





Artificial Intelligence Models for the Diagnosis of Gastrointestinal Disorders: A Systematic Review of Literature

Llamo-Sánchez, Johan Iván¹; Esquén-Salazar, Erenia Vanessa²; Dios-Castillo, Christian Abraham³
^{1,2,3}Universidad Tecnológica del Perú, Perú, U21201696@utp.edu.pe, U21203191@utp.edu.pe, C16763@utp.edu.pe

Abstract– This study examines Artificial Intelligence (AI) models' effectiveness in detecting and classifying gastrointestinal disorders (GID) based on complex patterns and biometric data. The research highlights the impact of different AI approaches, focusing on Deep Learning (DL), Machine Learning (ML), and hybrid ML+DL models. The results show that CNN-based DL models perform exceptionally well when handling large volumes of data, achieving high accuracy, especially in identifying conditions such as polyps, ulcers, and Crohn's disease. Hybrid models that combine ML and DL architectures offer superior performance, with lower variability in results and higher diagnostic accuracy.

Keywords– Deep Learning, Artificial Intelligence, Gastrointestinal tract, Human, Diagnosis.

Artificial Intelligence Models for the Diagnosis of Gastrointestinal Disorders: A Systematic Review of Literature

Llamo-Sánchez, Johan Iván¹; Esquén-Salazar, Erenia Vanessa²; Dios-Castillo, Christian Abraham³
^{1,2}Universidad Tecnológica del Perú, Perú, U21201696@utp.edu.pe, U21203191@utp.edu.pe, C16763@utp.edu.pe

Resumen– *This study examines Artificial Intelligence (AI) models' effectiveness in detecting and classifying gastrointestinal disorders (GID) based on complex patterns and biometric data. The research highlights the impact of different AI approaches, focusing on Deep Learning (DL), Machine Learning (ML), and hybrid ML+DL models. The results show that CNN-based DL models perform exceptionally well when handling large volumes of data, achieving high accuracy, especially in identifying conditions such as polyps, ulcers, and Crohn's disease. Hybrid models that combine ML and DL architectures offer superior performance, with lower variability in results and higher diagnostic accuracy.*

Palabras clave– *Deep Learning, Artificial Intelligence, Gastrointestinal tract, Human, Diagnosis.*

I. INTRODUCCIÓN

Los trastornos gastrointestinales (TGI) constituyen una de las principales preocupaciones en el ámbito de la salud [1], [2]. Estos trastornos incluyen una amplia variedad de enfermedades gastrointestinales (EGI) y lesiones gastrointestinales (LGI) [3], que no solo se caracterizan por su elevada incidencia, sino también por las complicaciones que conllevan. Dichos trastornos impactan considerablemente la calidad de vida de quienes las padecen [4]. La detección y clasificación precisa de estos trastornos se han convertido en un objetivo prioritario dentro de la medicina moderna, especialmente por los desafíos diagnósticos que suponen las variaciones y similitudes en sus manifestaciones clínicas, lo que contribuye a diagnósticos tardíos y aumento de la mortalidad [5]. Al margen de lo dicho, es necesario abordar la detección de las EGI y de las LGI de manera más eficiente. En este contexto, los avances en inteligencia artificial (IA) y visión computacional han propiciado el desarrollo de técnicas innovadoras que permiten la identificación automatizada de diversos tipos de TGI. Estas herramientas tecnológicas emplean modelos de aprendizaje automático y aprendizaje profundo, los cuales examinan patrones complejos, facilitando una detección temprana y confiable de patologías gastrointestinales, lo que, a su vez, reduce la dependencia exclusiva de métodos invasivos tradicionales [6], [7]. La eficacia y aplicabilidad de estos modelos tecnológicos en el diagnóstico de TGI dependen de su capacidad para procesar conjuntos de datos que se rigen por principios específicos y refinados, como criterios visuales, biométricos, entre otros, los cuales son fundamentales para mejorar su exactitud. Estos parámetros ayudan a identificar las características más distintivas de cada enfermedad [8], permitiendo que los

modelos de IA se entrenen mediante un conjunto de datos que no solo maximicen su capacidad de identificación, sino que también permitan una continua iteración y ajuste de sus algoritmos [9]. Esto asegura una adaptabilidad a las complejidades inherentes a las diferentes presentaciones clínicas de los TGI. De esta manera, este estudio se centra en realizar una revisión de la literatura con el objetivo de determinar qué modelos de IA son los más efectivos para la detección de EGI y LGI, con base en las métricas resultantes e identificando y analizando los criterios más relevantes que se utilizan en la clasificación y diagnóstico de estos. El desarrollo de modelos de IA robustos no solo promete mejorar la precisión diagnóstica, sino también establecer un nuevo estándar de calidad en la práctica médica asistida por tecnología. Esta base sólida no solo cimenta su implementación en el ámbito clínico, sino que también plantea un enfoque de mejora continua. A medida que los modelos se exponen a nuevos datos y se perfeccionan a través de la retroalimentación constante, se vuelve posible que los sistemas de IA se adapten a las variaciones y particularidades de los casos clínicos, mejorando aún más su fiabilidad y precisión. A modo que, la IA se convierte en un apoyo fundamental para los profesionales de la salud, no solo como herramienta de diagnóstico, sino también como un socio estratégico en la toma de decisiones clínicas, al proporcionar información adicional y sugerencias fundamentadas que facilitan el proceso de toma de decisiones.

II. METODOLOGÍA

El presente estudio se llevó a cabo mediante una revisión sistemática de literatura, estructurada en torno a la formulación de preguntas específicas de investigación, lo que permitió guiar tanto la búsqueda como el análisis de los textos más relevantes para abordar el tema. Con este enfoque, se definió la siguiente pregunta principal de investigación, ¿Qué modelos de Inteligencia Artificial ofrecen la mayor efectividad en la identificación y clasificación de enfermedades y lesiones gastrointestinales basadas en patrones y datos biométricos complejos, y qué variables influyen más en su rendimiento? Para abordar esta interrogante, se formularon tres preguntas específicas, las cuales se muestran en la TABLA I. Estos planteamientos buscan definir aspectos clave que se desprenden de la pregunta principal. La primera, sobre la variable de estudio y su medición (Item 1). La segunda, orientada en definir el método de solución (Item 2). Y la

tercera, dirigida a identificar los resultados esperados con relación al modelo propuesto (Item 3). Además, se identificaron palabras clave asociadas como "keywords".

TABLA I
ESTRUCTURA DE PREGUNTAS ESPECÍFICAS

Item	Preguntas específicas	Keywords
1	¿Cuáles son los trastornos gastrointestinales en humanos que pueden ser identificados y clasificados a partir de patrones y datos biométricos complejos, y qué criterios permiten identificarlos?	Gastrointestinal diseases, Gastrointestinal tract, Digestive system diseases, Gastrointestinal disorders
2	¿Cómo se aplican los diferentes modelos de Inteligencia Artificial en la identificación y clasificación de trastornos gastrointestinales utilizando datos biométricos complejos?	Machine Learning, Artificial intelligence, Deep learning, Neural networks, Data mining, Predictive modeling, Pattern recognition, Biometrics-based detection
3	¿Qué modelo de Inteligencia Artificial ofrece la mayor efectividad en términos de sus métricas resultantes, y qué variables o factores afectan más el rendimiento de estos modelos en la detección de los trastornos gastrointestinales?	Model effectiveness, Accuracy, Sensitivity, Specificity, Machine Learning outcomes

Este estudio se fundamentó en una investigación bibliográfica mediante una búsqueda automatizada en las bases de datos WOS y SCOPUS. La ecuación de búsqueda fue construida a partir de las palabras clave (keywords) identificados en nuestras preguntas específicas, obteniendo la siguiente cadena: (TITLE-ABS-KEY (("Gastrointestinal diseases" OR "Gastrointestinal tract" OR "Digestive system diseases" OR "Gastrointestinal disorders") AND NOT ("Animal")) AND TITLE-ABS-KEY ("Machine Learning" OR "Artificial intelligence" OR "Deep learning" OR "Neural networks" OR "Data mining" OR "Predictive modeling" OR "Pattern recognition" OR "Biometrics-based detection") AND TITLE-ABS-KEY ("Model effectiveness" OR "Accuracy" OR "Sensitivity" OR "Specificity" OR "Machine Learning outcomes"))

La estructura de la cadena de búsqueda se diseñó utilizando el conector AND entre las diferentes secciones para asegurar que los términos relacionados con la variable de estudio (enfermedades y lesiones gastrointestinales), el modelo de solución (Machine Learning, Deep Learning, y relacionados), y los resultados esperados (efectividad del modelo) estuvieran interrelacionados, asegurando una exploración integral del tema estudiado. Por otro lado, dentro de cada sección, se utilizó el conector OR para incluir sinónimos y términos, ampliando el alcance de la búsqueda y garantizando resultados relevantes. A partir de este punto, se definieron filtros específicos para ajustar y delimitar nuestra ecuación de búsqueda, tal como se detalla en la TABLA II, para ajustar la ecuación de búsqueda debido al elevado volumen de documentos obtenidos inicialmente.

TABLA II
FILTROS APLICADOS A LA CADENA DE BÚSQUEDA

Item	Filtro	Nomenclatura	Descripción
1	Tiempo	PUBYEAR > 2021 AND PUBYEAR < 2025	Limitar la búsqueda a documentos publicados entre un rango de fechas específico, delimitándolo a solo 3 años de antigüedad
2	Tipo de Documento	LIMIT-TO (DOCTYPE , "ar") OR LIMIT-TO (DOCTYPE , "re")	Se filtraron los resultados para incluir únicamente documentos clasificados como artículos (ar) y revisiones literarias (re)
3	Lenguaje	LIMIT-TO (LANGUAGE , "English")	Se restringió el idioma de los documentos a inglés, en función del dominio del idioma
4	Acceso	LIMIT-TO (OA , "all")	Se limitaron los resultados a documentos de acceso abierto

Dichos criterios fueron integrados a la cadena de búsqueda generada, alcanzando como resultado la siguiente ecuación final: (TITLE-ABS-KEY (("Gastrointestinal diseases" OR "Gastrointestinal tract" OR "Digestive system diseases" OR "Gastrointestinal disorders") AND NOT ("Animal")) AND TITLE-ABS-KEY ("Machine Learning" OR "Artificial intelligence" OR "Deep learning" OR "Neural networks" OR "Data mining" OR "Predictive modeling" OR "Pattern recognition" OR "Biometrics-based detection") AND TITLE-ABS-KEY ("Model effectiveness" OR "Accuracy" OR "Sensitivity" OR "Specificity" OR "Machine Learning outcomes")) AND PUBYEAR > 2021 AND PUBYEAR < 2025 AND (LIMIT-TO (DOCTYPE , "ar") OR LIMIT-TO (DOCTYPE , "re")) AND (LIMIT-TO (LANGUAGE , "English")) AND (LIMIT-TO (OA , "all"))

En consecuencia, se establecieron criterios de inclusión y exclusión, detallados en la TABLA III para filtrar las fuentes identificadas y seleccionar aquellas que fueran pertinentes para el análisis. Estos parámetros aseguran que los documentos elegidos cumplan con las características necesarias para abordar adecuadamente los objetivos de la investigación.

