
Tabla 3. Relación de resultados arrojados por algoritmo (Clase Predicha) Vs Etiquetado manual (Clase verdadera).	42
Tabla 4. Interpretación de datos de tabla cruzada.....	42
Tabla 5. Variables analizadas por algoritmo y los resultados obtenidos.	44
Tabla 6. Resultado de Estudios de sets de validación 40 imágenes (20 sanos y 20 conocidos con enfermedad).....	47

2. ÍNDICE DE GRAFICAS E IMÁGENES

Gráfico. 1. Matriz de Confusión obtenida del análisis de sets de validación	47
Imagen. 1. Interfaz de usuario de análisis de imágenes de tomografía con mapa de saliencia.49	
Imagen. 2 Mapas de saliencia con evidencia de Diverticulitis señalada con mapas de calor, a mayor incandescencia, mayor probabilidad de presentar hallazgos de diverticulitis.....	50

3. RESUMEN

TÍTULO: Desempeño de redes neuronales convolucionales para la Identificación de hallazgos en tomografía de pacientes con diverticulitis aguda en el hospital General de Zona No. 3, OOAD Aguascalientes.

INTRODUCCIÓN: La diverticulitis aguda es una causa prevalente de hospitalización que representa un desafío diagnóstico para el cirujano general. La tomografía computada (TC) constituye el estándar de oro para su clasificación, aunque su eficacia depende de la interpretación humana y la disponibilidad de especialistas experimentados. En este escenario, la inteligencia artificial (IA), mediante redes neuronales convolucionales (CNN), surge como una herramienta prometedora para automatizar la detección de patrones radiológicos y optimizar el proceso diagnóstico clínico. No obstante, la evidencia sobre su aplicación en patologías inflamatorias abdominales aún es limitada.

MATERIAL Y MÉTODOS: Se realizó un estudio descriptivo-correlacional, no experimental y transversal con diseño instrumental. Se implementó un algoritmo de aprendizaje profundo bajo la arquitectura ResNet-18, utilizando imágenes de TC abdominal de pacientes con diagnóstico confirmado del HGZ No. 3 (IMSS Aguascalientes), complementadas con bases de datos públicas de referencia. Las imágenes fueron etiquetadas manualmente y segmentadas en tres conjuntos: entrenamiento (64%), validación (16%) y prueba (20%). El modelo fue evaluado mediante métricas de desempeño diagnóstico (exactitud, sensibilidad, especificidad, valores predictivos y F1 Score) y métricas de segmentación (índices de Jaccard/IoU y de Dice). Se cumplieron las guías éticas institucionales y el checklist CLAIM 2024 para investigaciones de IA en imagen médica.

RESULTADOS: De una cohorte de 109 pacientes, se analizaron 40 estudios con 10,225 cortes. El algoritmo obtuvo una exactitud de 96.4%, sensibilidad de 94.1%, especificidad de 97.6%, valor predictivo positivo de 94.8% y un F1 Score de 94.4%. A nivel de estudio, clasificó correctamente los 20 casos positivos. En segmentación, alcanzó un índice de Jaccard de 0.80 y un coeficiente de Dice de 0.89, confirmando una alta concordancia con la referencia.

CONCLUSIÓN: El algoritmo demostró un desempeño robusto, comparable al juicio experto. Esta herramienta puede apoyar el triage radiológico y la toma de decisiones quirúrgicas, fortaleciendo la precisión diagnóstica. El estudio permite proyectar validaciones multicéntricas para futuras implementaciones clínicas.

PALABRAS CLAVE: Diverticulitis aguda; Inteligencia artificial; Redes neuronales convolucionales; Tomografía computarizada; Índice de Jaccard; Coeficiente de Dice.



4. ABSTRACT

TITLE:

Performance of Convolutional Neural Networks for the Identification of Findings in CT Scans of Patients with Acute Diverticulitis at Hospital General de Zona No. 3, OOAD Aguascalientes

BACKGROUND: Acute diverticulitis is a common cause of hospital admission and a significant public health burden due to its recurrent nature and diagnostic complexity. Computed tomography remains the gold standard for diagnosis and disease staging. However, image interpretation depends on radiologist expertise. In this context, artificial intelligence particularly convolutional neural networks, offers the potential to assist clinicians in image-based decision-making by automatically identifying patterns associated with diverticulitis.

OBJECTIVE: To develop and validate a convolutional neural network algorithm capable of identifying CT findings compatible with acute diverticulitis using local hospital imaging data and open-access repositories.

METHODS: A descriptive-correlational, non-experimental, cross-sectional study with an instrumental design was conducted following the CLAIM 2024 checklist for AI in medical imaging. The algorithm was built using a semi-supervised learning approach with the ResNet-18 architecture, employing three independent datasets for training (64%), validation (16%), and testing (20%). Performance metrics included accuracy, sensitivity, specificity, positive predictive value, negative predictive value, F1 Score, and overlap indices (Jaccard/IoU and Dice coefficient). Data were analyzed using MATLAB and Python environments.

RESULTS: A total of 109 patients with acute diverticulitis were reviewed, and 40 CT studies comprising approximately 10,225 axial slices were analyzed. The algorithm achieved an **accuracy of 96.4%, sensitivity 94.1%, specificity 97.6%, PPV 94.8%, NPV 97.3%, and F1 Score 94.4%.** At the case level, it correctly classified all 20 positive cases and produced 5 false positives among 20 controls. Overlap evaluation showed a **Jaccard index of 0.80**

and a **Dice coefficient of 0.89**, confirming excellent agreement between predicted and true labels. Saliency maps highlighted relevant radiological features, such as pericolic fat stranding and segmental wall thickening.

CONCLUSIONS: The CNN-based algorithm (ResNet-18) demonstrated high diagnostic performance for detecting acute diverticulitis in CT scans. This AI-assisted tool has potential clinical value as a triage aid and decision-support system, complementing radiologist and surgeon expertise. Further multicentric and prospective studies are warranted to validate its external generalizability and clinical impact.

KEYWORDS: Acute diverticulitis; Artificial intelligence; Convolutional neural networks; Radiomics; Computed tomography; Jaccard index; Dice coefficient.

5. INTRODUCCIÓN

La enfermedad diverticular del colon representa un problema de salud pública en constante crecimiento, particularmente en las sociedades occidentales, donde los cambios en los hábitos alimenticios, el envejecimiento poblacional y el aumento de enfermedades metabólicas han favorecido su incremento. La diverticulitis aguda, como complicación más frecuente, constituye una causa importante de hospitalización y gasto sanitario, siendo su diagnóstico preciso fundamental para evitar desenlaces adversos (1). En la actualidad se cuentan con herramientas diagnósticas con alta sensibilidad y especificidad para el diagnóstico de la enfermedad diverticular y sus complicaciones como lo es la tomografía computada, que nos ha permitido realizar modificaciones a la clasificación original propuesta por Hinchey en la década de los 70s(2). Desde la modificación de la clasificación de Hinchey en 2005 la tomografía computada abdominal es considerada el estándar de oro para su evaluación, permitiendo la clasificación, estadificación y planeación terapéutica. Con la llegada de nuevas tecnologías, como lo fue en su tiempo la tomografía de abdomen y en la actualidad el uso de la inteligencia artificial (IA) y el aprendizaje automático, se han transformado múltiples campos de la ciencia médica y no es la excepción la radiología, y la cirugía al facilitar esta tecnología el análisis automatizado de grandes volúmenes de imágenes diagnósticas. (3)

Dentro de estas tecnologías, las redes neuronales convolucionales (CNN) han demostrado un alto rendimiento en la identificación de patrones complejos en imágenes médicas, mejorando la precisión diagnóstica y reduciendo la carga de trabajo del especialista.(4)

En este contexto, la presente investigación tuvo como propósito desarrollar y validar un algoritmo basado en redes neuronales convolucionales capaz de identificar hallazgos compatibles con diverticulitis aguda en estudios de tomografía computada de abdomen. El proyecto se llevó a cabo en el Hospital General de Zona No. 3 del Instituto Mexicano del Seguro Social en Aguascalientes, utilizando imágenes de tomografía de pacientes con diagnóstico confirmado y bases de datos de acceso libre para el entrenamiento y validación del modelo.

Este estudio busca contribuir al conocimiento sobre la aplicación de la inteligencia artificial en el ámbito quirúrgico y radiológico, proponiendo una herramienta que complemente la práctica médica y optimice la toma de decisiones clínicas mediante un enfoque tecnológico, preciso y éticamente responsable.

6. ANTECEDENTES CIENTÍFICOS

Se realizó una búsqueda sistemática en bases de datos con la intención de consultar diversas fuentes de conocimiento accesibles en nuestro medio, se utilizaron los buscadores de PubMed y la Biblioteca Virtual de Salud, utilizando los siguientes descriptores con los operadores booleanos AND y OR.

Search: ((DIVERTICUL*[Title/Abstract]) AND (TOMOGRAPHY[Title/Abstract])) AND ((Artificial Intelligence [Title/Abstract]) OR (RADIOMICS[Title/Abstract]))

(Ziegelmayr et al. 2023) En un estudio experimental titulado: **Development and validation of a Deep Learning Algorithm to Differentiate Colon carcinoma From Acute Diverticulitis in Computed Tomography.** En donde se realiza el desarrollo de un algoritmo de aprendizaje profundo para diferenciar el carcinoma de colon y la diverticulitis aguda en estudios de imagen tomográficos para de esta forma analizar el impacto que tiene el uso de inteligencia artificial en la interpretación de los mismos y cómo puede el uso de esta tecnología mejorar el rendimiento diagnóstico de radiólogos específicamente en la reducción de falsos-negativos, lo cual a su vez impacta de manera positiva el pronóstico de los pacientes.

En el estudio antes mencionado se observó a 10 médicos radiólogos de diferentes niveles de experiencia y en él se solicitó la revisión y clasificación de una cohorte de paciente con y sin el apoyo de un algoritmo de inteligencia artificial. Se incluyeron en el estudio pacientes que fueron sometidos a cirugía entre Julio de 2005 y Octubre de 2020 por diverticulitis aguda y por carcinoma de colon con confirmación histológica, para su análisis se incluyeron imágenes 3-D de paciente en fase venosa hasta 60 días preoperatorios con engrosamiento segmentario de la pared colónica se desarrolló un modelo de procesamiento de imágenes, entrenamiento y evaluación utilizando el software de Python y Tensor Flow con la finalidad de desarrollar una red neural convolucional. Como resultado del análisis de un total de 585 pacientes se concluyó que el grupo combinado de médicos radiólogos mejoró significativamente con el apoyo de la inteligencia artificial desde una sensibilidad del 77-6% a 85-6% (IC 95% $p < .001$) y especificidad de 81-6% a 91.3· (IC 95% $p < .001$). Con ello la

inteligencia artificial redujo el número de falsos negativos y falsos positivos (valor predictivo negativo de 78.5% a 86.4% y un valor predictivo positivo de 80.9% a 90.8%; $p < .001$) así se concluye que el modelo de aprendizaje profundo puede distinguir la diverticulitis aguda del cáncer de colon y puede mejorar de manera significativa el rendimiento diagnóstico de los radiólogos. (5)

(Winkel et al. 2019) Condujo un estudio de casos y controles titulado: **Evaluation of an AI-Based Detection Software for Acute Findings in Abdominal Computed Tomography Scans. Toward an Automated Work List Prioritization of Routine CT Examinations.** El objetivo de este estudio fue probar el rendimiento diagnóstico de modelos basados en el aprendizaje profundo a manera de triage para la detección de hallazgos agudos en estudios tomográficos.

Se realizó un estudio experimental utilizando un algoritmo de red neural convolucional previamente entrenado para la detección de hallazgos agudos en imagen. Se utilizó un motor de búsqueda PACS (picture Archiving and Communication System) donde se obtuvieron 100 tomografías abdominales con al menos uno de los siguientes hallazgos: (aire libre, líquido libre, estriación de la grasa) y 100 casos controles con ausencia de estos hallazgos. Como instrumento de validación se realizó en un sistema basado en la retroalimentación de un radiólogo con 1 año de experiencia en imagen abdominal, sin conocimiento previo de los hallazgos de imagen mediante la interpretación o reporte escrito de referencia

Como resultado se incluyeron un total de 194 casos en el análisis 6 fueron excluidos debido a problemas técnicos, en el análisis de estos el algoritmo logró una sensibilidad del 93% 7 falsos negativos y especificidad de 97% (3 falsos positivos) en la detección de hallazgos agudos abdominales.

