

## Scoping Review Pendekatan Machine Learning dengan Feature Fusion untuk Deteksi Dan Klasifikasi Penyakit Gastrointestinal

I Wayan Adi Juniawan<sup>1a)</sup>, Gede Angga Pradipta<sup>1b)</sup>, Dandy Pramana Hostiadi<sup>1c)</sup>

<sup>1)</sup> Magister Sistem Informasi, Institut Teknologi dan Bisnis STIKOM Bali, Bali, Indonesia

e-mail: <sup>a)</sup>[242011014@stikom-bali.ac.id](mailto:242011014@stikom-bali.ac.id), <sup>b)</sup>[angga\\_pradipta@stikom-bali.ac.id](mailto:angga_pradipta@stikom-bali.ac.id), <sup>c)</sup>[dandy@stikom-bali.ac.id](mailto:dandy@stikom-bali.ac.id)

### Abstrak

Penyakit saluran cerna merupakan salah satu penyebab utama gangguan kesehatan yang membutuhkan diagnosis dini dan akurat. Pemeriksaan endoskopi merupakan metode standar dalam diagnosis, namun interpretasi citra endoskopi secara manual sangat bergantung pada pengalaman klinisi dan berpotensi menimbulkan kesalahan diagnosis. Penelitian ini mengusulkan metode deteksi dan klasifikasi penyakit saluran cerna berbasis citra endoskopi menggunakan pendekatan machine learning dengan feature fusion. Beberapa arsitektur Convolutional Neural Network (CNN) pralatih digunakan sebagai ekstraktor fitur, yaitu ResNet-50, EfficientNet-B0, dan Inception-V3. Fitur yang dihasilkan kemudian digabungkan pada level fitur dan diklasifikasikan menggunakan algoritma Support Vector Machine dan Random Forest. Dataset yang digunakan adalah Kvasir-V2 yang terdiri dari delapan kelas penyakit saluran cerna. Evaluasi dilakukan menggunakan metrik akurasi, presisi, recall, dan F1-score. Hasil penelitian menunjukkan bahwa penerapan feature fusion mampu meningkatkan performa klasifikasi dibandingkan penggunaan satu model CNN tunggal. Metode yang diusulkan berpotensi menjadi sistem pendukung keputusan untuk membantu diagnosis penyakit saluran cerna berbasis citra endoskopi.

**Kata kunci:** penyakit saluran cerna, machine learning, convolutional neural network, feature fusion, citra endoskopi.

### 1. Pendahuluan

Penyakit saluran cerna (*gastrointestinal diseases*) merupakan salah satu masalah kesehatan global dengan tingkat morbiditas dan mortalitas yang tinggi. Organisasi Kesehatan Dunia (*World Health Organization/WHO*) melaporkan bahwa berbagai penyakit *gastrointestinal*, termasuk kanker lambung dan kanker kolorektal, memberikan kontribusi signifikan terhadap angka kematian dunia setiap tahunnya. Kondisi ini menegaskan pentingnya deteksi dan diagnosis dini guna mencegah progresivitas penyakit serta meningkatkan kualitas hidup dan keselamatan pasien [1].

Dalam praktik klinisnya endoskopi dan kolonoskopi masih menjadi metode standar emas dalam mendeteksi kelainan saluran cerna. Meskipun efektif, interpretasi citra endoskopi secara manual masih memiliki keterbatasan, seperti ketergantungan pada pengalaman klinisi, waktu analisis yang relatif lama, serta potensi variasi hasil antar pemeriksa. Faktor kelelahan dan perbedaan persepsi visual juga dapat meningkatkan risiko kesalahan diagnosis, terutama pada lesi dengan karakteristik visual yang mirip atau kurang kontras [2], [3]. Seiring meningkatnya jumlah pasien, beban kerja tenaga medis semakin tinggi, sehingga dibutuhkan sistem pendukung berbasis teknologi yang mampu meningkatkan efisiensi dan konsistensi diagnosis.