TABLA III
CRITERIOS DE INCLUSIÓN Y EXCLUSIÓN

Item	Criterios de Inclusión	Criterios de Exclusión
1	Los documentos deben abordar el tema de detección o clasificación de TGI en humanos	Documentos que no estén relacionados con el tema de interés o se enfoquen en estudiar estas en animales
2	Los documentos deben aplicar modelos de IA en relación con el tema objetivo (TGI)	Documentos que no apliquen modelos de IA para la evaluación de TGI
3	Los documentos deben estar disponibles en formatos pdf o texto y asegurarse de ser acceso abierto	Documentos cuyos formatos no cumplan con lo establecido o no sean de acceso abierto

Para la interpretación de los resultados, se utilizó el modelo PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analysis), ampliamente reconocido por estructurar revisiones sistemáticas de manera eficaz,

reduciendo el sesgo y garantizando conclusiones basadas en evidencia de calidad [10], [11], lo que es fundamental en investigaciones como esta. Este enfoque permitió identificar 330 artículos a través de dos bases de datos: Scopus, con 237 registros, y Web of Science (WOS), con 93. Luego, se eliminaron 77 registros duplicados, quedando 253 para el cribado inicial. Tras evaluar títulos y resúmenes según los criterios definidos en la TABLA III, se excluyeron 129 artículos. De los restantes, se evaluaron en función a su disponibilidad, donde 3 fueron descartados por no ser de libre acceso. Finalmente, los 121 restantes fueron analizadas en detalle, excluyéndose 6 por no cumplir los criterios específicos detallados en la TABLA III. Como resultado del riguroso proceso de selección, el cual se puede visualizar en la Fig. 1, se incluyeron 115 estudios en la revisión sistemática, garantizando que solo los artículos más relevantes fueran considerados.

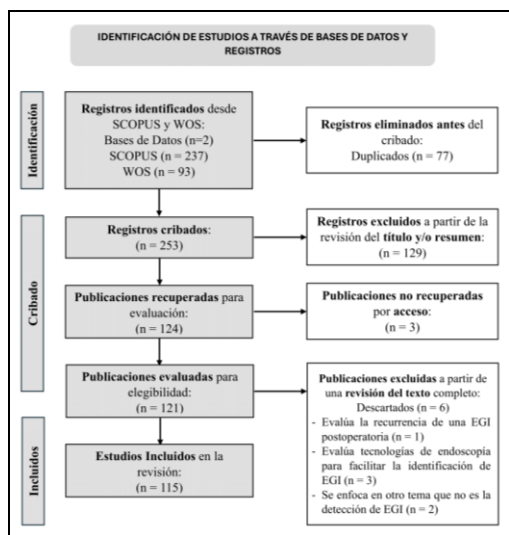


Fig. 1 Diagrama PRISMA

III. RESULTADOS Y DISCUSIONES

El presente análisis bibliométrico examina una selección de documentos que exploran la implementación de Modelos de IA en el diagnóstico de TGI, detallando la distribución temática a la que pertenecen, tal como se muestra en la TABLA IV. En esta se destacan las áreas con mayor interés investigativo, siendo *Engineering* (33.91%), *Computer Science* y *Medicine* (33.91%) las categorías líderes, esto debido al papel complementario que constan estas áreas, por un lado, *Engineering* proporciona la infraestructura y las herramientas necesarias que permitan la implementación de modelos de IA, relacionándolo con el entorno sanitario (*Science* y *Medicine*). Del mismo modo, otras disciplinas se hacen presentes, tales como *Biochemistry, Genetics, Telecommunications, Gastroenterology Hepatology, General Internal Medicine*, entre otros, consolidándose como los temas más frecuentes y estratégicos en los estudios. Se debe resaltar que la categoría *Others* mostrada en la TABLA IV se

distribuye en 21 categorías, incluye campos como *Biotechnology Applied Microbiology, Imaging Science Photographic Technology*, reflejando la amplitud y diversidad de enfoques investigativos. Este segmento resalta la naturaleza multidisciplinaria del área, con espacio para disciplinas emergentes y especializadas. Es importante destacar que los porcentajes se calculan en función del total de artículos revisados, y debido a que un trabajo puede abarcar varias áreas, las sumas no alcanzan el 100%, evidenciando la flexibilidad y diversidad en los temas tratados.

TABLA IV
DISTRIBUCIÓN DE LAS TEMÁTICAS ABORDADAS

Área temática	Frecuencia	% respecto al Total de documentos analizados
Engineering	39	33.91%
Computer Science	39	33.91%
Medecine	28	24.35%
Biochemistry, Genetics	15	13.04%
Telecommunications	9	7.83%
Gastroenterology Hepatology	9	7.83%
Materials Science	8	6.96%
Science Technology Other Topics	6	5.22%
Mathematics	5	4.35%
General Internal Medicine	5	4.35%
Others	39	33.91%
Total de documentos analizados	115	

Nota: Elaborado con base en los documentos analizados.

Al examinar el contenido de cada documento abordado se identificó un patrón respecto a las palabras clave, mostrado en la TABLA V. Este enfoque revela no solo las tendencias predominantes, sino también las relaciones entre las temáticas investigadas. Destaca en primer lugar *Deep Learning*, presente en el 49.57% de los trabajos y con un valor de enlace de 514, lidera como técnica fundamental ampliamente aplicada, consolidándose como un eje transversal en este ámbito. Le sigue *Artificial Intelligence*, mencionada en el 34.78% y con una fuerza de enlace de 383, lo que refleja su rol como marco conceptual flexible e integrador en diversos contextos, sirviendo como base teórica para modelos y técnicas complementarias. El término *Human* (33.04%) evidencia la conexión directa entre estas tecnologías y su aplicación clínica, resaltando su pertinencia en el tratamiento de pacientes y su vinculación con conceptos médicos. En el área de salud, destacan *Gastrointestinal tract* (26.96%) y *Gastrointestinal disease* (22.61%), enfocándose en TGI. Además, *Endoscopy* (21.74%) y *Capsule Endoscopy* (13.04%) reflejan el uso de IA en diagnósticos innovadores, promoviendo precisión y opciones menos invasivas. Estos resultados subrayan el impacto de la inteligencia artificial en la medicina, especialmente en diagnósticos avanzados. Desde una perspectiva técnica, *Convolutional Neural Network* (21.74%) emerge como una herramienta esencial dentro del *Deep Learning*, mientras que *Feature Extraction* (13.91%) y *Algorithm* (13.91%) destacan la importancia de los procesos de preparación y optimización de datos. Estos términos confirman la relevancia de los aspectos técnicos en la

construcción de modelos eficaces, contribuyendo al avance en la aplicación de IA en el diagnóstico médico.

TABLA V
DISTRIBUCIÓN DE PALABRAS CLAVE

Área temática	Frecuencia	Fuerza total de enlace	% respecto al Total de documentos analizados
Deep learning	57	514	49.57%
Artificial Intelligence	40	383	34.78%
Human	38	518	33.04%
Gastrointestinal Tract	31	261	26.96%
Article	27	377	23.48%
Gastrointestinal Disease	26	293	22.61%
Convolutional Neural Network	25	306	21.74%
Endoscopy	25	275	21.74%
Diagnosis	23	187	20.00%
Classification	20	99	17.39%
Humans	18	266	15.65%
Algorithm	16	243	13.91%
Feature Extraction	16	150	13.91%
Machine Learning	16	170	13.91%
Capsule Endoscopy	15	136	13.04%

Nota: Elaborado con base en los documentos analizados.

Primera pregunta específica: ¿Cuáles son los trastornos gastrointestinales en humanos que pueden ser identificados y clasificados a partir de patrones y datos biométricos complejos, y qué criterios permiten identificarlos?

El análisis evidenció que los TGI más estudiados son las LGI, evidenciados en la TABLA VI, con los pólipos a la cabeza, representando el 70.43% del total de documentos analizados, debido a su relevancia en la prevención del cáncer colorrectal y su inclusión en programas de detección temprana [12]. Las úlceras y erosiones, vinculadas a trastornos ácido-pépticos [13], también constituyen un foco clave de investigación (50.43%), pues son un tipo de lesión muy recurrente. Así mismo, el cáncer y los tumores se destacan, representando el 49.57% del total, por su alta mortalidad y la necesidad de enfoques multidisciplinarios para su manejo [5]. Entre las EGI, resaltan la esofagitis y la colitis ulcerosa, que demandan diagnósticos precisos debido a su variabilidad clínica [2]. Estas patologías subrayan su complejidad diagnóstica y la necesidad de herramientas especializadas [14]. En cuanto a los métodos de identificación y clasificación de los TGI predominan los análisis visuales y biométricos de acuerdo con los documentos analizados. El color y el contraste (74.78%) son esenciales para detectar alteraciones estructurales y patrones iniciales de lesiones [12]. La textura (71.30%) permite diferenciar lesiones con colores similares, pero estructuras distintas [15]. Factores como la forma y profundidad (46.09%) y el tamaño (36.52%) complementan el análisis, correlacionando dimensiones con el potencial maligno de las lesiones [15]. En contraste, los parámetros biométricos, como los biomarcadores (11.30%) y el análisis de microbiota (8.70%), tienen menor frecuencia de aplicación, pero aportan significativamente en el manejo de enfermedades

inflamatorias crónicas y neoplasias gástricas, facilitando enfoques más personalizados [16]. Por su parte, la entropía (1.74%) es un indicador limitado por su abstracción, utilizado en imágenes endoscópicas para evaluar la variabilidad de texturas mediante el nivel de desorden en la distribución de píxeles. Valores altos de entropía indican mayor complejidad visual, útil para detectar patrones irregulares vinculados a posibles lesiones [17], [18]. La TABLA V resalta categorías como *Enfoque Genérico*, que abarca estudios con análisis generales de TGI sin especificar tipos particulares, centrados en revisiones literarias, y la categoría *Otros*, que agrupa condiciones gastrointestinales diversas no clasificadas en las principales categorías, reflejando la amplitud de los temas abordados. Es importante destacar que las frecuencias de los TGI y criterios aplicados se calcularon individualmente respecto al total de estudios, ya que un trabajo puede abordar múltiples afecciones según los datos analizados. Sin embargo, la disponibilidad limitada de bases de datos clínicas amplias y estructuradas restringe el uso de herramientas de inteligencia artificial, que requieren grandes volúmenes de información para entrenar modelos predictivos efectivos [19].