Como conclusión, el algoritmo autónomo de detección de hallazgos patológicos demostró un alto rendimiento diagnóstico, permitiendo así su uso como herramienta para priorizar análisis de tomografías con condiciones agudas. (6)

a. **DIAGRAMA PRISMA**

Identificación de nuevos estudios vía base de datos y archivos



7. MARCO TEÓRICO

a. MODELOS Y TEORÍAS

El uso de nuevas tecnologías aplicadas a la ciencia de la salud ha abierto un nuevo campo de oportunidad para la atención médica y la implementación biomédica y de investigación.

La digitalización de la atención médica ha logrado generar una amplia cantidad de información y con ello el surgimiento de un campo de la medicina que busca la fusión de la ciencia computacional y estadística a los problemas médicos.

Se cree que el aprendizaje automático (Machine learning) es el futuro para la investigación biomédica, medicina personalizada y diagnóstico asistido por computadora para así mejorar el área de la salud de manera global.

i. INTELIGENCIA ARTIFICIAL Y MACHINE LEARNING

La inteligencia artificial ha prometido revolucionar la medicina desde hace un par de décadas, sin embargo, recientemente han existido avances en esta área de la tecnología que podrían convertir en realidad esta promesa.

El término de aprendizaje automático o "Machine Learning" fue acuñado en 1959 por Arthur Samuel, usualmente los términos de "Machine learning" e inteligencia artificial son utilizados de forma intercambiable, sin embargo, no es del todo correcto. Inteligencia artificial se refiere al concepto de máquina pensante, capaz de tomar decisiones de manera automatizada, mientras que Arthur Samuel describe machine learning como darles a las computadoras la habilidad de aprender sin ser explícitamente programadas, siendo así la premisa principal es introducir algoritmos que analicen datos ingresados para identificar patrones y tendencias para así finalmente aprender de experiencia previa.

Existen así diversas aplicaciones del machine learning en el campo médico como lo son la medicina personalizada, la terapéutica dirigida, la hematología, oncología y patología. Sin embargo, para la presente investigación nos enfocaremos en su uso en la cirugía y la radiología.

En cirugía se ha utilizado de manera más común en dos campos: Robótica y apoyo a la toma de decisiones; mientras que en el campo de la robótica su aplicación es técnica en el

TESIS TESIS TESIS TESIS TESIS

apoyo de tareas simples, en la toma de decisiones se utiliza para identificar candidatos quirúrgicos, complicaciones postoperatorias y predicción de resultados finales de acuerdo con procedimientos previamente planteados.

En el campo de la radiología las técnicas de machine learning han crecido debido a que esta es una especialidad que maneja información predominantemente de datos digitales, imágenes y reportes textuales.

El potencial para el reconocimiento automatizado y análisis de imágenes es único y es por ello que esta área ha comenzado a desarrollarse comercialmente. El análisis de imágenes apoyado por computadora se ha vuelto más prevalente en disminuir la carga de trabajo de médicos radiólogos y ha sido aplicado en la segmentación de imágenes donde la computadora aprende a separar estructuras y órganos.

Se han propuesto también sistemas basados en la recuperación de imágenes para la búsqueda de similitud entre imágenes alimentadas por el análisis de texto de reportes radiológicos y con ello la creación de base de datos como lo es el consorcio de datos de imágenes pulmonares. (7)

Existen así típicamente cuatro tareas que se solicitan de un algoritmo de machine learning, la primera es la regresión, donde un valor numérico resulta de cierta entrada dada, la segunda es clasificación, donde resulta una etiqueta indicativa de membresía en un grupo especificado o set matemático, la tercera y cuarta pertenecen a las aplicaciones computacionales, la tercera es segmentación la cual es simplemente una clasificación a nivel de píxeles y la última es la detección de objetos, una tarea híbrida con elementos de regresión y clasificación, donde un subgrupo de los datos introducidos son partidos y localizados. (4)

Los modelos de machine learning, en específico el modelo de aprendizaje supervisado tiene la meta de predecir un objetivo conocido, por ejemplo, clasificación de objetos, tareas que son realizables por una persona entrenada en radiología. La detección automática de nódulos pulmonares en estudios de rayos x, por ejemplo(8)

Así mismo se han investigado redes híbridas (una combinación de machine learning y deep learning) lo cual permitirá la predicción de la supervivencia o la severidad de los padecimientos al integrar las características de las lesiones encontradas con los datos clínicos y laboratoriales de los pacientes.

El uso de modelos radiómicos, los cuales utilizan machine learning avanzado y caracterización de imágenes han comenzado a esparcirse debido a que son simples y no invasivos y pueden ayudar en el diagnóstico y en la toma de decisiones personalizadas prediciendo así el pronóstico y respuesta al tratamiento. (3).

ii. APLICACIÓN EN EL CAMPO QUIRÚRGICO

A nivel mundial, la tomografía de abdomen y pelvis es considerada como el mejor método de imagen para la evaluación de la enfermedad diverticular, cumpliendo así las siguientes funciones: Confirmar la presencia de diverticulitis colónica aguda, la evaluación de la severidad y grado de la misma, guía de planeación en presencia de complicaciones (como absceso o perforación), diagnóstico diferencial con otras patologías que pueden simular el cuadro clínico de dolor abdominal. (9)

Es así pues, que el uso de inteligencia artificial puede ser de utilidad en el análisis de imágenes tomográficas para el diagnóstico y evaluación de patologías quirúrgicas como lo es la enfermedad diverticular y sus complicaciones.

La enfermedad diverticular es una condición quirúrgica común, especialmente en el mundo occidental, que tiene una presentación variable y puede presentar un reto en el manejo tanto para personal de salud, como para el paciente.

La diverticulosis se refiere a la saculación de la mucosa y submucosa colónica, usualmente sucede alrededor de la vasculatura penetrante, puede ocurrir en cualquier segmento de intestino, sin embargo, el colon sigmoide es el sitio mayormente afectado. Previamente se creía que la enfermedad diverticular se asociaba con la edad, sin embargo, en estudios recientes se ha identificado la prevalencia en población jóvenes debido a la dieta occidental baja en fibra, tendencia al sobrepeso y obesidad y otros factores que hacen aumentar la presión intraabdominal. La enfermedad diverticular tiene varias presentaciones clínicas, se

TESIS TESIS TESIS TESIS TESIS

presenta más frecuentemente como dolor abdominal, cambios en el hábito intestinal y sangrado rectal, sus secuelas frecuentes incluyen la diverticulitis, perforación y absceso pericólico / flemón. (1)

La diverticulitis aguda es la complicación de la enfermedad diverticular más común (10-25% de los pacientes) y representa una urgencia abdominal, esta incluye una variedad de condiciones que se extienden desde la inflamación localizada hasta la peritonitis fecal, por ello la importancia de un diagnóstico preciso, en ello, la tomografía juega un rol principal debido a su alta sensibilidad y especificidad así mismo permite la estadificación de la enfermedad y el diagnóstico diferencial.

iii. CLASIFICACIÓN DE LA ENFERMEDAD DIVERTICULAR:

La fisiopatología de la diverticulitis aguda recae en la obstrucción del divertículo por heces o restos alimentarios, llevando así a daño en la mucosa y consecuentemente isquemia, micro perforación e infección, en esta enfermedad la tomografía computada representa la herramienta diagnóstica de primera elección presentando una alta sensibilidad y especificidad de 98-99% y 99-100% respectivamente, el tratamiento de la diverticulitis aguda depende de si esta es o no complicada, y de la presencia o ausencia de complicaciones. En 1978 Hinchey clasificó la severidad de la diverticulitis aguda en cuatro etapas basado en los hallazgos intraoperatorios, para así guiar el manejo quirúrgico.

Un absceso exclusivamente peri cólico, cambios flegmonosos o absceso caracteriza al estadio I, mientras que el absceso distante pélvico, retroperitoneal o intraabdominal categoriza el estadio II. El estadio III incluye a la peritonitis purulenta, mientras que el estadio IV ocurre cuando una perforación mayor, lleva a la peritonitis fecal.

iv. APLICACIÓN DE IMAGEN EN EL ABORDAJE TERAPÉUTICO DE DIVERTICULITIS

Con la llegada de la tomografía la clasificación de Hinchey fue modificada en 2005 por Kaiser, et al integrando así hallazgos radiológicos incluyendo así el estadio 0 en donde la presencia de un divertículo se asocia o no al engrosamiento de la pared colónica, la

(confinado a inflamación pericólica con cambios pericólicos de tejidos blandos, Ib. (absceso pericólico / mesocólico) (10)

Se han establecido manejos de acuerdo a esta estadificación para eventos de diverticulitis aguda, para la diverticulitis no complicada (Hinchey 0 y IA modificada) (70%) la tasa de éxito en el manejo conservador es superior al 90%, los antibióticos, se mantienen como el base para tratamiento inicial no quirúrgico tanto en pacientes ambulatorios, como en hospitalizados, así mismo se ha propuesto la administración de probióticos y rifaximina como uso seguro en la enfermedad diverticular no complicada, medicamentos anti-inflamatorios como la mesalamina se han estudiado de igual manera para el tratamiento y la prevención de diverticulitis recurrente, sin embargo, la evidencia de su eficacia permanece en estudio al día de hoy.

La diverticulitis complicada con formación de absceso (Hinchey IB y II modificada) representa hasta el 15%-25% de las presentaciones agudas el manejo de este padecimiento invariablemente comienza con la administración de antibióticos de amplio espectro. Abscesos pequeños <4cm tienen la posibilidad de resolver con terapia antibiótica por sí misma, mientras que abscesos >5cm indican el intento de drenaje percutáneo guiado por imagen, la resolución clínica presenta un rango amplio del 49-94% y la falla al tratamiento a corto plazo ocurre en el 12 al 30% y debe valorarse manejo quirúrgico inmediato. Aún después de la resolución existe un riesgo sustancial de enfermedad recurrente sólo el 28% de los pacientes con absceso no ameritan manejo quirúrgico o presentan un ataque recurrente. La recurrencia se presenta en el 61% global y 71% en el contexto de pacientes con drenaje guiado por imagen.

En la diverticulitis complicada con perforación / peritonitis generalizada purulenta y fecal (Hinchey III y IV) el primer paso crucial es distinguir a los pacientes con evidencia de peritonitis generalizada de los pacientes que presentan aire libre distante, pero no presentan datos clínicos de sepsis o peritonitis generalizada, la combinación de juicio clínico y análisis tomográfico es esencial para la toma de decisiones. Existen diversas estrategias quirúrgicas, sin embargo, la resección del segmento inflamado y perforado es incuestionablemente la mejor fuente para el control de la sepsis. La derivación exclusiva o drenaje exclusivo se han asociado a una recuperación prolongada y morbilidad aumentada.