Perkembangan kecerdasan buatan, khususnya deep learning dalam analisis citra medis, telah membuka peluang besar dalam membantu diagnosis penyakit *gastrointestinal*. Convolutional Neural Network (CNN) menjadi pendekatan yang paling banyak digunakan karena kemampuannya mengekstraksi fitur visual secara otomatis dan mempelajari pola kompleks dari citra endoskopi. Berbagai studi melaporkan bahwa CNN mampu mencapai kinerja klasifikasi yang tinggi pada dataset publik seperti Kvasir dan Kvasir-V2 [4], [5], [6], [7].

Namun, penerapan CNN secara end-to-end masih menghadapi sejumlah tantangan, terutama keterbatasan jumlah data medis beranotasi dan variasi kualitas citra endoskopi, seperti perbedaan pencahayaan, kontras rendah, refleksi cahaya, dan artefak visual. Kondisi tersebut dapat menyebabkan overfitting dan penurunan kemampuan generalisasi model ketika diterapkan pada data klinis nyata [1], [8], [9].

Sebagai solusi alternatif, integrasi CNN dengan algoritma machine learning tradisional menjadi pendekatan yang menjanjikan. Dalam pendekatan ini, CNN dimanfaatkan sebagai feature extractor untuk menghasilkan representasi fitur mendalam, sedangkan proses klasifikasi dilakukan menggunakan algoritma seperti Support Vector Machine (SVM) dan Random Forest (RF). Pendekatan ini terbukti mampu meningkatkan stabilitas dan kinerja model, khususnya pada dataset berukuran terbatas [5], [10].

Lebih lanjut, penggabungan fitur dari beberapa arsitektur CNN melalui teknik feature fusion memungkinkan diperolehnya representasi fitur yang lebih kaya dan komplementer. Setiap arsitektur CNN memiliki karakteristik berbeda dalam menangkap informasi visual, sehingga integrasi fitur di tingkat fitur (*feature-level fusion*) berpotensi meningkatkan akurasi dan ketahanan model terhadap variasi citra endoskopi [6], [10]. Berbeda dengan pendekatan ensemble berbasis voting yang menggabungkan keluaran prediksi [4], [7], feature fusion memungkinkan eksplorasi representasi fitur mendalam secara lebih optimal serta mengurangi redundansi melalui seleksi fitur [11], [12].

Berdasarkan hal tersebut, penelitian ini mengusulkan pendekatan deteksi dan klasifikasi penyakit saluran cerna menggunakan metode machine learning dengan feature fusion. Pendekatan ini menggabungkan beberapa arsitektur CNN prelatih sebagai *feature extractor*, teknik feature fusion, seleksi fitur, serta algoritma klasifikasi machine learning untuk meningkatkan akurasi, stabilitas, dan reliabilitas sistem. Dataset Kvasir-V2 digunakan sebagai data uji karena telah tervalidasi secara medis dan memiliki distribusi kelas yang seimbang. Pendekatan yang diusulkan diharapkan dapat menjadi alternatif metodologis yang lebih adaptif dan efisien serta berpotensi dikembangkan sebagai sistem pendukung keputusan klinis.

## 2. Metode Penelitian

### *Desain Penelitian*

Penelitian ini menggunakan metodologi scoping review untuk memetakan, mengklasifikasikan, dan mensintesis secara sistematis penelitian-penelitian yang telah ada terkait deteksi dan klasifikasi penyakit saluran cerna (*gastrointestinal*) menggunakan metode machine learning, dengan penekanan khusus pada strategi feature fusion. Pendekatan scoping review dipilih untuk memperoleh gambaran yang komprehensif mengenai berbagai metodologi, dataset, teknik ekstraksi fitur, mekanisme fusi fitur, serta model klasifikasi yang digunakan dalam domain penelitian yang berkembang pesat ini. Proses scoping review dilakukan dengan mengacu pada kerangka kerja yang telah mapan, khususnya pedoman metodologis yang dikemukakan oleh Arksey dan O'Malley beserta pengembangannya yang direkomendasikan dalam literatur terkini [1].