TABLA VI
DISTRIBUCIÓN DE LOS TGI ESTUDIADOS

Tipos de TGI	Detalle	Frecuencia	% respecto al Total de documentos analizados
Lesiones Vasculares	Úlceras y/o Erosiones	58	50.43%
	Angioectasias	10	8.70%
	Varices	3	2.61%
Lesiones Protuberantes	Pólipos	81	70.43%
	Nódulos	5	4.35%
Enfermedades Inflamatorias	Esofagitis	52	45.22%
	Colitis ulcerosa	51	44.35%
	Chron	12	10.43%
	H. Pylori	12	10.43%
Otros TGI	Cáncer y Tumores	57	49.57%
	Otros	43	37.39%
	Enfoque Genérico	29	25.22%

Nota: Elaborado con base en los documentos analizados.

Asimismo, un análisis estadístico reveló conexiones significativas entre las afecciones digestivas y los métodos de evaluación utilizados. En los pólipos, se observó una correlación leve con la evaluación mediante patrones texturales (coeficiente 0.347, $p < 0.01$) y un vínculo bajo con las características de forma y profundidad (coeficiente 0.255, $p < 0.01$), subrayando una influencia limitada en su análisis. Para la enfermedad de Crohn, los biomarcadores demostraron una conexión moderada (coeficiente 0.507, $p < 0.01$), evidenciando su importancia en la detección y monitoreo de esta condición inflamatoria. Por su parte, el estudio del microbiota indicó una correlación débil (coeficiente 0.298, $p < 0.01$), destacando su papel en la aparición y progresión de la enfermedad [16]. Finalmente, los trabajos realizados en torno a los TGI en personas han logrado establecer métodos de detección que combinan elementos visuales y datos biológicos

avanzados. Entre los primeros destacan aspectos cromáticos, propiedades estructurales y dimensiones, mientras que en los segundos sobresalen las señales biológicas y microbianas, cuya importancia se incrementa en diagnósticos complejos.

Segunda pregunta específica: ¿Cómo se aplican los diferentes modelos de Inteligencia Artificial en la identificación y clasificación de trastornos gastrointestinales utilizando datos biométricos complejos? Las investigaciones analizadas muestran una preferencia predominante por los modelos basados exclusivamente en Deep Learning (DL), que abarcan el 67.83% de los casos según la TABLA VII, gracias a su capacidad para identificar patrones complejos en grandes volúmenes de datos [20]. En contraste, los enfoques centrados únicamente en Machine Learning (ML) representan un 5.22%, limitados por su menor robustez frente a problemas complejos y los altos requerimientos de preprocesamiento y ajuste [1], [14]. La combinación de DL y ML, presente en el 26.96% de los estudios, destaca por integrar las fortalezas de ambas técnicas, donde ML mejora la calidad de los datos en etapas iniciales y DL se enfoca en análisis más especializados como la clasificación y segmentación avanzadas [21], [22].

TABLA VII
MODELOS DE IA ABORDADOS

Modelos de IA	Deep Learning		Total	
	NO	SI		
Machine Learning NO	Referencia	[1], [2], [3], [6], [8], [9], [12], [15], [17], [19], [20], [23], [24], [25], [26], [27], [28], [29], [30], [31], [32], [33], [34], [35], [36], [37], [38], [39], [40], [41], [42], [43], [44], [45], [46], [47], [48], [49], [50], [51], [52], [53], [54], [55], [56], [57], [58], [59], [60], [61], [62], [63], [64], [65], [66], [67], [68], [69], [70], [71], [72], [73], [74], [75], [76], [77], [78], [79], [80], [81], [82], [83], [84], [85], [86], [87], [88], [89]	-	-
	Recuento	0	78	78
	% del total	0.00%	67.83%	67.83%
Machine Learning SI	Referencia	[4], [5], [7], [14], [16], [18], [21], [22], [95], [96], [97], [98], [99], [100], [101], [102], [103], [104], [105], [106], [107], [108], [109], [110], [111], [112], [113], [114], [115], [116], [117]	-	-
	Recuento	6	31	37
	% del total	5.22%	26.96%	32.17%
Total	Recuento	6	109	115
	% del total	5.22%	94.78%	100.00%

Nota: Elaborado con base en los documentos analizados.

La TABLA VIII resume las estructuras de los modelos de IA analizados, agrupándolos por su enfoque predominante para facilitar su comprensión. Las CNN (*Convolutional Neural Networks*) destacan como las más empleadas,

representando el 44.35% del total, debido a su capacidad para analizar imágenes médicas y extraer características jerárquicas complejas [14]. Este predominio refleja la importancia de las imágenes médicas como fuente clave en los modelos desarrollados, siendo esenciales tanto para el entrenamiento como para la evaluación. Las CNN se consolidan como herramientas eficaces para identificar características sutiles, lo que las hace fundamentales en la clasificación precisa de los TGI [12], [20]. El 36.52% de los estudios combina CNN con otros enfoques (*XModelo*), como ANN (*Artificial Neuronal Network*) [20], [22], sistemas CAD (*Computer Aided Diagnosis*) [95], [96], entre otros, mostrando una inclinación hacia metodologías híbridas diseñadas para ajustarse a las particularidades de los datos [115]. Esta integración permite aprovechar las fortalezas de cada modelo, incrementando la precisión y robustez de los sistemas de diagnóstico [113]. Por otro lado, el 6.09% emplea variantes avanzadas de CNN, como las tales como DCNN (*Deep Convolutional Neural Networks*), RCNN (*Region-based CNN*) y PDCNN (*Progressive Deep CNN*). Estas versiones optimizan las capacidades de las CNN tradicionales [6], añadiendo capas que capturan patrones abstractos y complejos [69], [111], y procesando datos de manera progresiva, mejorando iterativamente la calidad de las características relevantes durante el entrenamiento [76], [58].

TABLA VIII
MODELOS DE DEEP LEARNING Y MACHINE LEARNING DESARROLLADOS

Detalle Modelos abordados	Frecuencia	% respecto al total de documentos estudiados
CNN	51	44.35%
CNN + XModelo	42	36.52%
Variaciones de CNN ^a	7	6.09%
SVM ^b + XModelo	5	4.35%
RF ^c + XModelo	2	1.74%
Otros modelos	8	6.96%
Total	115	100.00%

Nota: Elaborado con base en los documentos analizados.

^aVariaciones de CNN: DCNN, RCNN, PDCNN. ^bSVM: Support Vector Machine. ^cRF: Random Forest.

En relación con las metodologías utilizadas, se identificó que El 81.74% de las investigaciones emplea una metodología experimental, mientras que el 18.26% corresponde a análisis teóricos. Los estudios experimentales siguen un enfoque sistemático que comienza con la obtención de datos, generalmente de bases públicas o recursos propios. Estos datos, organizados en datasets, se utilizan para analizar o entrenar algoritmos de inteligencia artificial [1]. Posteriormente, los datos pasan por un pretratamiento que los segmenta en conjuntos destinados a aprendizaje, validación y pruebas, etapas fundamentales para el diseño y evaluación del modelo. Este enfoque estructurado permite medir resultados mediante indicadores clave de rendimiento. En contraste, los análisis teóricos se centran en la recopilación y síntesis de información existente. Mediante revisiones detalladas, ofrecen una visión general sobre el estado actual de la investigación en

TGI, destacando logros alcanzados y áreas que requieren mayor atención en el futuro. En síntesis, el enfoque experimental predomina en las investigaciones, con un uso destacado de modelos de IA, especialmente los basados en DL, destacando las CNN como la herramienta más utilizada para la identificación y clasificación de TGI. Aunque los modelos de ML presentan una menor frecuencia cuando se abordan de manera exclusiva, pero adquieren gran relevancia en estrategias híbridas que los combinan con DL. Este enfoque combinado permite incrementar tanto la precisión como la efectividad en los diagnósticos, optimizando el desempeño de los modelos aplicados.

Tercera pregunta específica: ¿Qué modelo de Inteligencia Artificial ofrece la mayor efectividad en términos de sus métricas resultantes, y qué variables o factores afectan más el rendimiento de estos modelos en la detección de los trastornos gastrointestinales? El análisis del rendimiento de un modelo incluye factores como el preprocesamiento de datos, el volumen utilizado y los criterios de evaluación empleados [63]. En la TABLA IX se presenta la distribución identificada según las métricas de uso, con relación al total de documentos estudiados. Cabe destacar que no se realiza una suma total, ya que la presencia de cada métrica es independiente, y puede haber uno o más de estos indicadores dentro de un mismo documento. A partir de ello se identificó que la *Accuracy*, es la métrica predominante en los documentos estudiado, presente en el 88.70% de los documentos, el cual refleja la proporción de aciertos totales y es clave en categorías equilibradas, consolidándose como un estándar ampliamente aceptado [63]. *Recall* y *Specificity*, con presencias del 77.39% y 60%, respectivamente, son esenciales para evaluar la identificación correcta de casos verdaderamente positivos y negativos, minimizando errores diagnósticos y garantizando resultados confiables [107]. El F1-score, documentado en el 43.48%, presentado por la media armónica entre precisión y sensibilidad, evalúa de manera integral el rendimiento del modelo, siendo útil en clases desiguales y crítico en contextos clínicos para evitar falsos positivos o negativos [67], [69]. Finalmente, el AUC (*Area Under the Curve*), observado en el 33.91% de los estudios, mide la capacidad de diferenciación entre clases; su cercanía a 1 indica alto desempeño en tareas de clasificación binaria, proporcionando diagnósticos confiables en problemas complejos [37].