Anteriormente la resección de Hartmann era el abordaje más comúnmente realizado y hoy en día representa una aproximación segura, especialmente en pacientes inestable, frágiles o con tejidos friables, sin embargo, debido a la alta probabilidad de nunca tener una reversión del estoma, nos orilla al esfuerzo por una anastomosis primaria con o sin derivación proximal en pacientes seleccionados. En algunos estudios referidos en la bibliografía consultada, la mayoría retrospectivos o revisiones sistemáticas como: "Primary Resection With Anastomosis vs. Hartmann's Procedure in Nonelective Surgery for Acute Colonic Diverticulitis: A Systematic Review" Publicada en 2006, se concluyó que la mortalidad fue comparable en ambos procedimientos cercana al 14%. Así mismo, en un análisis de decisiones publicado en 2007 en Annals of surgery, titulado: "Operative Strategies for Diverticular Peritonitis A Decision Analysis Between Primary Resection and Anastomosis Versus Hartmann's Procedures" se sugiere que la anastomosis primaria con derivación proximal tiene la mayor probabilidad de un resultado favorable a corto y largo plazo en pacientes con enfermedad diverticular III-IV. (11)

8. MARCO CONCEPTUAL:

Radiómica / Radiomics

Extracción de una gran cantidad de características de imágenes de pacientes mediante algoritmos de caracterización de datos para descubrir patrones y características tumorales que mejoren el diagnóstico. (BVS)

Inteligencia Artificial / Artificial Intelligence

Teoría y desarrollo de SISTEMAS DE COMPUTACIÓN que realizan tareas que normalmente requieren de inteligencia humana. Estas tareas pueden incluir el reconocimiento de voz, APRENDIZAJE, PERCEPCIÓN VISUAL, CÓMPUTOS MATEMÁTICOS, razonamiento, SOLUCIÓN DE PROBLEMAS, TOMA DE DECISIONES y traducción de idioma. (BVS)

Aprendizaje Automático / Machine Learning

Un tipo de INTELIGENCIA ARTIFICIAL que permiten a las COMPUTADORAS iniciar y ejecutar independientemente APRENDIZAJE cuando se expone a nuevos datos (BVS).

Redes Neurales de la Computación / Neural Networks, Computer

Una arquitectura hecha en computadora, que se puede implementar tanto en hardware como en software, modelada de acuerdo con las redes biológicas neuronales. Como el sistema biológico, en el cual la capacidad de procesamiento es resultado de las fuerzas de interconexión entre arreglos de nodos de procesamiento no lineales, las redes neurales computarizadas, frecuentemente llamadas perceptrones o modelos de conexión en múltiples capas, consisten en unidades similares a las neuronas. Un grupo homogéneo de unidades forma una capa. Estas redes son buenas para el reconocimiento de patrones. Son adaptativas, realizan tareas según ejemplo y por tanto son mejores para la toma de decisiones que las máquinas lineales de aprendizaje o análisis de grupo. No requieren programación explícita. (BVS)

Enfermedades Diverticulares / Diverticular Diseases


Enfermedades del DIVERTÍCULO a menudo debido a infección y/o inflamación (DIVERTICULITIS). (BVS)

Diverticulitis del Colon / Diverticulitis, Colonic

Inflamación del DIVERTÍCULO DEL COLON, generalmente con formación de abscesos y subsiguiente perforación (BVS)

Diverticulosis del Colon / Diverticulosis, Colonic

Afección caracterizada por la presencia de un número de divertículos cólicos (DIVERTÍCULO DEL COLON) en el COLON. Su patogénesis es multifactorial, incluyendo envejecimiento del colon, disfunción motora, incremento de la presión intraluminal, y carencia de fibra en la dieta. (BVS)



9. JUSTIFICACIÓN:

Con la presente investigación se planteó como objetivo obtener conocimiento sobre la aplicación de las tecnologías de la información de vanguardia en la toma de decisiones enfocadas en el diagnóstico y tratamiento de la enfermedad diverticular, particularmente de la diverticulitis aguda, con ello se plantea de acuerdo a los resultados implementar herramientas que apoyen al personal de salud, específicamente al cirujano a la toma de decisiones apoyada en un sistema de inteligencia artificial en el análisis de estudios de imagen.

¿Cómo se relaciona la investigación con las prioridades de la región y del país?

Dada la naturaleza emergente de la tecnología que se implementó en el presente estudio aún no existe de manera prioritaria a nivel institucional un protocolo para la búsqueda de la implementación de herramientas como esta, sin embargo, el uso de tecnologías de apoyo como lo es la inteligencia artificial, podría presentar un alivio a la carga de trabajo en hospitales de alto volumen para la caracterización de patrones asociados a enfermedad diverticular complicada y de esta forma priorizar la interpretación de estudios a manera de triage autónomo.

A nivel regional este protocolo se enfoca en la línea de generación del conocimiento con respecto a herramientas diagnósticas en el paciente quirúrgico de la Universidad Autónoma de Aguascalientes.

¿Qué conocimiento e información se obtendrá? ¿Qué finalidad se persigue con el conocimiento que brindará el estudio?

Con el presente estudio se buscó generar una base de datos local con las características de imagen del paciente con diverticulitis con respecto a sus características clínicas-quirúrgicas. La finalidad de ello es generar un antecedente para futuros proyectos de cohorte y facilitar la identificación de factores de riesgos imagenológicos y/o clínicos, con lo cual se buscará prevenir el retraso del tratamiento adecuado.

¿Cómo se diseminarán los resultados?

Los resultados del presente estudios serán difundidos como publicación en revistas científicas indexadas, así como localizarse en la base de datos del Instituto Mexicano del seguro social y el repositorio de la Universidad Autónoma de Aguascalientes, contribuyendo así al acervo bibliográfico de la comunidad científica del estado, del país y a nivel internacional.

¿Cómo se utilizarán los resultados y quienes serán los beneficiados?

Con la aplicación de este estudio, se verán beneficiados no sólo el personal de salud usuario de herramientas de interpretación radio diagnóstica y los ejecutores de los tratamientos, en este caso cirujanos generales, sino también los pacientes usuarios del sistema de salud mexicano y otros sistemas de salud, al poder disponer de herramientas diagnósticas auxiliares que apoyen la toma de decisiones de los médicos antes mencionados.

Así mismo, se pretende que la presente investigación de pie a la mejora continua y la generación de conocimiento posterior dando lugar a investigaciones subsecuentes.

10. PLANTEAMIENTO DEL PROBLEMA

Existe al momento de redactarse el presente documento una tendencia en la comunidad científica en la búsqueda de información y aplicación de tecnologías de nuevo desarrollo, el uso de robots, computadoras, software y recientemente el uso de inteligencia artificial con la finalidad de crear nuevas herramientas diagnósticas y terapéuticas que lleven al manejo integral y optimizado de pacientes, sus aplicaciones van desde llevar la agenda de citas de una institución, hasta la toma de decisiones sobre un tratamiento y el impacto en el pronóstico de un paciente.

Sin embargo, aún existe una gran área de oportunidad en la generación de conocimiento para ciertas patologías de gran impacto a nivel local, regional y mundial como lo es la enfermedad diverticular.

A. Magnitud y frecuencia

La prevalencia de la diverticulosis es variable en México con respecto al grupo en que se investigue, de acuerdo con el grupo etario, prevalece en mujeres (50 años o más) o en el varón (50 años o menos) es difícil establecer una epidemiología acertada en nuestro país

ya que la mayoría de los casos se presentan asintomáticos y solo el 10 al 20% se presentan con diverticulitis o hemorragia diverticular, sin embargo en la última década ha habido un incremento en la hospitalización y por ende costo en servicios de la salud en el mundo, a pesar de que en México, no existen cifras al respecto. De acuerdo a reportes de países como los Estados Unidos de América fue el octavo diagnóstico gastrointestinal más frecuente en pacientes ambulatorios, mientras que la diverticulitis sin hemorragia presentó un incremento del 21% en 2012 comparado con datos previos de 2003, generando así un costo de 2,200 millones de dólares. (12)

B. Causas probables del problema

Hasta el momento no hay un consenso o estudios que se enfoquen en el uso de herramientas de inteligencia artificial para la caracterización, clasificación y apoyo en la toma de decisiones en la enfermedad diverticular complicada, existen antecedentes sin embargo, de su efectividad en la identificación de patrones de imágenes que pueden categorizar la enfermedad, por lo cual existe un precedente, sin embargo, hasta el momento solo se ha visto su aplicación experimental en el diagnóstico diferencial de enfermedades neoplásicas.

C. Soluciones posibles y preguntas sin respuesta

En la presente investigación se propone resolver dicha problemática estableciendo un vínculo entre la aplicación de la tecnología en herramientas diagnósticas ya disponibles como lo es la radiómica aplicada a las imágenes generadas por tomografía y asociarla a la toma de decisiones en un análisis retrospectivo, logrando así resolución a preguntas sin respuesta y áreas de oportunidad en la implementación de estas tecnologías disponibles de manera global.

Desempeño de redes neuronales convolucionales para la Identificación de hallazgos en tomografía de pacientes con diverticulitis aguda en el hospital General de Zona No. 3, OOAD Aguascalientes.

11. PREGUNTA DE INVESTIGACIÓN:

- ¿Es posible desarrollar un algoritmo de inteligencia artificial capaz de realizar el diagnóstico de diverticulitis aguda y realizar una validación del mismo con imágenes de pacientes hospitalizados en el Hospital General de Zona No. 3?

12. OBJETIVOS

a. OBJETIVO GENERAL

Desarrollar un instrumento para la detección de diverticulitis aguda con el uso de un algoritmo de inteligencia artificial en imágenes de tomografía, utilizando las imágenes de pacientes con diverticulitis aguda de nuestro instituto como parte de los sets de muestreo, así como imágenes disponibles en las diferentes bases de datos de uso libre.

b. OBJETIVOS ESPECÍFICOS

- Desarrollo de software de inteligencia artificial en el análisis de datos e imágenes de tomografía para la detección de datos sugestivos de diverticulitis aguda.
- Comparar los hallazgos generados por computadora contra la opinión de un experto realizando así un algoritmo supervisado.
- Crear un método de análisis métrico adecuado para la validación interna o test interno con el algoritmo desarrollado para la detección de diverticulitis aguda.

13. HIPÓTESIS

Al ser este un estudio de carácter instrumental no se requiere de hipótesis para el desarrollo del mismo.

14. MATERIAL Y MÉTODOS

a. Tipo de estudio:

Se realizó un estudio de tipo descriptivo-correlacional con un diseño instrumental, no experimental y transversal.

Lugar del estudio: Hospital General de Zona No. 3 IMSS Aguascalientes, IMSS. OOAD Aguascalientes.

Universo de estudio: El estudio se realizó en pacientes hospitalizados en el servicio de Cirugía General del Hospital General de Zona No. 3 de Aguascalientes.

Población: Se realizó el análisis en este estudio de imágenes de tomografía de abdomen de pacientes con diagnóstico de diverticulitis aguda, sin distinción de sexo o edad, con derechohabencia al Instituto Mexicano del Seguro Social con adscripción al Hospital General de Zona No. 3 de la delegación Aguascalientes

b. Criterios de selección

- Imágenes de tomografía axial computarizada de abdomen con reporte escrito.
- Imágenes de tomografía cuyo reporte incluya la clasificación de Hinchey en la conclusión.

c. Criterios de exclusión

- Imágenes de tomografía con fallas técnicas.
- Tomografías incompletas

d. Criterios de eliminación

- Pacientes con expediente incompleto

e. DISEÑO DEL ESTUDIO

Respecto al diseño metodológico de este estudio se tomó en cuenta la guía CLAIM en su actualización de 2024, (13) la guía breve para autores, revisores y lectores publicada por la barra editorial de la revista Radiology en 2019 y la propuesta establecida por Dominik Müller en 2022 para la evaluación métrica en la segmentación de imágenes. (14)

Para la determinación del tamaño de la muestra se definió en primera instancia la necesidad de contar con tres sets de imágenes para el desarrollo del algoritmo de machine learning en la detección de diverticulitis aguda, siendo estos tres sets los siguientes: Entrenamiento, validación y set de entrenamiento de imágenes.

El algoritmo de inteligencia artificial es entrenado en un set inicial de imágenes de acuerdo al estándar de referencia, el en entrenamiento es ajustado y validado en otro set de imágenes y finalmente se tiene un set independiente de imágenes es usado para reportar los resultados estadísticos finales de la inteligencia artificial, idealmente cada uno de estos tres sets de imágenes debe ser independiente sin superposición(15).