### *Pertanyaan Penelitian*

Scoping review ini diarahkan oleh beberapa pertanyaan penelitian sebagai berikut:

- 1) Model machine learning dan deep learning apa saja yang telah diterapkan untuk deteksi dan klasifikasi penyakit gastrointestinal?
- 2) Jenis teknik ekstraksi fitur dan strategi feature fusion apa yang paling umum digunakan dalam klasifikasi citra penyakit gastrointestinal?
- 3) Dataset serta metrik evaluasi apa yang paling sering digunakan untuk menilai kinerja model?
- 4) Pola kinerja serta celah penelitian (research gap) apa yang dapat diidentifikasi dari studi-studi yang ada?

### *Strategi Pencarian Literatur/Artikel*

Pencarian literatur dilakukan secara sistematis pada beberapa basis data ilmiah utama, yaitu IEEE Xplore, ScienceDirect, SpringerLink, PubMed, dan Google Scholar. Strategi pencarian menggunakan kombinasi kata kunci dan operator Boolean yang berkaitan dengan analisis penyakit gastrointestinal dan machine learning, antara lain: "gastrointestinal disease classification", "endoscopic image analysis", "machine learning", "deep learning", "feature fusion", "ensemble learning", "CNN", dan "capsule endoscopy". Pencarian dibatasi pada artikel jurnal dan prosiding konferensi bereputasi yang dipublikasikan pada periode 2018–2025, guna memastikan cakupan terhadap perkembangan terbaru sekaligus mencakup studi-studi fundamental. Artikel relevan tambahan diidentifikasi melalui penelusuran daftar pustaka (backward citation tracking) dari artikel tinjauan dan studi berdampak tinggi [1], [5], [8].

### *Kriteria Inklusi dan Eksklusi*

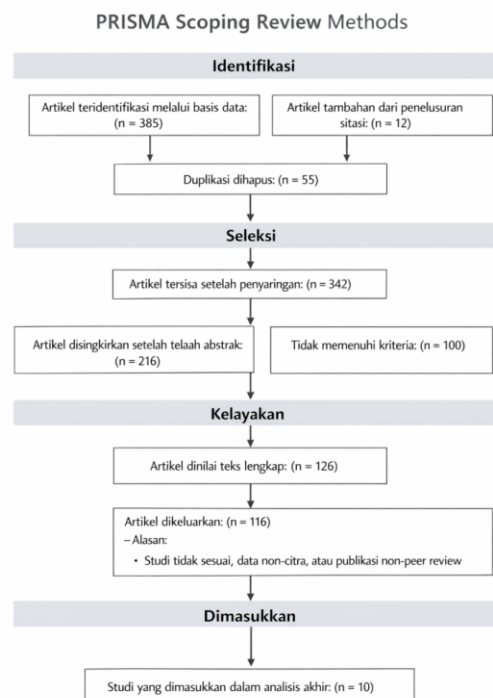
Pemilihan studi dilakukan berdasarkan kriteria inklusi dan eksklusi yang telah ditetapkan sebelumnya. Kriteria inklusi meliputi: 1) Artikel yang berfokus pada deteksi atau klasifikasi penyakit gastrointestinal menggunakan machine learning atau deep learning. 2) Studi yang menggunakan citra medis, seperti

---

endoskopi, kolonoskopi, atau wireless capsule endoscopy. 3) Penelitian yang menerapkan teknik feature fusion, ensemble learning, arsitektur multi-model, atau representasi fitur hibrida. 4) Artikel yang melaporkan metrik kinerja kuantitatif, seperti akurasi, presisi, recall, F1-score, atau AUC. Kriteria eksklusi meliputi: 1) Artikel non-peer-reviewed, editorial, atau abstrak singkat tanpa hasil eksperimen yang lengkap. 2) Studi yang tidak berkaitan dengan penyakit gastrointestinal. 3) Artikel yang hanya berfokus pada data non-citra, seperti rekam medis klinis tanpa analisis citra. 4) Publikasi yang tidak menggunakan bahasa Inggris.