TABLA IX
MÉTRICAS RESULTANDES APLICADAS EN LOS ESTUDIOS ANALIZADOS

Métrica	Frecuencia	% respecto al Total
Accuracy	101	87.83%
Recall	89	77.39%
Specificity	70	60.87%
F1-score	50	43.48%
AUC	39	33.91%
MCC	15	13.04%
VPP	14	12.17%
Main IoU	11	9.57%
Main Dice	9	7.83%

VPN	7	6.09%
Kappa	6	5.22%
MAE	2	1.74%
Depth RMSE	1	0.87%
K-fold	1	0.87%

Nota: Elaborado con base en los documentos analizados.

En relación con el volumen y la procedencia de las bases empleadas en los estudios analizados, se evidencia una marcada diversidad. Las bases de origen propio, recolectadas en centros especializados, destacan por su tamaño, que varía desde 1670 imágenes (datos) en las investigaciones más pequeñas, y alcanzando valores de 148158 datos en los trabajos de mayor alcance. Asimismo, *Kvasir* sobresale como la fuente más utilizada, ya sea en su formato original, en combinación con otros conjuntos (*Kvasir + Xdataset*) o mediante sus variantes (*Kvasir_V2*, *Hyper-Kvasir*, *Kvasir-SEG*, etc.), abarcando el 53.91% de los estudios revisados y presentando, al igual que las bases propias, un rango considerable en su volumen (13.91%). Sin embargo, un 18.21% de los estudios no proporciona detalles sobre la procedencia ni el tamaño específico de los datasets utilizados, lo cual dificulta la valoración del alcance y la fiabilidad de los modelos planteados. La disparidad en las dimensiones de los conjuntos de datos es un factor crucial para el rendimiento y la aplicabilidad de las metodologías en tareas como la clasificación o el diagnóstico [63]. En términos generales, los modelos entrenados con bases de datos más amplias tienden a ser más sólidos y adaptables, mientras que aquellos que utilizan conjuntos más pequeños suelen estar diseñados para aplicaciones de menor escala, con restricciones en problemas de mayor complejidad [63]. Asimismo, en este análisis se revelan diferencias significativas en el desempeño y el volumen de datos utilizados, como se detalla en la TABLA X. De las 115 publicaciones analizadas, se seleccionaron estudios que aplican ML, DL y enfoques híbridos que unifican los ya mencionados. Los hallazgos resaltan la superioridad de las CNN del enfoque DL, ejemplificada en el modelo aplicado para identificar úlceras, erosiones, pólipos, esofagitis y colitis ulcerosa [31], logrando un 98.32% de *accuracy*, 96.13% de *recall* y 99.68% de *specificity*. Este sistema, que opera en dos etapas: localización y clasificación detallada, utilizando 4854 imágenes, optimizando su rendimiento gracias al volumen procesado [31]. Por otra parte, los sistemas que emplean conjuntos más pequeños, como el desarrollado para detectar pólipos mediante imágenes endoscópicas [32], exhiben un comportamiento distinto. Este último utiliza un enfoque bidireccional para captar detalles locales y globales, optimizando la detección en múltiples escalas, logrando resultados significantes. Este ejemplo subraya que no solo la cantidad de datos, sino también el diseño técnico y la estructura del sistema, influyen significativamente en el rendimiento [63]. Esta precisión no solo depende de la cantidad de datos disponibles, sino también de factores como el diseño del modelo, el preprocesamiento y la interpretación de los resultados, resaltando ello, tenemos a los modelos LSTM (*Long Short-Term Memory*) [27] con su capacidad para

manejar secuencias temporales, reportaron niveles de *accuracy* entre 96.63% y 99.22%, junto a F1-scores que oscilan entre el 98% y el 99%. De igual manera, el modelo basado en SVM + RBF (*Radial Basis Function*) [93] orientado a la detección de pólipos mediante características gaussianas, demostró ser eficaz en tareas específicas. Sistemas entrenados con volúmenes más grandes, como RF + Lasso (*Least Absolute Shrinkage and Selection Operator*) [94], alcanzaron un AUC de 0.73, mientras que, un enfoque similar que aborda RF + LR (*Logistic Regression*) [90], al trabajar con conjuntos más extensos, lograron entre 0.73 y 0.75 en esta misma métrica. Finalmente, los modelos híbridos que combinan DL con técnicas de ML presentan un equilibrio destacado. Una arquitectura que integra CNN, KNN (*k-Nearest Neighbors*), SVM, RF y XGBoost (*eXtreme Gradient Boosting*) [104] alcanzó una 85% de *accuracy*, 96.5% en *recall* y 90.2% en

F1-score, demostrando su efectividad incluso con volúmenes de datos más reducidos. demostrando alta eficacia incluso con datos reducidos. En conclusión, las técnicas DL destacan por su capacidad para procesar grandes volúmenes de datos complejos, obteniendo métricas de alta precisión y capacidad discriminatoria. Por otro lado, los modelos ML presentan excelentes resultados cuando se entrenan con conjuntos extensos, sobresaliendo en indicadores como *accuracy* y *recall*. No obstante, los enfoques híbridos, al combinar lo mejor de ambas metodologías, ofrecen un desempeño sobresaliente y menor variabilidad, consolidándose como opciones preferentes en tareas de clasificación de TGI. La elección final dependerá de factores como la arquitectura, el procesamiento y el tamaño de los datos utilizados en el entrenamiento.

TABLA X
ESTUDIOS SELECCIONADOS DE MODELOS DE IA PARA LA DETECCIÓN DE TGI MÁS RELEVANTES EN FUNCIÓN A SUS MÉTRICAS RESULTANTES Y VOLUMEN DE DATOS UTILIZADOS

Modelos Abordados	Tipo de Modelo	Objetivo	Dataset	Tamaño de Datos	Métricas resultantes
CNN [32]	DL	TGI: Úlceras y/o Erosiones, Cáncer y Tumores, Otros.	Fuente Propia	1638	Accuracy: 84.2%; Recall: 80.5%; Specificity: 78.2%; F1-score: 83.5%; AUC: 0.90
CNN [31]	DL	TGI: Úlceras y/o Erosiones, Pólipos, Esofagitis, Colitis ulcerosa,	Kvasir-SEG + Kvasir V2 + Hyper-Kvasir	4854	Accuracy: 98.32%; Recall: 96.13%; Specificity: 99.68%; Main IoU: 90.3%; Main Dice: 82.08%
CNN + LSTM [27]	DL	TGI: Úlceras y/o Erosiones, Pólipos, Esofagitis, Colitis ulcerosa, Otros.	Kvasir + WCE	18000	Accuracy: 96.63% - 99.22% ; Recall: 91% - 97%; F1-score: 98% - 99%; AUC: 0.99 - 1.00
RF + LR [90]	ML	TGI: Cáncer y Tumores,	Fuente Propia	148158	AUC: 0.73 - 0.75
SVM + RBF [93]	ML	TGI: Pólipos,	Kvasir-Capsule	34338	Accuracy: 99.6% ; Recall: 97.5%; Specificity: 99.5%; F1-score: 0.985
RF + Lasso [94]	ML	TGI: Chron, Colitis ulcerosa, Cáncer y Tumores, Enfoque Genérico,	GMrepo-V2	9708	AUC: 0.73
CNN + KNN + SVM + RF + XGBoost [104]	ML + DL	TGI: Úlceras y/o Erosiones, H. Pylori, Esofagitis, Otros.	ImageNet	2167	Accuracy: 85%; Recall: 96.5% ; F1-score: 90.2%; AUC: 0.88; VPP: 84.7%
CNN + GB ^d + RF + KNC ^e [101]	ML + DL	TGI: Pólipos, Esofagitis,	Kvasir-V1	2000	Accuracy: 99.73% ; Recall: 96.91%; Specificity: 98.41%; F1-score: 95.83%; K-fold: 86.96%
CNN + SVM + KNN [7]	ML + DL	TGI: Úlceras y/o Erosiones, Pólipos, Esofagitis, Cáncer y Tumores,	Kvasir-V2 + HyperKvasir.	18422	Accuracy: 98.53%; F1-score: 98.42% ; AUC: 0.99 ; MCC: 0.98

Nota: Elaborado con base en los documentos analizados. ^dGB: Gradient Boosting. ^eKNC: k-Nearest Neighbors Classifier.

IV. CONCLUSIONES

En conclusión, los modelos de IA, en especial los basados en DL, como las CNN, muestran una gran efectividad en la identificación y clasificación de los TGI debido a su capacidad para manejar grandes volúmenes de datos complejos. Estos modelos, al trabajar con datos visuales y biométricos, han demostrado ser particularmente eficaces en el diagnóstico de condiciones como pólipos, úlceras, esofagitis y la enfermedad de Crohn. No obstante, los modelos híbridos que combinan DL y ML ofrecen un rendimiento aún más destacado, ya que aprovechan lo mejor de ambas arquitecturas. Además, se destaca que, debido a la naturaleza de los datos, los criterios visuales son los más usados para diferenciar los distintos tipos de TGI. Asimismo, las métricas de *accuracy*, *recall* y AUC son fundamentales para evaluar estos modelos, pero factores como

el volumen de datos y la calidad del preprocesamiento son determinantes clave en su rendimiento. En general, los modelos híbridos tienden a ofrecer mayor precisión y estabilidad, lo que los convierte en una opción preferible en la clasificación de TGI.

V. PROCESAMIENTO DE DATOS

El procesamiento de los datos puede consultarse en línea en <https://doi.org/10.5281/zenodo.14322088>

VI. AGRADECIMIENTO

Expresamos el agradecimiento al Dr. Nestor Abel Sánchez Goycochea (nsanchezg@utp.edu.pe), investigador de la Universidad Tecnológica del Perú por su contribución en la asesoría del presente manuscrito.