De acuerdo con la guía publicada por Bluemke. et al. en su cuarto punto, la justificación del tamaño de la muestra depende de la aplicación del mismo, un modelo de IA puede aprender la segmentación de imágenes posterior a solo un par de cientos de imágenes, mientras que la detección de nódulos en radiografías de tórax requiere miles de imágenes. (16)

f. TAMAÑO DE LA MUESTRA

Para muchas aplicaciones el número "correcto" de imágenes puede ser desconocido al inicio de la investigación, el equipo de investigación deberá evaluar la relación entre el número de imágenes de entrenamiento contra las evaluadoras del performance del modelo, para el desarrollo del set de prueba las consideraciones estadísticas tradicionales en la determinación del tamaño de muestra pueden aplicarse para determinar el número mínimo de imágenes. Por lo cual para tal motivo se determinó de manera tradicional el tamaño de muestra adecuado para este set de imágenes para determinar la proporción de estudios que representan de manera significativa nuestra población con un intervalo de confianza de 95% se utilizó la fórmula siguiente:

$$n = N * X / (X + N - 1)$$

donde: $X = Z_{\alpha/2} * p * (1-p) / MOE^2$

$Z_{\alpha/2}$ es el valor crítico de la distribución normal de $\alpha/2$. (Intervalo de confianza de 95%)

MOE es el margen de error (del 5%)

P es la proporción de la muestra.

N es el tamaño de la población.

Se tienen registros de pacientes hospitalizados con diverticulitis en servicio de cirugía general desde febrero de 2022 hasta la fecha de inicio de este protocolo de investigación (29 de septiembre de 2024) donde se registraron un total de 54 pacientes con diferentes grados de diverticulitis aguda 0-IV.

Tomando en cuenta que de acuerdo con la bibliografía revisada la diverticulitis representa la complicación más frecuente de la enfermedad diverticular (10-25%) se utilizó este valor para calcular la proporción de nuestra muestra (10%) de tal forma se llegó a la conclusión que es necesaria una muestra de 40 imágenes de tomografía de pacientes con este diagnóstico para obtener un resultado significativo en este estudio.

Para el complemento del resto de imágenes para el entrenamiento y referencia en el desarrollo del algoritmo de inteligencia artificial se utilizará el estándar de referencia, el cual es ampliamente aceptado en el campo radiológico.

El término "estándar de referencia" se ha adoptado en lugar de verdad absoluta o Gold standard por el Checklist for Artificial Intelligence in Medical Imaging en su actualización de 2024 y se recomienda su uso para indicar la base contra la cual será medido el performance del algoritmo de Inteligencia artificial, este mismo término es usado ampliamente en el uso de tecnología y en la investigación de los servicios de salud para medir el performance de una prueba diagnóstica. (13)

De acuerdo a los autores de la guía para evaluación métrica en segmentación, Dominik Müller y Frank Krammer en su artículo publicado en 2021 titulado MIScnn: un marco para la segmentación de imágenes médicas con redes convolucionales neurales y deep learning y citado en la guía antes mencionada, se tomaron los siguientes parámetros muestrales

64% correspondiente al set de entrenamiento 16% al set de validación y 20% al set de muestreo. (14) por lo cual las 40 imágenes obtenidas por muestreo tradicional representarán el 20% del total de las imágenes analizadas.

g. DESARROLLO DEL MÉTODO DE IA DE ACUERDO A CLAIM.

Para el desarrollo del estudio previamente mencionado se tomó en cuenta la guía CLAIM, realizando el checklist de los 44 elementos establecidos en la misma, contestando en cada uno de ellos: Si, No y No aplicable, mostrando en el manuscrito final la página establecida en cada elemento marcado como Si, Así como dando justificación en caso de contestar No en cada ítem. Se agrega Anexo a este protocolo de la checklist de la guía CLAIM. (Anexo. 2).

Para el desarrollo del algoritmo de Inteligencia Artificial se planteó realizar un método de aprendizaje semi supervisado donde un ejemplo conocido es emparejado con una etiqueta conocida y ambos son usados para entrenar o enseñar al algoritmo, así el algoritmo puede entonces generalizar datos nunca antes visto a un tipo similar, el aprendizaje semi supervisado requiere intervención de expertos en el tema, como lo son los radiólogos, por lo cual se solicitará apoyo de un médico radiólogo para realizar pruebas internas y externas.

Para la presente investigación se utilizó el mapeo binario, para la visualización 2D de la imagen obtenida y así su análisis estadístico posterior.

h. FUENTE DE DATOS.

Para la obtención de imágenes para entrenamiento del algoritmo, las cuales representan el 60% de las imágenes a analizar con el algoritmo establecido, se obtendrán imágenes en repositorios de acceso libre de terceros partidos como GitHub, Kaggle y Zenodo, donde existen publicaciones con data sets, de imágenes de tomografía de abdomen.

i. ANÁLISIS ESTADÍSTICO:

En el área de segmentación de imagen médica el class imbalance (fenómeno que ocurre cuando el número de observaciones en una clase es mucho mayor que en número de observaciones en otra clase) afecta la evaluación métrica debido a que una imagen contiene usualmente una sola región de interés, ocupando un porcentaje menor de píxeles en la imagen, mientras que el resto de la imagen es anotado como fondo, este desequilibrio propicia todos los aspectos de una visión de túnel en la segmentación de imagen.

En la guía creada por Dominil Müller, Iñaki Soto-Rey y Frank Kramer se recomienda el uso de métricas basadas en la medición del score-F tales como DSC como la principal métrica para validación y performance de interpretación, así mismo, se recomienda el uso de AHD / IoU para la interpretación de sensibilidad y especificidad.

La intersección sobre la unión (IoU) también conocido como índice de similaridad de Jaccard. y el coeficiente de similaridad de Dice (DSC) por sus siglas en inglés, también conocido como score-F1 o índice de Sørensen-Dice es definido como la media armónica entre sensibilidad y precisión. (17)

$$IoU = \frac{TP}{TP + FP + FN}$$

$$DSC = \frac{2TP}{2TP + FP + FN}$$

15. DESCRIPCIÓN DE VARIABLES Y OPERACIONALIZACIÓN DE VARIABLES.

Variables	Definición conceptual	Definición operacional	Indicador	Valor o escala	Tipo de variable	Codificación y unidad de medida
Edad	Tiempo transcurrido desde el nacimiento hasta el momento de la evaluación.	Tiempo transcurrido desde el nacimiento hasta el momento de la evaluación.	Numérico	18-30 años	Cuantitativa	0= 18-30 años
				31-50 años		1= 31-50 años
				51-70 años		2= 51-70 años
				Mayor a 70 años		Mayor a 70 años
Sexo	Características fenotípicas que diferencian a un varón de una mujer.	Características fenotípicas que diferencian a un varón de una mujer.	Establecido en expediente.	Masculino	Cualitativa dicotómica	0= Femenino
				Femenino		1= Masculino
Clasificación de Hinchey	Clasificación tomográfica de grados de severidad modificada en 2005.	Diagnóstico al momento de hospitalización.	Establecido en expediente.	Grado 0	Cualitativa	0= Grado 0
				Grado Ia		1= Grado Ia
				Grado Ib		2= Grado Ib
				Grado II		3= Grado II
				Grado III		4= Grado III
				Grado IV		5= Grado IV
Tratamiento establecido en hospitalización	Describe el tratamiento establecido para la diverticulitis aguda.	Manejo médico o procedimiento quirúrgico establecido.	Establecido en expediente.	Antibioticoterapia.	Cualitativa	0= Antibioticoterapia.
				Drenaje percutáneo asistido por imagen.		1= Drenaje percutáneo.
				Drenaje laparoscópico.		2= Drenaje laparoscópico.
				Resección y anastomosis.		3= Grado II
				Procedimiento de Harmann		4= Grado III
Matriz de confusión	Las matrices de confusión son la forma más usual y estándar de informar sobre la exactitud temática de productos derivados de	Herramienta que permite la visualización del desempeño de un algoritmo que se emplea en	Establecido tras el análisis de imágenes.	Porcentaje de falsos positivos.	Cualitativa.	1=Algoritmo confiable
				Porcentaje de falsos negativos.		
				Promedio de precisión.		2=Algoritmo sesgado.

	la clasificación de datos procedentes de imágenes. (17)	aprendizaje supervisado.		Factor de covarianza.		
--	---	-----------------------------	--	--------------------------	--	--

(17)



16. PROCESAMIENTO Y ANÁLISIS DE DATOS

a. PROCEDIMIENTO PARA RECOLECCIÓN.

1. Para el presente estudio, se solicitó la aprobación del anteproyecto por el servicio de Cirugía, profesor titular de Cirugía General y jefatura de enseñanza del Hospital General de Zona No. 3 del Instituto Mexicano del seguro social en Aguascalientes; así mismo se realizó la solicitud de participación de investigador principal y asociados.
2. Posteriormente por medio de la plataforma institucional SIRELCIS, el protocolo se sometió a valoración por el Comité de Ética en Investigación y el Comité Local de Investigación en Salud y tras su aprobación se solicitó la autorización con Directivos del Hospital General de Zona No. 3 para realizar el estudio teniendo así acceso a los expedientes físicos y electrónicos de los sujetos de estudio, se extrajeron las características clínicas, evolución del paciente, desenlace quirúrgico así como datos de imágenes de tomografías en la computadora personal del investigador asociado dentro de la institución para su análisis.
3. Se desarrolló un algoritmo de machine learning/inteligencia artificial con ayuda de la investigadora externa para la aplicación en el análisis de datos con el uso de la herramienta MatLab con la herramienta de "Image Labeler app" con las características de hallazgos radiológicos que apoyaron al diagnóstico de diverticulitis aguda, en sus diferentes grados de severidad.
4. Apegados a los principios de Machine Learning, se realizó retroalimentación de los datos obtenidos, entrenando así al algoritmo con los diferentes hallazgos observados por el tesista y el experto en imagen compatibles con diverticulitis aguda realizando etiquetado manual inicialmente para la creación de máscaras de las características específicas de las imágenes con la morfología de los divertículos y los cambios en escala de grises presentados por la estriación de la grasa mesentérica.
5. Se verificó la utilidad del algoritmo desarrollado mediante matriz de confusión y se realizó la comparación con estudios de imagen de pacientes sanos.
6. Las imágenes tomográficas fueron obtenidas en la base de datos PACS del Hospital General de Zona No. 3, y se analizaron en Matlab con el algoritmo desarrollado con

- herramientas de uso libre, obteniendo así la interpretación generada por inteligencia artificial.
7. Se obtuvieron los datos analizados en el instrumento previamente desarrollado y se realizó un vaciado de los datos generados por inteligencia artificial con valores de pixeles activos detectados por el instrumento de inteligencia artificial.
 8. Al contar con los datos completos de la muestra siendo estos los archivos de imagen y la base de datos generada por el algoritmo de inteligencia artificial se realizó el análisis estadístico de los datos generados, para obtener los resultados que se proponen en el objetivo general y en los específicos para plasmarlo la redacción de la presente tesis.

17. INSTRUMENTOS UTILIZADOS:

Se utilizó para el análisis de los datos e imágenes obtenidas visualizadores de imágenes tomográficas como el BeeDICOM viewer, software de uso libre, se hizo uso de herramientas para el desarrollo de algoritmos de inteligencia artificial y procesamiento de imágenes como lo son Python, Matlab y sus diferentes herramientas de procesamiento de imágenes y algoritmos de Machine Learning.

En específico para el entrenamiento del algoritmo se utilizó la arquitectura de Red ResNet 18 donde las imágenes se representan como una matriz de píxeles:

Escala de grises: matriz 2D, cada píxel es un valor numérico que describe la intensidad de luz/color.

Las capas convolucionales aplican una serie de filtros donde se extraen patrones que detectan bordes, líneas, texturas y formas complejas como lo es un divertículo en una tomografía, finalmente se crean mapas de características que son representaciones intermedias de las imágenes analizadas.

Al final, las características extraídas se aplanan en un vector y se pasan por capas densas, Estas capas funcionan como un clasificador, asignando probabilidades a las clases (ejemplo: sano vs diverticulitis).

La red predijo probabilidades y se comparó con la etiqueta real usando una **función de pérdida** por ejemplo entropía cruzada.