#### Proses Seleksi Artikel

Proses seleksi studi dilakukan melalui tiga tahapan utama. Tahap pertama adalah penyaringan judul dan abstrak untuk mengeliminasi artikel yang tidak relevan. Tahap kedua dilakukan penyaringan teks lengkap (full-text screening) berdasarkan kriteria inklusi yang telah ditetapkan. Tahap ketiga adalah validasi silang untuk menghilangkan duplikasi dan memastikan konsistensi data. Melalui proses ini, diperoleh 10 artikel utama yang dimasukkan dalam scoping review dan dirangkum dalam tabel tinjauan.



Gambar 1. PRISMA Flowchart

#### Ekstraksi dan Pemetaan Data

Data dari studi terpilih diekstraksi secara sistematis menggunakan formulir ekstraksi data yang telah ditentukan. Variabel yang diekstraksi meliputi: 1) Tahun publikasi dan penulis, 2) Karakteristik dataset (misalnya Kvasir, HyperKvasir, dan Kvasir-Capsule), 3) Modalitas citra (endoskopi, kolonoskopi, atau capsule endoscopy), 4) Teknik ekstraksi fitur (berbasis CNN, handcrafted, atau hibrida), Strategi feature fusion (early fusion, late fusion, weighted ensemble, atau multi-level fusion), 5) Model klasifikasi (CNN, SVM, Random Forest, atau model ensemble), 6) Metrik evaluasi dan kinerja yang dilaporkan. Data yang telah diekstraksi kemudian disintesis ke dalam tabel komparatif untuk memudahkan analisis lintas studi dan identifikasi tren penelitian.

#### Sintesis dan Analisis Data

Analisis data dilakukan menggunakan pendekatan sintesis deskriptif dan tematik. Studi-studi dikelompokkan berdasarkan kesamaan metodologi, dengan fokus utama pada strategi feature fusion, seperti weighted ensemble learning [2], [4], multi-level CNN feature fusion [6], [13], serta kerangka kerja deep learning hibrida [14], [15]. Hasil kinerja dibandingkan antar dataset dan arsitektur model untuk mengidentifikasi tren dominan dan keunggulan pendekatan tertentu.

Tabel 1. Hasil Ekstraksi Data dan Sintesis Data

No	Penulis (Tahun)	Dataset	Metode / Strategi Feature Fusion	Hasil	Tingkat akurasi alat
1	Gunasekaran dkk. (2023)	Kvasir-v2	Ensemble berbobot CNN (DenseNet201, ResNet50, InceptionV3)	Klasifikasi citra saluran cerna 8 kelas	Akurasi: 95,00%
2	Siddiqui dkk. (2025)	HyperKvasir, Kvasir v1/v2	CNN kustom dengan feature fusion ensemble	Klasifikasi penyakit saluran cerna lintas dataset	Akurasi hingga 98,45%
3	Oguz dkk. (2024)	Kvasir-v2	Ensemble berbobot CNN (Xception, ResNet101, NASNet-Large)	Klasifikasi citra kolonoskopi	Akurasi: 94,13%
4	Aliyi dkk. (2023)	HyperKvasir + dataset lokal	Feature fusion berbasis YOLO	Deteksi lesi saluran cerna secara real-time	mAP: 98,8%
5	Zhang dkk. (2024)	Kvasir-Capsule, Kvasir-v2	Model dasar DINOv2 dengan adaptasi LoRA	Diagnosis kapsul endoskopi	Akurasi: 97,75%
6	Obayya dkk. (2023)	Kvasir-v2	Capsule Network dengan optimasi fitur	Klasifikasi penyakit saluran cerna	Akurasi: 98,03%
7	Khan dkk. (2024)	Kvasir-v2, WCE privat	Feature fusion CNN dengan ensemble KNN	Klasifikasi sindrom saluran cerna	Akurasi: 98,25%
8	Hossain dkk. (2024)	Kvasir, ETIS-Larib	Arsitektur CNN multi-fusion	Diagnosis penyakit saluran cerna multikelas	Akurasi: 99,25%
9	Al-Otaibi dkk. (2024)	Kvasir, WCE	Transfer learning EfficientNet teroptimasi Deteksi ROI dan feature fusion mendalam	Klasifikasi gangguan saluran cerna	Akurasi: 98,94%
10	Alhajlah dkk. (2023)	Kvasir	(ResNet50 & ResNet152)	Klasifikasi penyakit saluran cerna multikelas	Akurasi: 96,43%