REFERENCIAS

- [1] Rajkumar, S., Harini, C. S., Giri, J., Sairam, V. A., Ahmad, N., Badawy, A. S., Krithika, G. K., Dhanusha, P., Chandrasekar, G. E., & Saphagirivasan, V. (2024). GastroNet: A CNN based system for detection of abnormalities in gastrointestinal tract from wireless capsule endoscopy images. *AIP Advances*, 14(8). <https://doi.org/10.1063/5.0208691>
- [2] Saeed, T., Loo, C. K., & Safiruz Kassim, M. S. (2022). Ensembles of deep learning framework for stomach abnormalities classification. *Computers, Materials and Continua*, 70(3), 4357–4372. <https://doi.org/10.32604/cmc.2022.019076>
- [3] Alhajlah, M., Noor, M. N., Nazir, M., Mahmood, A., Ashraf, I., & Karamat, T. (2023). Gastrointestinal Diseases Classification Using Deep Transfer Learning and Features Optimization. *Computers, Materials and Continua*, 75(1), 2227–2245. <https://doi.org/10.32604/cmc.2023.031890>
- [4] Lin, C. H., Hsu, P. I., Tseng, C. D., Chao, P. J., Wu, I. T., Ghose, S., Shih, C. A., Lee, S. H., Ren, J. H., Shie, C. B., & Lee, T. F. (2023). Application of artificial intelligence in endoscopic image analysis for the diagnosis of a gastric cancer pathogen-*Helicobacter pylori* infection. *Scientific Reports*, 13(1). <https://doi.org/10.1038/s41598-023-40179-5>
- [5] Christou, C. D., & Tsoulfas, G. (2023). Challenges involved in the application of artificial intelligence in gastroenterology: The race is on! In *World Journal of Gastroenterology* (Vol. 29, Issue 48, pp. 6168–6178). Baishideng Publishing Group Inc. <https://doi.org/10.3748/wjg.v29.i48.6168>
- [6] Aggarwal, S., Gupta, I., Kumar, A., Kautish, S., Almazyad, A. S., Mohamed, A. W., Werner, F., & Shokouhifar, M. (2024). GastroFuse-Net: an ensemble deep learning framework designed for gastrointestinal abnormality detection in endoscopic images. *Mathematical Biosciences and Engineering*, 21(8), 6847–6869. <https://doi.org/10.3934/mbe.2024300>
- [7] Sivari, E., Bostanci, E., Guzel, M. S., Acici, K., Asuroglu, T., & Ercelebi Ayyildiz, T. (2023). A New Approach for Gastrointestinal Tract Findings Detection and Classification: Deep Learning-Based Hybrid Stacking Ensemble Models. *Diagnostics*, 13(4). <https://doi.org/10.3390/diagnostics13040720>
- [8] Mohammad, F., & Al-Razgan, M. (2022). Deep Feature Fusion and Optimization-Based Approach for Stomach Disease Classification. *Sensors*, 22(7). <https://doi.org/10.3390/s22072801>
- [9] Pokuaa, H. A., Adekoya, A. F., Weyori, B. A., & Nyarko-Boateng, O. (2024). Patch-and-amplify Capsule Network for the recognition of gastrointestinal diseases. *Scientific African*, 25. <https://doi.org/10.1016/j.sciaf.2024.e02277>
- [10] David Pacheco Ramos, E., Castillo Christian Abraham, D., & Chavarry Chankay, M. (2024). Evaluation of the level of accuracy of multispectral aerial imagery matching through the “Siamese” neural network mode. *Proceedings of the LACCEI International Multi-Conference for Engineering, Education and Technology*. <https://doi.org/10.18687/LACCEI2024.1.1.1808>
- [11] Dios-Castillo, C., Chafloque-Llontop, C., & Sánchez-Rentería, R. (2024). Effectiveness of Machine Learning in environmental pollution from remote sensing images. *Systematic Literature Review*. *Proceedings of the LACCEI International Multi-Conference for Engineering, Education and Technology*. <https://doi.org/10.18687/LACCEI2024.1.1.1402>
- [12] Liu, J., Zhang, W., Liu, Y., & Zhang, Q. (2024). Polyp segmentation based on implicit edge-guided cross-layer fusion networks. *Scientific Reports*, 14(1). <https://doi.org/10.1038/s41598-024-62331-5>
- [13] Dahmouni, A., Abdelouahad, A. A., Aderghal, Y., Guelzim, I., Bellamine, I., & Silkan, H. (2024). A Robust Approach for Ulcer Classification/Detection in WCE Images. *International Journal of Online and Biomedical Engineering*, 20(6), 86–102. <https://doi.org/10.3991/ijoe.v20i06.45773>
- [14] Javed, N., Ghazanfar, H., Balar, B., & Patel, H. (2024). Role of Artificial Intelligence in Endoscopic Intervention: A Clinical Review. *Journal of Community Hospital Internal Medicine Perspectives*, 14(3). <https://doi.org/10.55729/2000-9666.1341>
- [15] Nagao, S., Tani, Y., Shibata, J., Tsuji, Y., Tada, T., Ishihara, R., & Fujishiro, M. (2022). Implementation of artificial intelligence in upper gastrointestinal endoscopy. In *DEN Open* (Vol. 2, Issue 1). John Wiley and Sons Inc. <https://doi.org/10.1002/deo.2.72>
- [16] Lee, K. S., & Kim, E. S. (2022). Explainable Artificial Intelligence in the Early Diagnosis of Gastrointestinal Disease. In *Diagnostics* (Vol. 12, Issue 11). Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/diagnostics12112740>
- [17] Jin, J., Hu, D., Pu, W., Luo, Y., & Feng, X. (2024). Few-shot learning with task adaptation for multi-category gastrointestinal endoscopy classification. *Biomedical Signal Processing and Control*, 95. <https://doi.org/10.1016/j.bspc.2024.106387>
- [18] Baljon, M. (2024). Stomach Disorder Detection and Analysis using Hybrid Learning Vector Quantization with African Buffalo Optimization Algorithm. *International Journal of Mathematical, Engineering and Management Sciences*, 9(1), 90–110. <https://doi.org/10.33889/IJMEMS.2024.9.1.005>
- [19] Liang, H., Li, Z., Lin, W., Xie, Y., Zhang, S., Li, Z., Luo, H., Li, T., & Han, S. (2024). Enhancing Gastrointestinal Stromal Tumor (GIST) Diagnosis: An Improved YOLOv8 Deep Learning Approach for Precise Mitotic Detection. *IEEE Access*, 12, 116829–116840. <https://doi.org/10.1109/ACCESS.2024.3446613>
- [20] Sharma, P., & Hassan, C. (2022). Artificial Intelligence and Deep Learning for Upper Gastrointestinal Neoplasia. In *Gastroenterology* (Vol. 162, Issue 4, pp. 1056–1066). W.B. Saunders. <https://doi.org/10.1053/j.gastro.2021.11.040>
- [21] Naz, J., Sharif, M. I., Sharif, M. I., Kadry, S., Rauf, H. T., & Ragab, A. E. (2023). A Comparative Analysis of Optimization Algorithms for Gastrointestinal Abnormalities Recognition and Classification Based on Ensemble XcepNet23 and ResNet18 Features. *Biomedicines*, 11(6). <https://doi.org/10.3390/biomedicines11061723>
- [22] Chen, H.-Y., Ge, P., Liu, J.-Y., Qu, J.-L., Bao, F., Xu, C.-M., Chen, H.-L., Shang, D., & Zhang, G.-X. (2022). Artificial intelligence: Emerging player in the diagnosis and treatment of digestive disease. *World Journal of Gastroenterology*, 28(20), 2152–2162. <https://doi.org/10.3748/wjg.v28.i20.2152>
- [23] Mendes, F., Mascarenhas, M., Ribeiro, T., Afonso, J., Cardoso, P., Martins, M., Cardoso, H., Andrade, P., Ferreira, J. P. S., Mascarenhas Saraiva, M., & Macedo, G. (2024). Artificial Intelligence and Panendoscopy—Automatic Detection of Clinically Relevant Lesions in Multibrand Device-Assisted Enteroscopy. *Cancers*, 16(1). <https://doi.org/10.3390/cancers16010208>
- [24] Mascarenhas, M., Mendes, F., Ribeiro, T., Afonso, J., Cardoso, P., Martins, M., Cardoso, H., Andrade, P., Ferreira, J., Saraiva, M. M., & Macedo, G. (2023). Deep Learning and Minimally Invasive Endoscopy: Automatic Classification of Pleomorphic Gastric Lesions in Capsule Endoscopy. *Clinical and Translational Gastroenterology*. <https://doi.org/10.14309/ctg.000000000000609>
- [25] Ramamurthy, K., George, T. T., Shah, Y., & Sasidhar, P. (2022). A Novel Multi-Feature Fusion Method for Classification of Gastrointestinal Diseases Using Endoscopy Images. *Diagnostics*, 12(10). <https://doi.org/10.3390/diagnostics12102316>
- [26] Tan, J. L., Pitawela, D., Chinnaratha, M. A., Beany, A., Aguila, E. J., Chen, H. T., Carneiro, G., & Singh, R. (2024). Exploring vision transformers for classifying early Barrett’s dysplasia in endoscopic images: A pilot study on white-light and narrow-band imaging. *JGH Open*, 8(9). <https://doi.org/10.1002/jgh3.70030>
- [27] Al-Otaibi, S., Rehman, A., Mujahid, M., Alotaibi, S., & Saba, T. (2024). Efficient-gastro: optimized EfficientNet model for the detection of gastrointestinal disorders using transfer learning and wireless capsule endoscopy images. *PeerJ Computer Science*, 10, 1–30. <https://doi.org/10.7717/peerj-cs.1902>
- [28] Lalinia, M., & Sahafi, A. (2024). Colorectal polyp detection in colonoscopy images using YOLO-V8 network. *Signal, Image and Video Processing*, 18(3), 2047–2058. <https://doi.org/10.1007/s11760-023-02835-1>
- [29] Sahoo, P. K., Gupta, P., Lai, Y. C., Chiang, S. F., You, J. F., Onthoni, D. D., & Chern, Y. J. (2023). Localization of Colorectal Cancer Lesions in Contrast-Computed Tomography Images via a Deep Learning Approach. *Bioengineering*, 10(8). <https://doi.org/10.3390/bioengineering10080972>
- [30] Zhang, B., Cheng, L., Niu, Y., Wang, A., Zhang, P., Shen, T., Xi, L., Zhang, D., & Li, S. (2022). Identification Tool for Gastric Cancer Based on Integration of 33 Clinical Available Blood Indices Through Deep Learning. *IEEE Access*, 10, 106081–106092. <https://doi.org/10.1109/ACCESS.2022.3172477>
- [31] Nouman Noor, M., Nazir, M., Khan, S. A., Ashraf, I., & Song, O. Y. (2023). Localization and Classification of Gastrointestinal Tract Disorders Using Explainable AI from Endoscopic Images. *Applied Sciences (Switzerland)*, 13(15). <https://doi.org/10.3390/app13159031>
- [32] Ham, H. S., Lee, H. S., Chae, J. W., Cho, H. C., & Cho, H. C. (2022). Improvement of Gastroscopy Classification Performance Through Image Augmentation Using a Gradient-Weighted Class Activation Map. *IEEE Access*, 10, 99361–99369. <https://doi.org/10.1109/ACCESS.2022.3207839>
- [33] Gandikota, H. P., Abirami, S., & Kumar, M. S. (2023). Bottleneck Feature-Based U-Net for Automated Detection and Segmentation of Gastrointestinal Tract Tumors from CT Scans. *Traitement Du Signal*, 40(6), 2789–2797. <https://doi.org/10.18280/ts.400639>
- [34] Sutton, R. T., Zaiâne, O. R., Goebel, R., & Baumgart, D. C. (2022). Artificial intelligence enabled automated diagnosis and grading of ulcerative colitis endoscopy images. *Scientific Reports*, 12(1). <https://doi.org/10.1038/s41598-022-06726-2>
- [35] Chu, Y., Huang, F., Gao, M., Zou, D.-W., Zhong, J., Wu, W., Wang, Q., Shen, X.-N., Gong, T.-T., Li, Y.-Y., & Wang, L.-F. (2023). Convolutional neural network-based segmentation network applied to image recognition of angiodysplasias lesion under capsule endoscopy. *J Gastroenterol*, 29(5), 766–907. <https://doi.org/10.3748/wjg.v29.i5.879>
- [36] Sharmila, V., & Geetha, S. (2024). Gastro Intestinal Disease Classification Using Hierarchical Spatio Pyramid TranfoNet with PitTree Fusion and Efficient-CondConv SwishNet. *IEEE Access*, 12, 113972–113987. <https://doi.org/10.1109/ACCESS.2024.3438799>
- [37] Padmavathi, P., & Harikiran, J. (2023). Se-Resnet: A Novel Method for Gastrointestinal (GI) Diseases Classification from Wireless Capsule Endoscopy (WCE) Images. *Traitement Du Signal*, 40(4), 1341–1353. <https://doi.org/10.18280/ts.400404>
- [38] Elmagzoub, M. A., Kaur, S., Rajab, A., Rajab, K. D., Reshan, M. S. al, Alshahrani, H., & Shaikh, A. (2024). Improving Endoscopic Image Analysis: Attention Mechanism Integration in Grid Search Fine-Tuned Transfer Learning Model for Multi-Class Gastrointestinal Disease Classification. *IEEE Access*, 12, 80345–80358. <https://doi.org/10.1109/ACCESS.2024.3408224>