La imagen se convirtió en tensores de píxeles donde ResNet-18 extrajo características progresivamente como bordes, texturas intestinales y patrones de inflamación como lo es la estriación de la grasa mesentérica, resultando la capa final con una probabilidad de pertenencia a cada grupo.

Se decidió utilizar la arquitectura de Red ResNet 18 porque cuenta con ventajas clave en el desarrollo del algoritmo de detección de imágenes como lo es la facilidad de entrenamiento al trabajar a través de conexiones residuales, requiere menos datos para entrenamiento que redes más profundas además de que permite extraer mapas de activación (Saliency Maps) para localizar las partes más importantes en un mapa de calor.

Se verificó la confiabilidad del instrumento mediante validación con matriz de confusión, para su posterior aplicación al estudio planteado.

Se utilizó una hoja de registro en el programa Excel donde se registraron los valores numéricos arrojados por el instrumento de procesamiento de imágenes, donde se registraron valores de percentil de pixeles activos, valores de pixeles en escala de grises activos, valores de entropía activos y área de pixeles activos en el estudio.

Al completar la recolección de datos y contar con la base de datos mínima necesaria para que la muestra sea suficientemente significativa, se procederá a realizar el análisis estadístico buscando cumplir con los objetivos generales y específicos establecidos en el desarrollo de la presente investigación.

18. ANÁLISIS DE DATOS

Las características clínicas y quirúrgicas, así como demográficas se obtuvieron del expediente clínico revisado mediante sistema de PHEDS y en la base de datos PACS del Hospital General de Zona No. 3 IMSS Aguascalientes, IMSS. Lo anterior, de acuerdo con sexo, edad, tratamiento establecido y estudio tomográfico a su ingreso.

Se empleó el paquete estadístico SPSS v.20 para el procesamiento de los datos. Por medio del cual se realizará el análisis estadístico de los datos así mismo, utilizando el índice de similitud de Jaccard y el coeficiente de similitud de DICE.

19. CONSIDERACIONES ÉTICAS.

Acorde a lo referido en el Procedimiento para la Evaluación, registro, seguimiento, enmienda y cancelación de protocolos de investigación en salud presentados ante los Comités Locales de investigación en Salud y los comités de ética en Investigación dentro del Instituto Mexicano del Seguro Social se considera este estudio de acuerdo con el artículo 17 como:

TESIS TESIS TESIS TESIS TESIS

Sin riesgo ya que revisarán únicamente los expedientes médicos e imagenológicos de pacientes que hayan cursado con el diagnóstico de diverticulitis durante su hospitalización, por lo cual se incluye en ser incluida la carta de excepción del consentimiento informado (Anexo).

Así mismo, el presente protocolo se someterá a su aprobación y análisis por el comité local de Investigación en salud.

Este protocolo de investigación cumple con las consideraciones emitidas en el Código de Núremberg, la Declaración de Helsinki, promulgada en 1964 y sus diversas modificaciones, incluyendo la actualización de Fortaleza, Brasil 2013, así como las pautas internacionales para la investigación médica con seres humanos, adoptadas por la OMS y el Consejo de Organizaciones Internacionales para la investigación con seres humanos, en México cumple con lo establecido por la Ley General de Salud y el IFAI, en materia de investigación para la Salud.

El presente protocolo se apeg a la “Ley federal de protección de datos personales en posesión de los particulares” publicada el 5 de julio del año 2010 en el Diario Oficial de la Federación: Capítulo I, Artículo 3 y sección VIII en sus disposiciones generales la protección de los datos. La confidencialidad de los datos del paciente será garantizada mediante la asignación de números o claves que solo los investigadores identifiquen, para brindar la seguridad de que no se identificará al sujeto y que se mantendrá la confidencialidad de la información relacionada con su privacidad.

Este protocolo se ajusta a las normas éticas e institucionales de este Hospital con apego al Reglamento de la Ley General de Salud en materia de investigación en Salud: título segundo, Capítulo I, Artículo 17, Selección I.

Al momento del desarrollo de la presente investigación no existen lineamientos en nuestro país que regulen el uso de inteligencia artificial en la investigación clínica, sin embargo existe el precedente de la Ley de Inteligencia Artificial del Parlamento Europeo de 2023 (P9_TA (2023) 0236) donde en la enmienda 12 se establece que dicha regulación debe contribuir a apoyar la investigación e innovación, y no perjudicar las actividades de investigación científica, por lo cual es necesario excluir de su ámbito de aplicación los sistemas de IA desarrollados específicamente con el fin exclusivo de la investigación y el

desarrollo científico, estas actividades deberán llevarse de conformidad con la Carta, El Derecho de la unión y el derecho nacional. Así como en su enmienda 32 donde se establece que a fin de impulsar el desarrollo y el despliegue de la inteligencia artificial, especialmente entre las pymes, las empresas emergentes y la investigación académica, el reglamento no se aplicará a los componentes de IA proporcionados en el marco de licencias libres y de código abierto. (18)

Respecto al resguardo de datos personales, resguardo de información de manera digital será durante un periodo temporal a futuro de 10 años en la base de datos del autor principal así como de manera física en la unidad de Coordinación de Enseñanza del Hospital General de Zona No. 3.

20. RECURSOS FINANCIEROS Y FACTIBILIDAD

No ameritó el uso de recursos externos para la realización de la investigación ya que se cuenta con el equipo y personal en la unidad para su realización, ya que se trata de un estudio retrospectivo únicamente se analizarán los estudios de tomografía de abdomen que se hayan adquirido hasta el momento en que se recolecte la muestra, así como las diferentes hojas de cálculo para el vaciamiento de datos, sin requerir el uso de otro recurso material extra.

El investigador asociado proporcionará el equipo de cómputo y el software para análisis de imágenes y datos.

Recursos humanos

Investigador principal: Dr. José Luis Bizueto Monroy

Investigador colaborador: Dr. Edgar Galicia Guel

Investigador colaborador externo: Dra. Mariana Sofia Flores Jiménez

Investigador asociado: Dr. Yair Hernandez Carlos.

La presente investigación no cuenta con financiamiento público ni privado para su desarrollo.

Factibilidad:

Para el desarrollo de la presente investigación se cuenta con los recursos humanos, económicos y materiales necesarios para cumplir con los objetivos señalados en los periodos estipulados. Además, los investigadores tienen acceso a la población de estudio, por lo que es factible su realización.

21. MARCO ANALÍTICO.

a. PROCESAMIENTO DE DATOS

Se tomaron registros de pacientes hospitalizados en el periodo comprendido, de los cuales se extrajo una muestra de 40 pacientes para la validación del algoritmo, durante el periodo comprendido entre noviembre de 2024 y agosto de 2025 considerando a todos aquellos pacientes registrados en los censos del servicio de cirugía general con diagnóstico de diverticulitis y que hayan estado hospitalizados para los diferentes tratamientos de este padecimiento conforme a los criterios establecidos durante el periodo de estudio.

Se recopilaron los estudios tomográficos y se procesaron mediante un visualizador de imágenes DICOM obteniendo las tomografías en sus diferentes fases y cortes utilizando los cortes axiales para el entrenamiento del algoritmo, se realizó el etiquetado manual de las áreas de interés (ROI) donde se encontraron hallazgos de relevancia en el estudio tomando como parámetros el hallazgo de divertículos y grasa mesentérica con cambios inflamatorios, posteriormente se introdujeron al algoritmo los estudios tomográficos completos tomando cada corte como una imagen. Así mismo se utilizó un dataset de un repositorio de imágenes de acceso libre de Zenodo llamado: Healthy Abdominal Organ Segmentation (CHAOS) Challenge.

El cual contiene 20 archivos DICOM y sus imágenes de diferentes pacientes con abdomenes sin alteraciones.

Se realizó el análisis del total de imágenes arrojando una tabla con las siguientes variables:

True Class	Predicted Class	Score	MeanActivation	PercActivePixels	MeanGrayActive	EntropyActive	MeanAreaActive

Donde se estableció la clase real de cada corte (etiquetado manual de cortes con y sin hallazgo de diverticulitis) y se arrojó la clase predicha de cada corte analizado (diverticulitis / sin diverticulitis) otorgando un score arrojado por el algoritmo que representa la probabilidad de pertenecer a la clase predicha (diverticulitis / sin diverticulitis).

Mean Activation es el valor arrojado por el algoritmo de acuerdo a la intensidad de activación de píxeles en regiones de interés.

En la columna PercActivePixels se establece la porción de píxeles activos en el mapa de saliencia.

La columna MeanGrayActive indica la intensidad promedio de los píxeles activos en regiones de interés manifestado en escala de grises, reflejando las diferencias de densidad en la tomografía entre un paciente sano vs un paciente con el padecimiento analizado.

La columna EntropyActive cuantifica la complejidad o dispersión de la activación, en el análisis de imágenes con inteligencia artificial, la entropía se usa como una medida estadística de la cantidad de información o complejidad presente en la imagen o en sus representaciones, mide el grado de incertidumbre o aleatoriedad en la distribución de sus píxeles o característica.

Finalmente, la columna MeanAreaActive representa el tamaño promedio del área activa, en el contexto de nuestro estudio, en las imágenes con diverticulitis la cantidad de píxeles con cambios estructurales o con zonas de inflamación.

22. RESULTADOS

ENTRENAMIENTO Y VALIDACIÓN

Se registraron un total de 109 pacientes con el diagnóstico de diverticulitis aguda en el periodo comprendido de febrero de 2022 y noviembre de 2024.

Se observó una amplia gama de diagnósticos y comorbilidades dentro de la población estudiada identificando diagnósticos con complicaciones graves como peritonitis fecal, sepsis abdominal, fístulas colovesicales, fascitis necrosante de pared, choque séptico y lesión renal aguda asociada.

Durante la hospitalización de estos pacientes existió registro en un 50% de los pacientes una estratificación clínica asociada, como diverticulitis complicada o clasificada con la clasificación de Hinchey.

De los 109 registros se agruparon diagnósticos en categorías principales:

Enfermedad diverticular complicada 17 casos, no complicada en 8 casos, Hinchey I sin subtipo 12 casos, Hinchey IA 11 casos, Hinchey IB 8 casos, además con estatus de colostomía o ileostomía en 6 casos.

Existió una distribución de 61 pacientes masculinos (55.6%) y 48 pacientes femeninos (44.3%) en la muestra. Con una distribución por edad de 62.3 años de edad media representando el grupo de edad de 51-70 años el más numeroso con 56 pacientes (51.1%)

De los datos obtenidos sólo el 56 de los 109 (51%) casos analizados contaron con registro tomográfico

Se seleccionaron 40 pacientes al azar, para obtener el estudio tomográfico obteniendo en promedio de 400 imágenes (cortes) por estudio.

Tras el procesamiento y análisis de los datos se analizaron un total de 10,225 imágenes representando cada corte de la totalidad de estudios analizados, de los cuales se clasificó manualmente aquellos con hallazgos compatibles con diverticulitis (Clase verdadera).

Presentando un total de 3,271 con hallazgos compatibles con diverticulitis, mientras que se encontraron 6,952 imágenes sin hallazgos compatibles con diverticulitis. Se corrió el análisis (Clase predicha) donde el algoritmo clasificó 3,248 con hallazgos compatibles con diverticulitis, mientras que se encontraron 6,975 imágenes sin hallazgos compatibles con diverticulitis. Teniendo así un contraste entre la clase predicha y la clase verdadera.

(Tabla 1. Frecuencia de imágenes clasificadas manualmente como con hallazgos con y sin diverticulitis)

(Tabla 2. Frecuencia de imágenes clasificadas por algoritmo como con hallazgos con y sin diverticuliti)

CLASE VERDADERA				
Categoría	Frecuencia	Porcentaje	Porcentaje válido	Porcentaje acumulado
Diverticulitis	3,271	32	32	32
Sin Diverticulitis	6,952	68	68	100
Total	10,225	100	100	

Tabla 1. Frecuencia de imágenes clasificadas manualmente como con hallazgos con y sin diverticulitis

CLASE PREDICHA				
Categoría	Frecuencia	Porcentaje	Porcentaje válido	Porcentaje acumulado
Diverticulitis	3,248	31.8	31.8	31.8
Sin Diverticulitis	6,975	68.2	68.2	100
Total	10,225	100	100	—

Tabla 2. Frecuencia de imágenes clasificadas por algoritmo como con hallazgos con y sin diverticulitis.

Se obtuvo clasificación. errónea de 170 imágenes clasificadas como diverticulitis en pacientes sanos (Falsos positivos).

Así mismo se omitió el diagnóstico en 193 imágenes de pacientes previamente clasificados manualmente con hallazgos de diverticulitis (Falsos negativos)

Teniendo así un total de 3,078 imágenes correctamente identificadas de pacientes con diverticulitis (Verdaderos positivos TP) y 6,782 imágenes sin hallazgos de diverticulitis correctamente descartados (Verdaderos negativos). (Tabla 3. Relación de resultados arrojados por algoritmo (Clase Predicha) Vs Etiquetado manual (Clase verdadera).)(Tabla 4. Interpretación de datos de tabla cruzada.)

CLASE PREDICHA VS CLASE VERDADERA					
			Clase Verdadera		Total
			Diverticulitis	Sin Diverticulitis	
Clase Predicha	Diverticulitis	Cuenta	3078	170	3248
	porcentaje dentro de la clase verdadera.		94.10%	2.40%	31.80%
	Sin Diverticulitis	Cuenta	193	6782	6975
	porcentaje dentro de la clase verdadera.		5.90%	97.60%	68.20%
TOTAL		Cuenta	3271	6952	10225
	porcentaje dentro de la clase verdadera.		100%	100%	100%

Tabla 3. Relación de resultados arrojados por algoritmo (Clase Predicha) Vs Etiquetado manual (Clase verdadera).

Categoría	Definición	Conteo	Porcentaje
TP (Verdaderos positivos)	Imágenes con diverticulitis correctamente identificados	3,078	94.1%
TN (Verdaderos negativos)	Imágenes sin diverticulitis correctamente descartados	6,782	97.6%
FP (Falsos positivos)	imágenes sin diverticulitis diagnosticados erróneamente como positivos	170	2.4%
FN (Falsos negativos)	Imágenes con diverticulitis no detectados por el algoritmo	193	5.9%
Total (n)	Suma total de imágenes analizadas	10,225	

Tabla 4. Interpretación de datos de tabla cruzada.

De estos datos obtenidos se realizó el análisis de diferentes indicadores para validar el rendimiento del algoritmo, se calculó la exactitud (Accuracy), la sensibilidad, la especificidad, el valor predictivo positivo, el valor predictivo negativo, y el Score F1 de la siguiente manera:

Exactitud, siendo la proporción del total de aciertos positivos y negativos del modelo, en este caso se calculó con la fórmula.

$$\text{Exactitud} = \frac{VP + VN}{n}$$
$$\text{Exactitud} = \frac{3,078 + 6,782}{10,225} = \frac{9,860}{10,225} = 0.964 \text{ (96.4\%)}$$

En este caso se puede interpretar que el modelo detecta 96 de cada 100 imágenes analizadas 9,860 decisiones correctas de 10,225.

Sensibilidad es la capacidad del algoritmo para detectar los casos reales de diverticulitis, el modelo detecta 94 de cada 100 pacientes y omite el 5.9% (Los falsos negativos).

$$\text{Sensibilidad} = \frac{VP}{VP + FN}$$
$$\text{Sensibilidad} = \frac{3,078}{3,078 + 193} = \frac{3,078}{3,271} = 0.941 \text{ (94.1\%)}$$

La especificidad del algoritmo fue del 97.6% de cada 100 sanos 98 pacientes son descartados correctamente, mientras que el 2.4% terminan como falsos positivos.

$$\text{Especificidad} = \frac{VN}{VN + FP}$$
$$\text{Especificidad} = \frac{6,782}{6,782 + 170} = \frac{6,782}{6,952} = 0.976 \text{ (97.6\%)}$$

El valor predictivo positivo del algoritmo fue del 94.8% lo cual indica la probabilidad de tener diverticulitis cuando el modelo identifica una imagen como positiva. 19 de cada 20 positivos

del modelo son verdaderos, mientras que el valor predictivo negativo fue de 97.3%, lo cual se traduce a la posibilidad de no tener diverticulitis cuando el resultado es negativo,

$$VALOR\ PREDICTIVO\ POSITIVO\ VPP = \frac{VP}{VP + FP}$$

$$VPP = \frac{3,078}{3,078 + 170} = \frac{3,078}{3,248} = 0.948\ (94.8\%)$$

$$VALOR\ PREDICTIVO\ NEGATIVO\ VPN = \frac{VN}{VN + FN}$$

$$VPN = \frac{6,782}{6,782 + 193} = \frac{6,782}{6,975} = 0.973\ (97.3\%)$$

Así mismo se realizó el cálculo del F1 Score una medida que hace relación al valor predictivo positivo y la sensibilidad del instrumento resultando con un valor de 94.4% lo que indica un balance adecuado entre la detección y no sobre diagnosticar

$$Score\ F1 = \frac{2 \cdot (VPP \cdot Sensibilidad)}{VPP + Sensibilidad}$$

$$Score\ F1 = \frac{2 \cdot (0.948 \cdot 0.941)}{0.948 + 0.941} = (94.4\%)$$

A continuación, se presentan las variables analizadas por el algoritmo de detección de imágenes.

Variable analizada	N	Valor mínimo	Valor máximo	Media	Desviación estándar	Varianza
Score	10,225	0.5001	0.9999	0.9371	0.1123	0.013
MeanActivation	10,225	0.1552	0.6028	0.3398	0.0723	0.005
PercActivePixels	10,225	0.0619	0.7124	0.2703	0.1000	0.01
MeanGrayActive	10,225	21.6610	190.6757	120.355	25.1726	633.664
EntropyActive	10,225	1.6743	6.48857	4.6994	0.6012	0.362
MeanAreaActive	10,225	872.25	35,750.00	11,166.02	5,809.02	33,744,742.69
Valid N (listwise)	10,225					

Tabla 5. Variables analizadas por algoritmo y los resultados obtenidos.

Se expone del total de 10225 imágenes analizadas los valores mínimos, máximos, la media, desviación estándar y varianza (Tabla 5. Variables analizadas por algoritmo y los resultados obtenidos.).

Donde se analiza el score que dio el algoritmo a cada imagen de acuerdo con la interpretación de la misma con un rango de 0.5001 – 0.999996

Media $\pm$ DE: 0.9372 ± 0.1123 (Var 0.013). El mínimo > 0.5 delata que el “Score” es, con alta probabilidad, la confianza de la clase predicha (la probabilidad “ganadora” del modelo), no la probabilidad de “Diverticulitis” para todos los casos.

Por definición, la probabilidad de la clase escogida es ≥ 0.5 , de ahí el piso en 0.5.

La media ~ 0.94 y el rango muy cerca de 1 sugieren confianza alta y efecto techo (muchos casos “casi 1”). Eso explica métricas globales muy buenas (sensibilidad y especificidad altas), pero advierte posible sobre confianza o calibración imperfecta (puntajes muy altos pueden no ser probabilidades bien calibradas).

Respecto a MeanActivation (promedio de activación del mapa/heatmap) se presentan valores de un rango de 0.1552 – 0.6028 con media $\pm$ DE: 0.3399 ± 0.0723 (Var 0.005), CV de 0.21

Los Valores alrededor de 0.34 sugieren que, en promedio, las regiones “activas” del modelo no están saturadas.

En la fila de PercActivePixels, se evalúa la información de la proporción de pixeles activos obtenida por el algoritmo con valores que van del 0.062 – 0.712 con media $\pm$ DE: 0.2703 ± 0.1000 (Var 0.010), CV 0.37 (alto) en algunas imágenes el modelo activa pocas zonas (6%), en otras muchas (71%). Un porcentaje de activación muy alto puede reflejar falsos positivos (activación difusa por artefactos, grasa pericólica, colon con contenido diverso, etc.) Un porcentaje muy bajo podría aparecer en falsos negativos (lesión pequeña, leve, o señal débil).

Respecto a MeanGrayActive, se plasman los datos de la intensidad media dentro de la región activa con un rango de 21.66 a 190.68 en escala de grises (unidades de gris) representando esta una reescala de unidades Hounsfield (0-255) Lo cual permite manejar como una imagen más fácil de procesar para el entrenamiento de redes neuronales. Representando así 21-66 una intensidad de gris muy baja (Oscuro, equivalente a tejido de densidad reducida como grasa/aire) y 190.68 una intensidad gris alta (Tejido más denso como músculo/hueso o zonas con contraste).

Se presentan valores con media $\pm$ DE de 120.36 ± 25.17 (Var 633.7), CV 0.21, la media se encuentra representando a los tejidos blandos, la dispersión (Desviación estándar) indica que el modelo atiende regiones con heterogeneidad de densidades (Grasa, inflamación, engrosamiento mural).

El rango amplio (21.66 a 190.68) sugiere que la señal activa no depende solo de una ventana estrecha; podría estar afectada por configuraciones de ventana escáner o por presencia de contraste, lo cual es esperado en el contexto de la realización de estudios contrastados en gran parte de la población analizada.

En el apartado EntropyActive, que representa la entropía o complejidad de textura en la región activa se observa un rango que va de 1-67 a 6.49 (Siendo el máximo teórico cercano a 8 en imágenes de 8 bits) Se presenta una media $\pm$ DE: 4.699 ± 0.601 (Var 0.362), CV 0.13.

La entropía media de 4.7 sugiere texturas moderadamente complejas en la región activa, puede discriminar un patrón inflamatorio (estriación grasa pericólica al compararlo con texturas uniformes u otras estructuras).

Finalmente analizando los resultados de la variable MeanAreaActive (tamaño medio de la región activa en pixeles) se obtiene datos con un rango de 872 -35,750 con media $\pm$ DE: $11\ 166 \pm 5\ 809$ (Var(5 809)²) CV 0.52 (muy alto)

Se interpreta como una distribución muy dispersa y probablemente asimétrica (cola derecha): hay casos con activación muy grande.

La estadística anterior representa el análisis general de las imágenes utilizadas en el set de entrenamiento y validación del algoritmo, posteriormente se realizó el análisis de la muestra con 40 sets de imágenes de pacientes sanos y pacientes conocidos con diverticulitis dividiéndolos en 20 sanos y 20 pacientes con enfermedad. (Tabla 6)

Se alimentó el archivo DICOM completo al algoritmo para su clasificación analizando corte por corte dando finalmente una categoría al estudio como con predicción a la presencia de diverticulitis o se descartó el diagnóstico en el estudio.

PRICHO VS REAL				
		REAL		Total
		Diverticulitis	Sin Diverticulitis	
PREDICHO	Diverticulitis	20	5	25
	Sin Diverticulitis	0	15	15
TOTAL		20	20	40

Tabla 6. Resultado de Estudios de sets de validación 40 imágenes (20 sanos y 20 conocidos con enfermedad)




Gráfico. 1. Matriz de Confusión obtenida del análisis de sets de validación

De los 40 estudios analizados el algoritmo clasificó 20 pacientes con diverticulitis de los cuales el 100% (20) verdaderos positivos presentaban el diagnóstico, (TP), Clasificando así 0 falsos negativos (FN) (estudios clasificados como sanos cuando se presentaba el diagnóstico)

Por otro lado, respecto a los estudios de la base de datos de pacientes sanos, el algoritmo clasificó a 5 de ellos como con hallazgos de diverticulitis a pesar de ser tomografías de abdomenes sanos, (Falsos positivos FP) Y clasificó a 15 de ellos como sanos, verdaderos negativos. (TN) siendo concordante con la clase real.