- [39] Kiziloluk, S., Yildirim, M., Bingol, H., & Alatas, B. (2024). Multi-feature fusion and dandelion optimizer based model for automatically diagnosing the gastrointestinal diseases. *PeerJ Computer Science*, 10. <https://doi.org/10.7717/peerj-cs.1919>
- [40] Ramzan, M., Raza, M., Sharif, M. I., Azam, F., Kim, J., & Kadry, S. (2023). Gastrointestinal tract disorders classification using ensemble of InceptionNet and proposed GITNet based deep feature with ant colony optimization. In *PLoS ONE* (Vol. 18, Issue 10 October). Public Library of Science. <https://doi.org/10.1371/journal.pone.0292601>
- [41] Haile, M. B., Salau, A. O., Enyew, B., & Belay, A. J. (2022). Detection and classification of gastrointestinal disease using convolutional neural network and SVM. *Cogent Engineering*, 9(1). <https://doi.org/10.1080/23311916.2022.2084878>
- [42] Khan, Z. F., Ramzan, M., Raza, M., Khan, M. A., Iqbal, K., Kim, T., & Cha, J. H. (2024). Deep Convolutional Neural Networks for Accurate Classification of Gastrointestinal Tract Syndromes. *Computers, Materials and Continua*, 78(1), 1207–1225. <https://doi.org/10.32604/cmc.2023.045491>
- [43] Iqbal, I., Walayat, K., Kakar, M. U., & Ma, J. (2022). Automated identification of human gastrointestinal tract abnormalities based on deep convolutional neural network with endoscopic images. *Intelligent Systems with Applications*, 16. <https://doi.org/10.1016/j.iswa.2022.200149>
- [44] Khan, M. A., Sahar, N., Khan, W. Z., Alhaisoni, M., Tariq, U., Zayyan, M. H., Kim, Y. J., & Chang, B. (2022). GastroNet: A Framework of Saliency Estimation and Optimal Deep Learning Features Based Gastrointestinal Diseases Detection and Classification. *Diagnostics*, 12(11). <https://doi.org/10.3390/diagnostics12112718>
- [45] Liu, E., He, B., Zhu, D., Chen, Y., & Xu, Z. (2024). Tiny polyp detection from endoscopic video frames using vision transformers. *Pattern Analysis and Applications*, 27(2). <https://doi.org/10.1007/s10044-024-01254-3>
- [46] Yokote, A., Umeno, J., Kawasaki, K., Fujioka, S., Fuyuno, Y., Matsuno, Y., Yoshida, Y., Imazu, N., Miyazono, S., Moriyama, T., Kitazono, T., & Torisu, T. (2024). Small bowel capsule endoscopy examination and open access database with artificial intelligence: The SEE-artificial intelligence project. *DEN Open*, 4(1). <https://doi.org/10.1002/deo2.258>
- [47] Thomas Abraham, J. v., Muralidhar, A., Sathyarajasekaran, K., & Ilakiyaselvan, N. (2023). A Deep-Learning Approach for Identifying and Classifying Digestive Diseases. *Symmetry*, 15(2). <https://doi.org/10.3390/sym15020379>
- [48] Liu, G.-S., Huang, P.-Y., Wen, M.-L., Zhuang, S.-S., Hua, J., & He, X.-P. (2022). Application of endoscopic ultrasonography for detecting esophageal lesions based on convolutional neural network. *J Gastroenterol*, 28(22), 2403–2526. <https://doi.org/10.3748/wjg.v28.i22.2457>
- [49] Bordbar, M., Helfroush, M. S., Danyali, H., & Ejtehadi, F. (2023). Wireless capsule endoscopy multiclass classification using three-dimensional deep convolutional neural network model. *BioMedical Engineering Online*, 22(1). <https://doi.org/10.1186/s12938-023-01186-9>
- [50] Khalaf, K., Fujiyoshi, M. R. A., Spadaccini, M., Rizkala, T., Ramai, D., Colombo, M., Fugazza, A., Facciorusso, A., Carrara, S., Hassan, C., & Repici, A. (2024). From Staining Techniques to Artificial Intelligence: A Review of Colorectal Polyps Characterization. In *Medicina (Lithuania)* (Vol. 60, Issue 1). Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/medicina60010089>
- [51] Mohapatra, S., Kumar Pati, G., Mishra, M., & Swarnkar, T. (2023). Gastrointestinal abnormality detection and classification using empirical wavelet transform and deep convolutional neural network from endoscopic images. *Ain Shams Engineering Journal*, 14(4). <https://doi.org/10.1016/j.asej.2022.101942>
- [52] Gunasekaran, H., Ramalakshmi, K., Swaminathan, D. K., J. A., & Mazzara, M. (2023). GIT-Net: An Ensemble Deep Learning-Based GI Tract Classification of Endoscopic Images. *Bioengineering*, 10(7). <https://doi.org/10.3390/bioengineering10070809>
- [53] Wu, S., Zhang, R., Yan, J., Li, C., Liu, Q., Wang, L., & Wang, H. (2023). High-Speed and Accurate Diagnosis of Gastrointestinal Disease: Learning on Endoscopy Images Using Lightweight Transformer with Local Feature Attention. *Bioengineering*, 10(12). <https://doi.org/10.3390/bioengineering10121416>
- [54] Nouman Noor, M., Nazir, M., Khan, S. A., Song, O. Y., & Ashraf, I. (2023). Efficient Gastrointestinal Disease Classification Using Pretrained Deep Convolutional Neural Network. *Electronics (Switzerland)*, 12(7). <https://doi.org/10.3390/electronics12071557>
- [55] Demirbas, A. A., Üzen, H., & Firat, H. (2024). Spatial-attention ConvMixer architecture for classification and detection of gastrointestinal diseases using the Kvasir dataset. *Health Information Science and Systems*, 12(1). <https://doi.org/10.1007/s13755-024-00290-x>
- [56] Pang, X., Zhao, Z., Wu, Y., Chen, Y., & Liu, J. (2023). Computer-aided diagnosis system based on multi-scale feature fusion for screening large-scale gastrointestinal diseases. *Journal of Computational Design and Engineering*, 10(1), 368–381. <https://doi.org/10.1093/jcde/qwac138>
- [57] Lee, E., Kim, J. S., Park, D. K., & Whangbo, T. (2024). YOLO-MR: Meta-Learning-Based Lesion Detection Algorithm for Resolving Data Imbalance. *IEEE Access*, 12, 49762–49771. <https://doi.org/10.1109/ACCESS.2024.3384088>
- [58] Ahamed, M. F., Nahiduzzaman, M., Islam, M. R., Naznine, M., Arselene Ayari, M., Khandakar, A., & Haider, J. (2024). Detection of various gastrointestinal tract diseases through a deep learning method with ensemble ELM and explainable AI. *Expert Systems with Applications*, 256. <https://doi.org/10.1016/j.eswa.2024.124908>
- [59] Lafraxo, S., Souaidi, M., el Ansari, M., & Koutti, L. (2023). Semantic Segmentation of Digestive Abnormalities from WCE Images by Using AttResU-Net Architecture. *Life*, 13(3). <https://doi.org/10.3390/life13030719>
- [60] Ahamed, M. F., Islam, M. R., Nahiduzzaman, M., Karim, M. J., Ayari, M. A., & Khandakar, A. (2024). Automated Detection of Colorectal Polyp Utilizing Deep Learning Methods With Explainable AI. *IEEE Access*, 12, 78074–78100. <https://doi.org/10.1109/ACCESS.2024.3402818>
- [61] Alam, M. J., Rashid, R. bin, Fattah, S. A., & Saquib, M. (2022). RA-CapsNet: A Deep Learning Network Utilizing Attention and Regional Information for Abnormality Detection in Wireless Capsule Endoscopy. *IEEE Journal of Translational Engineering in Health and Medicine*, 10. <https://doi.org/10.1109/JTEHM.2022.3198819>
- [62] Mohanalakshmi, S., Bindu, G. H., Rajavel, S. E., & Sriram, G. (2024). Attention Based Fused CNN for the Early Prediction of Gastrointestinal Disease. *SSRG International Journal of Electronics and Communication Engineering*, 11(8), 301–311. <https://doi.org/10.14445/23488549/IJECE-V11I8P129>
- [63] Kim, E. S., & Lee, K. S. (2024). Artificial intelligence in colonoscopy: from detection to diagnosis. In *Korean Journal of Internal Medicine* (Vol. 39, Issue 4, pp. 555–562). Korean Association of Internal Medicine. <https://doi.org/10.3904/kjim.2023.332>
- [64] Ye, C., Che, K., Yao, Y., Ma, N., Zhang, R., Xu, Y., Wang, J., & Meng, M. Q. H. (2024). A deep learning-based system for accurate detection of anatomical landmarks in colon environment. *Intelligence and Robotics*, 4(2), 164–178. <https://doi.org/10.20517/ir.2024.10>
- [65] Ayana, G., Barki, H., & Choe, S. W. (2024). Pathological Insights: Enhanced Vision Transformers for the Early Detection of Colorectal Cancer. *Cancers*, 16(7). <https://doi.org/10.3390/cancers16071441>
- [66] Sahafi, A., Koulaouzidis, A., & Lalinia, M. (2024). Polypoid Lesion Segmentation Using YOLO-V8 Network in Wireless Video Capsule Endoscopy Images. *Diagnostics*, 14(5). <https://doi.org/10.3390/diagnostics14050474>
- [67] Kaur, P., & Kumar, R. (2024). Performance analysis of convolutional neural network architectures over wireless capsule endoscopy dataset. *Bulletin of Electrical Engineering and Informatics*, 13(1), 312–319. <https://doi.org/10.11591/eei.v13i1.5858>
- [68] Pokuaa, H. A., Adekoya, A. F., Weyori, B. A., & Nyarko-Boateng, O. (2024). DPafy-GCaps: Denoising patch-and-amplify Gabor capsule network for the recognition of gastrointestinal diseases. *Turkish Journal of Electrical Engineering and Computer Sciences*, 32(3), 452–464. <https://doi.org/10.55730/1300-0632.4080>
- [69] Hossain, T., Shamrat, F. M. J. M., Zhou, X., Mahmud, I., Mazumder, M. S. A., Sharmin, S., & Gururajan, R. (2024). Development of a multi-fusion convolutional neural network (MF-CNN) for enhanced gastrointestinal disease diagnosis in endoscopy image analysis. *PeerJ Computer Science*, 10. <https://doi.org/10.7717/PEERJ-CS.1950>
- [70] Marya, A. A., Raj, A., P. W., Karthik, C., & Karunaharan, A. (2023). GastroNet: A Custom Deep Learning Approach for Classification of Anomalies in Gastrointestinal Endoscopy Images. *Current Medical Imaging Formerly Current Medical Imaging Reviews*, 20. <https://doi.org/10.2174/1573405620666230906092310>
- [71] Huo, X., Sun, G., Tian, S., Wang, Y., Yu, L., Long, J., Zhang, W., & Li, A. (2024). HiFuse: Hierarchical multi-scale feature fusion network for medical image classification. *Biomedical Signal Processing and Control*, 87. <https://doi.org/10.1016/j.bspc.2023.105534>
- [72] Thunold, H. H., Riegler, M. A., Yazidi, A., & Hammer, H. L. (2023). A Deep Diagnostic Framework Using Explainable Artificial Intelligence and Clustering. *Diagnostics*, 13(22). <https://doi.org/10.3390/diagnostics13223413>
- [73] Buchan, E., & Oppenheimer, P. G. (2023). Review—Vibrational spectroscopy-aided diagnosis, prognosis and treatment of inflammatory bowel disease. In *Clinical and Translational Discovery* (Vol. 3, Issue 5). Blackwell Publishing. <https://doi.org/10.1002/ctd2.249>
- [74] Manjunath, M. P., & Gorappa, K. N. (2023). Deep learning architectures for abnormality detection in endoscopy videos. *Revue d'Intelligence Artificielle*, 37(3), 773–782. <https://doi.org/10.18280/ria.370326>
- [75] Zhuang, H., Zhang, J., & Liao, F. (2023). A systematic review on application of deep learning in digestive system image processing. *Visual Computer*, 39(6), 2207–2222. <https://doi.org/10.1007/s00371-021-02322-z>
- [76] Souaidi, M., Lafraxo, S., Kerkaou, Z., el Ansari, M., & Koutti, L. (2023). A Multiscale Polyp Detection Approach for GI Tract Images Based on Improved DenseNet and Single-Shot Multibox Detector. *Diagnostics*, 13(4). <https://doi.org/10.3390/diagnostics13040733>
- [77] Lan, X., Chen, H., & Jin, W. (2023). DRI-Net: segmentation of polyp in colonoscopy images using dense residual-inception network. *Frontiers in Physiology*, 14. <https://doi.org/10.3389/fphys.2023.1290820>
- [78] Yasmin, F., Hassan, M. M., Hasan, M., Zaman, S., Bairagi, A. K., El-Shafai, W., Fouad, H., & Chun, Y. C. (2023). GastroNet: Gastrointestinal Polyp and Abnormal Feature Detection and Classification With Deep Learning Approach. *IEEE Access*, 11, 97605–97624. <https://doi.org/10.1109/ACCESS.2023.3312729>
- [79] Ahmad, S., Kim, J. S., Park, D. K., & Whangbo, T. (2023). Automated Detection of Ghac Lesions in Endoscopic Images by Leveraging Attention-Based YOLOv7. *IEEE Access*, 11, 87166–87177. <https://doi.org/10.1109/ACCESS.2023.3296710>
- [80] Noor, M. N., Nazir, M., Ashraf, I., Almujaally, N. A., Aslam, M., & Fizzah Jilani, S. (2023). GastroNet: A robust attention-based deep learning and cosine similarity