Como fue establecido en el desarrollo de este protocolo de investigación se contemplaron para la validación del algoritmo la intersección sobre la unión (IoU) también conocido como índice de similaridad de Jaccard. y el coeficiente de similaridad de Dice (DSC)

$$\text{Índice Jaccard} = \frac{VP}{VP + FP + FN} = \frac{20}{25} = 0.80$$

$$\text{Índice Dice} = \frac{2 VP}{2VP + FP + FN} = \frac{2 \cdot 20}{2 \cdot 20 + 5 + 0} = \frac{40}{45} = 0.8889$$

Como resultados se obtuvo un índice de Jaccard de 0.8, lo que se traduce a que el algoritmo coincide en un 80% entre los casos predichos como diverticulitis en casos reales, se obtuvo un coeficiente de similaridad de Dice o F1 de 0.8889 lo que significa que hay un 89% de similitud al comparar la intersección entre predicciones y casos reales frente al total combinado.

Finalmente se creó una interfaz para visualización del estudio tomográfico con predicción en el número de cortes con hallazgos compatibles con diverticulitis y se crearon mapas de saliencia, como representación visual donde se muestran qué partes del estudio de manera global o de algún corte en específico fueron más importantes para que la red neuronal convolucional tomara la decisión de clasificar la imagen como positiva o negativa.




Imagen. 1. Interfaz de usuario de análisis de imágenes de tomografía con mapa de saliencia.

Se puede observar en la interfaz, las zonas de activación en el mapa de saliencia, representadas por un mapa de calor, donde las zonas cálidas se acercan a regiones de interés con hallazgos compatibles con diverticulitis, mientras aquellas zonas frías, se consideran aquellas que no cuentan con pixeles activos para los hallazgos propios de la enfermedad.




Imagen. 2 Mapas de saliencia con evidencia de Diverticulitis señalada con mapas de calor, a mayor incandescencia, mayor probabilidad de presentar hallazgos de diverticulitis.

Se puede observar en la imagen ejemplos de detección en mapas de saliencia, donde se representan como zona de incandescencia aquellas regiones con mayor actividad de píxeles, representada por una gráfica con valores a escala a la derecha representando el porcentaje de píxeles activos y en la media de área activada.

23. DISCUSIONES

En la presente investigación nuestros hallazgos nos muestran que el algoritmo desarrollado con redes neuronales convolucionales de manera no supervisada alcanza un rendimiento global alto a nivel de análisis de imágenes individuales, con una sensibilidad de 94% y especificidad de 97.6% en el análisis de los sets de entrenamiento, además en la validación con la muestra planeada (n=40) identificó correctamente todos los casos con diverticulitis, sin embargo generó 5 falsos positivos entre los pacientes sanos (15/20) lo cual es un patrón consistente con umbrales agresivos de detección orientados a maximizar la sensibilidad.

Estos resultados, internamente consistentes con las métricas derivadas de la matriz de confusión y del dice score, respaldan la utilidad diagnóstica del modelo y sugieren que su comportamiento es estable cuando cambia la unidad de análisis (imagen individual a estudio tomográfico completo), aunque con diferencias esperables en sensibilidad-especificidad según nivel de agregación.

Se observa coherencia entre el desempeño del clasificador global y los patrones de activación regional (mapas de saliencia) lo cual sugiere que el sistema no solo acierta la etiqueta, sino que **concentra atención en regiones anatómicas plausibles** (engrosamiento mural, estriación de la grasa pericólica), lo cual es consistente con los mecanismos visuales que esperan los radiólogos en práctica

Comparación con el estándar clínico y consideraciones de aplicación.

En la práctica, la tomografía de abdomen es el estándar de imagen para el diagnóstico de diverticulitis no complicada y complicada; los desempeños reportados en literatura clínica para radiólogos expertos suelen situarse en sensibilidades y especificidades altas.

Nuestro modelo alcanza sensibilidades y especificidades cercanas a estos rangos en la evaluación de imágenes individuales, que el modelo alcance sensibilidades/especificidades cercanas a estos rangos a este nivel y mantenga una sensibilidad del 100% en la aplicación a estudios previamente no expuestos sugiere un potencial de utilidad en el apoyo diagnóstico, sin embargo, la presencia de falsos positivos en estudios sanos anticipa un sobrediagnóstico limitado.

La priorización de la sensibilidad sobre la especificidad es adecuada para un primer lector automático que sirva de tamizaje en presencia de hallazgos compatibles con diverticulitis, pudiendo ser útil para la confirmación definitiva realizada por un médico radiólogo.

Validación con índice de Jaccard y Dice

Con la finalidad de determinar la coherencia con clasificación binaria se determinó el índice de **Jaccard= 0.80** y de **Dice/DSC =0.89–0.98** (según se calcule a nivel corte o agregado) indican alto solapamiento entre las regiones o etiquetas positivas predichas y la referencia manual. Esta coherencia entre métricas de segmentación/solapamiento y métricas de clasificación (F1= 0.94 a nivel de corte; F1 = 0.98 a nivel de estudio) sugiere que el modelo no solo acierta la etiqueta, sino que enfoca regiones se consideraron relevantes en el etiquetado manual.

En términos de adopción, esto favorece la **relevancia clínica**, pues el mapa de saliencia del sistema converge con el etiquetado manual de un juicio experto en este caso el input de hallazgos de relevancia marcados por el tesista y el asesor médico radiólogo.

Alineamiento con guías y flujos clínicos

Las guías WSES 2020 mantienen que la TC es el pilar diagnóstico en diverticulitis, con desempeños reportados altos y capacidad de estadificación, lo que guía conductas terapéuticas (5). Integrar un algoritmo que priorice estudios “sospechosos” podría reducir tiempos de respuesta y fortalecer la estratificación, siempre que se implemente como soporte (no sustituto) y con umbrales ajustables a falsos positivos/negativos. Revisiones recientes en radiología abdominal destacan oportunidades para IA en detección, caracterización y triage de diverticulitis, pero insisten en la necesidad de validaciones multicéntricas y evaluación del cambio de conducta clínica (p. ej., disminución del tiempo a diagnóstico o mejor selección de pacientes para manejo ambulatorio) (4,6,7)

24. CONCLUSIONES

El presente trabajo demuestra que un modelo de Deep learning de inteligencia artificial aplicado al entorno quirúrgico es útil para el tamizaje de diverticulitis aguda con alto rendimiento, manteniendo sensibilidad alta y especificidad competitiva a nivel del desarrollo del algoritmo como en su aplicación con una muestra poblacional determinada. La coherencia entre las predicciones y los mapas de saliencia respalda la plausibilidad clínica de las decisiones del modelo, lo que habilita su uso como estudio de tamizaje, con el potencial de reducir tiempos de lectura y estándar detección en contextos de escenarios de alta demanda.

Los resultados posicionan a la herramienta como apoyo complementario al médico radiólogo, no como sustituto, capaz de mejorar la seguridad diagnóstica al minimizar omisiones en casos sutiles.

Consideramos, que este estudio da pie a la mejora del algoritmo en investigaciones futuras, donde se puede incluir mayor número de grupos poblacionales mayor número de imágenes tanto de pacientes sanos como enfermos, considerando estudios prospectivos, como validaciones multicéntricas, análisis por tipo de tomografía (simple vs contrastada en sus diferentes fases), estratificación por clasificación de Hinchey para cuantificar el desempeño en enfermedad complicada.

Con el cumplimiento de estas condiciones, la integración del modelo en el flujo clínico es tecnológicamente factible y clínicamente razonable, con una relación beneficio-riesgo favorable: pequeñas tasas de falsos positivos a cambio de mayor sensibilidad y priorización efectiva. En adelante, los esfuerzos deben enfocarse en medir impacto clínico real (tiempo a informe, cambios de conducta y resultados del paciente) y en cerrar brechas de generalización, para consolidar su implementación segura y sostenible en práctica asistencial.

FUENTES BIBLIOGRÁFICAS

1. Bhatia M, Mattoo A. Diverticulosis and Diverticulitis: Epidemiology, Pathophysiology, and Current Treatment Trends. *Cureus*. 2023 Aug 8;
2. Karentzos A, Ntourakis D, Tsilidis K, Tsoulfas G, Papavramidis T. Hinchey Ia acute diverticulitis with isolated pericolic air on CT imaging; to operate or not? A systematic review. Vol. 85, *International Journal of Surgery*. Elsevier Ltd; 2021. p. 1–9.
3. Barreiro-Ares A, Morales-Santiago A, Sendra-Portero F, Souto-Bayarri M. Impact of the Rise of Artificial Intelligence in Radiology: What Do Students Think? *Int J Environ Res Public Health*. 2023 Jan 1;20(2).
4. Borstelmann SM. Machine Learning Principles for Radiology Investigators. Vol. 27, *Academic Radiology*. Elsevier USA; 2020. p. 13–25.
5. Ziegelmayr S, Reischl S, Havrda H, Gawlitza J, Graf M, Lenhart N, et al. Development and Validation of a Deep Learning Algorithm to Differentiate Colon Carcinoma from Acute Diverticulitis in Computed Tomography Images. *JAMA Netw Open*. 2023 Jan 27;6(1):E2253370.
6. Winkel DJ, Heye T, Weikert TJ, Boll DT, Stieltjes B. Evaluation of an AI-Based Detection Software for Acute Findings in Abdominal Computed Tomography Scans: Toward an Automated Work List Prioritization of Routine CT Examinations. *Invest Radiol*. 2019 Jan 1;54(1):55–9.
7. Handelsman GS, Kok HK, Chandra R V., Razavi AH, Lee MJ, Asadi H. eDoctor: machine learning and the future of medicine. Vol. 284, *Journal of Internal Medicine*. Blackwell Publishing Ltd; 2018. p. 603–19.
8. Deo RC. Machine learning in medicine. *Circulation*. 2015 Nov 17;132(20):1920–30.
9. Minordi LM, Larosa L, Berte G, Pecere S, Manfredi R. CT of the acute colonic diverticulitis: A pictorial essay. *Diagnostic and Interventional Radiology*. 2020;26(6):546–51.
10. Tiralongo F, Di Pietro S, Milazzo D, Galioto S, Castiglione DG, Ini' C, et al. Acute Colonic Diverticulitis: CT Findings, Classifications, and a Proposal of a Structured Reporting Template. Vol. 13, *Diagnostics*. Multidisciplinary Digital Publishing Institute (MDPI); 2023.
11. Hanna MH, Kaiser AM. Update on the management of sigmoid diverticulitis. Vol. 27, *World Journal of Gastroenterology*. Baishideng Publishing Group Co; 2021. p. 760–81.
12. Raña-Garibay R, Salgado-Nesme N, Carmona-Sánchez R, Remes-Troche JM, Aguilera-Carrera J, Alonso-Sánchez L, et al. The Mexican consensus on the diagnosis and treatment of diverticular disease of the colon. *Rev Gastroenterol Mex*. 2019 Apr 1;84(2):220–40.
13. Tejani AS, Klontzas ME, Gatti AA, Mongan JT, Moy L, Park SH, et al. Checklist for Artificial Intelligence in Medical Imaging (CLAIM): 2024 Update. Vol. 6, *Radiology: Artificial Intelligence*. Radiological Society of North America Inc.; 2024.

- TESIS TESIS TESIS TESIS TESIS
14. Müller D, Kramer F. MIScnn: a framework for medical image segmentation with convolutional neural networks and deep learning. BMC Med Imaging. 2021 Dec 1;21(1).
 15. Gibson E, Hu Y, Huisman HJ, Barratt DC. Designing image segmentation studies: Statistical power, sample size and reference standard quality. Med Image Anal. 2017 Dec 1;42:44–59.
 16. Bluemke DA, Moy L, Bredella MA, Ertl-Wagner BB, Fowler KJ, Goh VJ, et al. Assessing radiology research on artificial intelligence: A brief guide for authors, reviewers, and readers-from the Radiology Editorial Board. Vol. 294, Radiology. Radiological Society of North America Inc.; 2020. p. 487–9.
 17. Müller D, Soto-Rey I, Kramer F. Towards a guideline for evaluation metrics in medical image segmentation. Vol. 15, BMC Research Notes. BioMed Central Ltd; 2022.
 18. Parlamento Europeo P9_TA(2023)0236 Ley de Inteligencia Artificial. 2019.
- 

|

|

ANEXOS

A. CRONOGRAMA DE ACTIVIDADES

ACTIVIDADES	2024				2025												2026	
	S E P	O C T	N O V	D I C	E N E	F E B	M A R	A B R	M A Y	J U N	J U L	A G O	S E P	O C T	N O V	D I C	E N E	F E B
PLANIFICACIÓN																		
DEFINIR TEMA DE INVESTIGACIÓN	R																	
REVISIÓN DE BIBLIOGRAFÍA	R																	
DISEÑO DE PROTOCOLO	R																	
EVALUACIÓN Y APROBACIÓN DE PROTOCOLO		T	T															
PREPARACIÓN DE RECURSOS Y LOGISTICA																		
RECOPILACIÓN DE IMÁGENES Y DATOS CLÍNICOS			P															
DESARROLLO DE ALGORITMO DE INTELIGENCIA ARTIFICIAL			P	P	P	P	P	P	P	P	P	P						
APLICACIÓN DE ALGORITMO A MUESTRA			P	P	P	P	P	P	P	P	P	P						
RECOPILACIÓN DE DATOS																		
RECOPILACION Y TABULACIÓN CON DATOS OBTENIDOS			P	P	P	P	P	P	P	P	P	P	P	P				
ANALISIS DE DATOS																		
DEPURACIÓN DE DATOS															P	P		
INTERPRETACIÓN DE RESULTADOS															P	P		
REPORTE DE RESULTADOS															P	P		
DIFUSIÓN DE RESULTADOS																		
PRESENTAR RESULTADOS																	P	P
PUBLICACIÓN INDEXADA																	P	P

ACTIVIDAD REALIZADA	R
ACTIVIDAD EN TRÁNSITO	T
ACTIVIDAD PROGRAMADA	P

B. CARTA DE CONSENTIMIENTO.



Gobierno de
México



INSTITUTO MEXICANO DEL SEGURO SOCIAL
SEGURIDAD Y SOLIDARIDAD SOCIAL



DRA. VIRGINIA VERÓNICA AGUILAR MERCADO
PRESIDENTA DEL COMITÉ DE ÉTICA EN
INVESTIGACIÓN 1018.
OOAD IMSS, DELEGACION AGUASCALIENTES.

Jesús María, Aguascalientes a 10 de enero de 2025

SOLICITUD DE EXCEPCIÓN DE LA CARTA DE CONSENTIMIENTO INFORMADO

Para dar cumplimiento a las disposiciones legales nacionales en materia de investigación en salud, solicito al Comité de Ética en Investigación del **Hospital General de Zona No. 3** del Instituto Mexicano del Seguro Social OOAD Aguascalientes que apruebe la excepción de la carta de consentimiento informado debido a que el protocolo de investigación **"Desempeño de redes neuronales convolucionales para la identificación de hallazgos en tomografía de pacientes con diverticulitis aguda en el Hospital General de Zona No. 3, OOAD Aguascalientes"**, es una propuesta de investigación de riesgo mínimo que implica la recolección de los siguientes datos ya contenidos en los expedientes clínicos:

- a) Número de seguridad social
- b) Edad
- c) Sexo
- d) Talla
- e) Comorbilidades
- f) Índice de masa corporal
- g) Tratamiento otorgado durante hospitalización.
- h) Interpretación radiológica de estudios de tomografía realizados
- i) Imágenes de tomografía alojadas en base de datos PACS del Hospital General de Zona No.3



Gobierno de
México



INSTITUTO MEXICANO DEL SEGURO SOCIAL
SEGURIDAD Y SOLIDARIDAD SOCIAL



MANIFIESTO DE CONFIDENCIALIDAD Y PROTECCIÓN DE DATOS

En apego a las disposiciones legales de protección de datos personales, me comprometo a recopilar solo la información que sea necesaria para la investigación y esté contenida en el expediente clínico y/o base de datos disponible, así como codificarla para imposibilitar la identificación del paciente, resguardarla, mantener la confidencialidad de esta y no hacer mal uso o compartirla con personas ajenas a este protocolo.

La información recabada será utilizada exclusivamente para la realización del protocolo **"Desempeño de redes neuronales convolucionales para la identificación de hallazgos en tomografía de pacientes con diverticulitis aguda en el Hospital General de Zona No. 3, OOAD Aguascalientes"**, cuyo propósito es producto comprometido de tesis.

Estando en conocimiento de que en caso de no dar cumplimiento se procederá acorde a las sanciones que procedan de conformidad con lo dispuesto en las disposiciones legales en materia de investigación en salud vigentes y aplicables.

Atentamente

Nombre:

Jose Luis Bizueto Monroy


Categoría contractual: Investigador Responsable.

**C. RESULTADO DEL CHECKLIST GUÍA CLAIM PARA PUBLICACIÓN DE
INVESTIGACIONES DE INTELIGENCIA ARTIFICIAL EN IMAGEN**

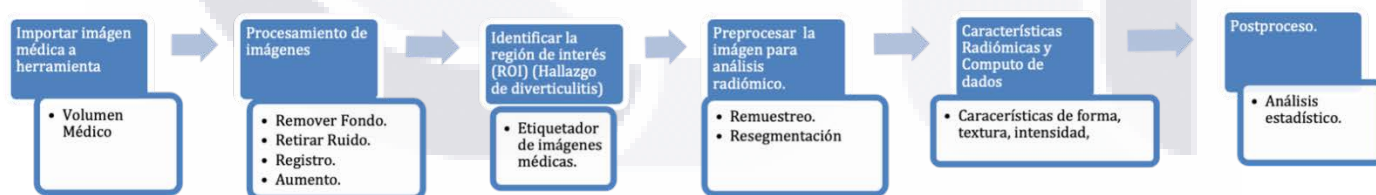
Sección / Tópico	N.º	Elemento (Item)	REALIZADOS
TÍTULO / RESUMEN	1	Identificación como un estudio de metodología de IA, especificando la categoría de tecnología utilizada (por ejemplo, aprendizaje profundo).	SI
	2	Resumen del diseño del estudio, métodos, resultados y conclusiones.	SI
INTRODUCCIÓN	3	Antecedentes científicos y/o clínicos, incluyendo el uso previsto y el papel de la IA.	SI
	4	Objetivos, metas e hipótesis del estudio.	SI
MÉTODOS			
Diseño del estudio	5	Estudio prospectivo o retrospectivo.	SI
	6	Meta del estudio.	SI
Datos	7	Fuentes de datos.	SI
	8	Criterios de inclusión y exclusión.	SI
	9	Preprocesamiento de datos.	SI
	10	Selección de subconjuntos de datos.	SI
	11	Métodos de desidentificación.	SI
	12	Manejo de datos faltantes.	SI
	13	Protocolo de adquisición de imágenes.	SI
Estándar de referencia	14	Definición del método utilizado para obtener el estándar de referencia.	SI
	15	Justificación para la elección del estándar de referencia.	SI
	16	Fuente de las anotaciones del estándar de referencia.	SI
	17	Anotación del conjunto de prueba.	SI
	18	Medidas de variabilidad intra e interevaluador de las características descritas por los anotadores.	SI
Partición de datos	19	Cómo se asignaron los datos a las particiones.	SI
	20	Nivel en el que las particiones son disjuntas.	SI
Modelo	21	Tamaño de muestra previsto.	SI
	22	Descripción detallada del modelo.	SI
	23	Software, marcos de trabajo y paquetes utilizados.	SI

	24	Inicialización de los parámetros del modelo.	SI
Entrenamiento	25	Detalles del enfoque de entrenamiento.	SI
	26	Método para seleccionar el modelo final.	SI
	27	Técnicas de ensamble (ensembling).	SI
Evaluación	28	Métricas de desempeño del modelo.	SI
	29	Medidas estadísticas de significancia e incertidumbre.	SI
	30	Análisis de robustez o sensibilidad.	SI
	31	Métodos de explicabilidad o interpretabilidad.	SI
	32	Evaluación en datos internos.	SI
	33	Evaluación en datos externos.	SI
	34	Registro de ensayo clínico (si aplica).	N/A
RESULTADOS			
Datos	35	Número de pacientes o exámenes incluidos y excluidos.	SI
	36	Características clínicas y demográficas de los casos en cada partición.	SI
Desempeño del modelo	37	Métricas de desempeño y medidas de incertidumbre estadística.	SI
	38	Estimaciones del desempeño diagnóstico y su precisión.	SI
	39	Análisis de fallos en los casos clasificados incorrectamente.	SI
DISCUSIÓN	40	Limitaciones del estudio.	SI
	41	Implicaciones para la práctica clínica, incluyendo el uso previsto y el papel de la IA.	SI
OTRA INFORMACIÓN	42	Referencia al protocolo completo del estudio o detalles técnicos adicionales.	SI
	43	Declaración sobre la disponibilidad del software, modelo entrenado y/o datos.	SI
	44	Fuentes de financiamiento y apoyo; papel de los financiadores.	SI

D. EJEMPLIFICACIÓN DE LA APLICACIÓN 2D EN MAPA BINARIO

Binary labelmap	Closed surface	Fractional labelmap	Planar contours, ribbons
			
easy 2D viewing and editing, always valid (even if transformed or edited)	easy 3D visualization	quite easy 2D viewing and editing, always valid, quite accurate	accurate 2D viewing and editing
inaccurate (finite resolution) requires lots of memory if overlap is allowed	difficult to edit, can be invalid (e.g., self-intersecting), especially after non-linear transformation	requires lots of memory	ambiguous in 3D, poor quality 3D visualization

E. MANUAL OPERACIONAL DIAGRAMA DE FLUJO PARA LA APLICACIÓN RADIOMICA EN EL ANÁLISIS DE IMÁGENES.



F. CÓDIGO PHYTON DE ALGORITMO DESARROLLADO PARA EL ANÁLISIS DE IMÁGENES (RED NEURONAL)

```
% Ruta a imagenes
imds = imageDatastore('dataset', ...
    'IncludeSubfolders',true, ...
    'LabelSource','foldernames');

% División: 80% entrenamiento, 20% validación
[imdsTrain, imdsValidation] = splitEachLabel(imds,0.8,'randomized');

net = resnet18; % se usa la red resnet
inputSize = net.Layers(1).InputSize; % tamaño de entrada de la red

% Ajustamos las imágenes al tamaño esperado
augTrain = augmentedImageDatastore(inputSize(1:2), imdsTrain);
augValidation = augmentedImageDatastore(inputSize(1:2), imdsValidation);

% Modificamos las últimas capas para clasificación binaria
layersTransfer = net.Layers(1:end-3);

numClasses = numel(categories(imdsTrain.Labels));
layers = [
    layersTransfer

    fullyConnectedLayer(numClasses,'WeightLearnRateFactor',10,'BiasLearnRateFactor',10)
    softmaxLayer
    classificationLayer];

% configuracion de entrenamiento
options = trainingOptions('sgdm', ...
    'MiniBatchSize',32, ...
    'MaxEpochs',10, ...
    'InitialLearnRate',1e-4, ...
    'ValidationData',augValidation, ...
    'ValidationFrequency',30, ...
    'Verbose',false, ...
    'Plots','training-progress');

% entrenamiento
netTransfer = trainNetwork(augTrain,layers,options);

% Predicciones
```

YPred = classify(netTransfer, augValidation);
YValidation = imdsValidation.Labels;

% Exactitud
accuracy = mean(YPred == YValidation)
confusionchart(YValidation, YPred);

%% Generacion de Saliency map para encontrar en la imagen qué regiones fueron las mas importantes para la red
% Imagen de prueba
I = readimage(imdsValidation,10);
I = imresize(I, netTransfer.Layers(1).InputSize(1:2));


% Predicción
[label, scores] = classify(netTransfer, I);

% Grad-CAM saliency map
map = gradCAM(netTransfer, I, label);

% Mostrar
figure;
imshow(I);
hold on;
imagesc(map,'AlphaData',0.5); % sobreponer mapa
colormap jet
colorbar
title(['Predicción: ' char(label)]);

G. EPOCAS DE ENTRENAMIENTO ALGORITMO

AGOSTO 2025



SEPTIEMBRE 2025