- feature selection framework for gastrointestinal disease classification from endoscopic images. *CAAI Transactions on Intelligence Technology*. <https://doi.org/10.1049/cit.12231>
- [81] Mary, X. A., Raj, A. P. W., Evangelina, C. S., Neebha, T. M., Kumaravelu, V. B., & Manimegalai, P. (2023). Multi-Class Classification of Gastrointestinal Diseases using Deep Learning Techniques. *The Open Biomedical Engineering Journal*, 17(1). <https://doi.org/10.2174/18741207-v17-e230215-2022-h27-3589-11>
- [82] Lonseko, Z. M., Du, W., Adjei, P. E., Luo, C., Hu, D., Gan, T., Zhu, L., & Rao, N. (2023). Semi-Supervised Segmentation Framework for Gastrointestinal Lesion Diagnosis in Endoscopic Images. *Journal of Personalized Medicine*, 13(1). <https://doi.org/10.3390/jpm13010118>
- [83] Alhajlah, M. (2022). Robust Ulcer Classification: Contrast and Illumination Invariant Approach. *Diagnostics*, 12(12). <https://doi.org/10.3390/diagnostics12122898>
- [84] del Amor, R., Meseguer, P., Parigi, T. L., Villanacci, V., Colomer, A., Launet, L., Bazarova, A., Tontini, G. E., Bisschops, R., de Hertogh, G., Ferraz, J. G., Götz, M., Gui, X., Hayee, B. H., Lazarev, M., Panaccione, R., Parra-Blanco, A., Bhandari, P., Pastorelli, L., ... Naranjo, V. (2022). Constrained multiple instance learning for ulcerative colitis prediction using histological images. *Computer Methods and Programs in Biomedicine*, 224. <https://doi.org/10.1016/j.cmpb.2022.107012>
- [85] Wallace, M. B., Sharma, P., Bhandari, P., East, J., Antonelli, G., Lorenzetti, R., Vieth, M., Speranza, I., Spadaccini, M., Desai, M., Lukens, F. J., Babameto, G., Batista, D., Palmer, D., Ramirez, W., Ramirez, F., Palmer, R., Lunsford, T., Ruff, K., ... Hassan, C. (2022). Impact of Artificial Intelligence on Miss Rate of Colorectal Neoplasia. *Gastroenterology*, 163(1), 295-304.e5. <https://doi.org/10.1053/j.gastro.2022.03.007>
- [86] Zhang, C., Xiong, Z., Chen, S., Ding, A., Cao, Y., Liu, B., & Liu, X. (2022). Automated Disease Detection in Gastroscopy Videos Using Convolutional Neural Networks. *Frontiers in Medicine*, 9. <https://doi.org/10.3389/fmed.2022.846024>
- [87] Hirai, K., Kuwahara, T., Furukawa, K., Kakushima, N., Furune, S., Yamamoto, H., Marukawa, T., Asai, H., Matsui, K., Sakai, Y., Sakai, D., Yamada, K., Nishikawa, T., Yahashi, D., Obayashi, T., Komiya, T., Ishikawa, E., Sawada, T., Maeda, K., ... Fujishiro, M. (2022). Artificial intelligence-based diagnosis of upper gastrointestinal subepithelial lesions on endoscopic ultrasonography images. *Gastric Cancer*, 25(2), 382–391. <https://doi.org/10.1007/s10120-021-01261-x>
- [88] Xia, L., Sun, S., & Dai, W. (2022). Deep Learning-Based Ultrasound Combined with Gastroscopy for the Diagnosis and Nursing of Upper Gastrointestinal Submucosal Lesions. *Computational and Mathematical Methods in Medicine*, 2022. <https://doi.org/10.1155/2022/1607099>
- [89] Ayyoubi Nezhad, S., Khatibi, T., & Sohrabi, M. (2022). Proposing Novel Data Analytics Method for Anatomical Landmark Identification from Endoscopic Video Frames. *Journal of Healthcare Engineering*, 2022. <https://doi.org/10.1155/2022/8151177>
- [90] Read, A. J., Zhou, W., Saini, S. D., Zhu, J., & Waljee, A. K. (2023). Prediction of Gastrointestinal Tract Cancers Using Longitudinal Electronic Health Record Data. *Cancers*, 15(5). <https://doi.org/10.3390/cancers15051399>
- [91] Safra, M., Werner, L., Peres, A., Polak, P., Salamon, N., Schvimer, M., Weiss, B., Barshack, I., Shouval, D. S., & Yaari, G. (2023). A somatic hypermutation-based machine learning model stratifies individuals with Crohn's disease and controls. *Genome Research*, 33(1), 71–79. <https://doi.org/10.1101/gr.276683.122>
- [92] Lee, S., & Lee, I. (2024). Comprehensive assessment of machine learning methods for diagnosing gastrointestinal diseases through whole metagenome sequencing data. *Gut Microbes*, 16(1). <https://doi.org/10.1080/19490976.2024.2375679>
- [93] Delagah, B., & Hassanpour, H. (2023). Feature Extraction for Polyp Detection in Wireless Capsule Endoscopy Video Frames. *Journal of Healthcare Engineering*, 2023. <https://doi.org/10.1155/2023/6076514>
- [94] Li, M., Liu, J., Zhu, J., Wang, H., Sun, C., Gao, N. L., Zhao, X. M., & Chen, W. H. (2023). Performance of Gut Microbiome as an Independent Diagnostic Tool for 20 Diseases: Cross-Cohort Validation of Machine-Learning Classifiers. *Gut Microbes*, 15(1). <https://doi.org/10.1080/19490976.2023.2205386>
- [95] Fati, S. M., Senan, E. M., & Azar, A. T. (2022). Hybrid and Deep Learning Approach for Early Diagnosis of Lower Gastrointestinal Diseases. *Sensors*, 22(11). <https://doi.org/10.3390/s22114079>
- [96] Obayya, M., Al-Wesabi, F. N., Maashi, M., Mohamed, A., Hamza, M. A., Drar, S., Yaseen, I., & Alsaid, M. I. (2023). Modified Salp Swarm Algorithm with Deep Learning Based Gastrointestinal Tract Disease Classification on Endoscopic Images. *IEEE Access*, 11, 25959–25967. <https://doi.org/10.1109/ACCESS.2023.3256084>
- [97] Vania, M., Tama, B. A., Maulahela, H., & Lim, S. (2023). Recent Advances in Applying Machine Learning and Deep Learning to Detect Upper Gastrointestinal Tract Lesions. In *IEEE Access* (Vol. 11, pp. 66544–66567). Institute of Electrical and Electronics Engineers Inc. <https://doi.org/10.1109/ACCESS.2023.3290997>
- [98] Luo, D., Kuang, F., Du, J., Zhou, M., Liu, X., Luo, X., Tang, Y., Li, B., & Su, S. (2022). Artificial Intelligence-Assisted Endoscopic Diagnosis of Early Upper Gastrointestinal Cancer: A Systematic Review and Meta-Analysis. In *Frontiers in Oncology* (Vol. 12). Frontiers Media S.A. <https://doi.org/10.3389/fonc.2022.855175>
- [99] Ukashi, O., Soffer, S., Klang, E., Eliakim, R., Ben-Horin, S., & Kopylov, U. (2023). Capsule Endoscopy in Inflammatory Bowel Disease: Panenteric Capsule Endoscopy and Application of Artificial Intelligence. In *Gut and Liver* (Vol. 17, Issue 4, pp. 516–528). Editorial Office of Gut and Liver. <https://doi.org/10.5009/gnl220507>
- [100] Wu, S., Wang, J., Guo, Q., Lan, H., Zhang, J., Wang, L., Janne, E., Luo, X., Wang, Q., Song, Y., Mathew, J. L., Xun, Y., Yang, N., Lee, M. S., & Chen, Y. (2022). Application of artificial intelligence in clinical diagnosis and treatment: an overview of systematic reviews. *Intelligent Medicine*, 2(2), 88–96. <https://doi.org/10.1016/j.imed.2021.12.001>
- [101] Islam, M. S., Rony, M. A. T., & Sultan, T. (2024). GastroVRG: Enhancing early screening in gastrointestinal health via advanced transfer features. *Intelligent Systems with Applications*, 23. <https://doi.org/10.1016/j.iswa.2024.200399>
- [102] Ghaleb Al-Mekhlafi, Z., Mohammed Senan, E., Sulaiman Alshudukhi, J., & Abdulkarem Mohammed, B. (2023). Hybrid Techniques for Diagnosing Endoscopy Images for Early Detection of Gastrointestinal Disease Based on Fusion Features. *International Journal of Intelligent Systems*, 2023. <https://doi.org/10.1155/2023/8616939>
- [103] Guo, H., Somayajula, S. A., Hosseini, R., & Xie, P. (2024). Improving image classification of gastrointestinal endoscopy using curriculum self-supervised learning. *Scientific Reports*, 14(1). <https://doi.org/10.1038/s41598-024-53955-8>
- [104] Qiao, X., Lu, C., Duan, M., Liu, Z., Liu, Y., Chen, W., Gao, R., Li, Z., & Zuo, X. (2024). Intelligent tongue diagnosis model for gastrointestinal diseases based on tongue images. *Biomedical Signal Processing and Control*, 96. <https://doi.org/10.1016/j.bspc.2024.106643>
- [105] Auzine, M. M., Khan, M. H. M., Baichoo, S., Sahib, N. G., Bissoonauth-Daiboo, P., Gao, X., & Heetun, Z. (2024). Development of an ensemble CNN model with explainable AI for the classification of gastrointestinal cancer. *PLoS ONE*, 19(6 June). <https://doi.org/10.1371/journal.pone.0305628>
- [106] Hicks, S., Storås, A., Riegler, M. A., Midoglu, C., Hammou, M., Lange, T. de, Parasa, S., Halvorsen, P., & Strümke, I. (2024). Visual explanations for polyp detection: How medical doctors assess intrinsic versus extrinsic explanations. *PLoS ONE*, 19(5 May). <https://doi.org/10.1371/journal.pone.0304069>
- [107] Guo, F., & Meng, H. (2024). Application of artificial intelligence in gastrointestinal endoscopy. In *Arab Journal of Gastroenterology* (Vol. 25, Issue 2, pp. 93–96). Elsevier Ltd. <https://doi.org/10.1016/j.ajg.2023.12.010>
- [108] Fang, S., Liu, Z., Qiu, Q., Tang, Z., Yang, Y., Kuang, Z., Du, X., Xiao, S., Liu, Y., Luo, Y., Gu, L., Tian, L., Liang, X., Fan, G., Zhang, Y., Zhang, P., Zhou, W., Liu, X., Tian, J., & Wei, W. (2024). Diagnosing and grading gastric atrophy and intestinal metaplasia using semi-supervised deep learning on pathological images: development and validation study. *Gastric Cancer*, 27(2), 343–354. <https://doi.org/10.1007/s10120-023-01451-9>
- [109] George, A. A., Tan, J. L., Kovoov, J. G., Lee, A., Stretton, B., Gupta, A. K., Bacchi, S., George, B., & Singh, R. (2024). Artificial intelligence in capsule endoscopy: development status and future expectations. In *Mini-invasive Surgery* (Vol. 8). OAE Publishing Inc. <https://doi.org/10.20517/2574-1225.2023.102>
- [110] Jiang, S., Wang, T., & Zhang, K. H. (2023). Data-driven decision-making for precision diagnosis of digestive diseases. In *BioMedical Engineering Online* (Vol. 22, Issue 1). BioMed Central Ltd. <https://doi.org/10.1186/s12938-023-01148-1>
- [111] Leśniewska, M., Patryn, R., Kopystecka, A., Kozioł, I., & Budzyńska, J. (2023). Third Eye? The Assistance of Artificial Intelligence (AI) in the Endoscopy of Gastrointestinal Neoplasms. In *Journal of Clinical Medicine* (Vol. 12, Issue 21). Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/jcm12216721>
- [112] Du, R. C., Ouyang, Y. bin, & Hu, Y. (2023). Research trends on artificial intelligence and endoscopy in digestive diseases: A bibliometric analysis from 1990 to 2022. *World Journal of Gastroenterology*, 29(22), 3561–3573. <https://doi.org/10.3748/wjg.v29.i22.3561>
- [113] Ahmed, I. A., Senan, E. M., & Shatnawi, H. S. A. (2023). Hybrid Models for Endoscopy Image Analysis for Early Detection of Gastrointestinal Diseases Based on Fused Features. *Diagnostics*, 13(10). <https://doi.org/10.3390/diagnostics13101758>
- [114] Yuan, L., Yang, L., Zhang, S., Xu, Z., Qin, J., Shi, Y., Yu, P., Wang, Y., Bao, Z., Xia, Y., Sun, J., He, W., Chen, T., Chen, X., Hu, C., Zhang, Y., Dong, C., Zhao, P., Wang, Y., ... Cheng, X. (2023). Development of a tongue image-based machine learning tool for the diagnosis of gastric cancer: a prospective multicentre clinical cohort study. <https://doi.org/10.1016/j.eclinm.2023.101834>
- [115] Parkash, O., Siddiqui, A. T. S., Jiwani, U., Rind, F., Padhani, Z. A., Rizvi, A., Hoodbhoj, Z., & Das, J. K. (2022). Diagnostic accuracy of artificial intelligence for detecting gastrointestinal luminal pathologies: A systematic review and meta-analysis. In *Frontiers in Medicine* (Vol. 9). Frontiers Media S.A. <https://doi.org/10.3389/fmed.2022.1018937>
- [116] Kim, H. J., Gong, E. J., Bang, C. S., Lee, J. J., Suk, K. T., & Baik, G. H. (2022). Computer-Aided Diagnosis of Gastrointestinal Protruded Lesions Using Wireless Capsule Endoscopy: A Systematic Review and Diagnostic Test Accuracy Meta-Analysis. In *Journal of Personalized Medicine* (Vol. 12, Issue 4). MDPI. <https://doi.org/10.3390/jpm12040644>
- [117] Narasimha Raju, A. S., Jayavel, K., & Rajalakshmi, T. (2022). ColoRectalCADx: Expeditious Recognition of Colorectal Cancer with Integrated Convolutional Neural Networks and Visual Explanations Using Mixed Dataset Evidence. *Computational and Mathematical Methods in Medicine*, 2022. <https://doi.org/10.1155/2022/8723957>