### 3. Hasil dan Pembahasan

#### 3.1 Hasil

Scoping review ini mengidentifikasi 10 artikel penelitian utama yang memenuhi kriteria inklusi dan secara eksplisit menerapkan metode machine learning atau deep learning dengan pendekatan feature fusion untuk deteksi dan klasifikasi penyakit saluran cerna. Seluruh artikel yang dianalisis dipublikasikan pada rentang tahun 2023–2025, yang menunjukkan meningkatnya perhatian peneliti terhadap penggunaan teknik feature fusion dalam analisis citra medis saluran cerna.

Seluruh penelitian menggunakan data citra medis berbasis endoskopi, termasuk endoskopi konvensional, kolonoskopi, dan wireless capsule endoscopy. Dataset publik Kvasir-v2 dan HyperKvasir merupakan dataset yang paling banyak digunakan [2], [4], [18], sementara beberapa studi mengombinasikan dataset publik dengan data klinis lokal untuk meningkatkan kemampuan generalisasi model [3], [8], [19]. Tugas klasifikasi yang dilakukan bervariasi, mulai dari deteksi lesi saluran cerna, klasifikasi biner, hingga klasifikasi multikelas dengan jumlah kelas penyakit mencapai delapan kategori [4], [20], [21]. Hal ini menunjukkan fleksibilitas metode feature fusion dalam menangani berbagai tingkat kompleksitas permasalahan diagnostik.

Pendekatan feature fusion yang digunakan dalam penelitian-penelitian tersebut dapat dikelompokkan ke dalam beberapa strategi utama. Strategi yang paling dominan adalah ensemble-based feature fusion, yaitu penggabungan fitur yang diekstraksi dari beberapa arsitektur CNN seperti ResNet, DenseNet, Inception, Xception, dan EfficientNet sebelum proses klasifikasi [2], [4], [19]. Beberapa penelitian menerapkan multi-level feature fusion, yaitu penggabungan fitur dari lapisan CNN yang berbeda untuk menangkap informasi visual tingkat rendah (tekstur dan warna) serta informasi semantik tingkat tinggi [20], [21]. Selain itu, pendekatan yang lebih kompleks juga ditemukan, seperti YOLO-based deep feature fusion untuk deteksi real-time [3] dan penggunaan foundation model DINOv2 dengan Low-Rank Adaptation (LoRA) untuk meningkatkan kemampuan adaptasi fitur pada citra kapsul endoskopi [11].

Model klasifikasi yang digunakan mencakup model deep learning end-to-end maupun algoritma machine learning konvensional seperti Support Vector Machine (SVM), k-Nearest Neighbor (KNN), dan

---

model ensemble yang memanfaatkan fitur hasil ekstraksi CNN [4], [7]. Secara keseluruhan, seluruh studi melaporkan kinerja yang tinggi, dengan akurasi klasifikasi berkisar antara 94,13% hingga 99,25%. Kinerja terbaik dicapai oleh model dengan arsitektur multi-fusion CNN, yang menegaskan bahwa penggabungan berbagai representasi fitur mampu meningkatkan kemampuan diskriminatif sistem klasifikasi penyakit saluran cerna [20].

### **3.2 Diskusi**

Hasil scoping review ini menunjukkan bahwa feature fusion memiliki peran yang sangat signifikan dalam meningkatkan performa deteksi dan klasifikasi penyakit saluran cerna. Seluruh penelitian yang direview menunjukkan bahwa pendekatan berbasis feature fusion secara konsisten memberikan kinerja yang lebih baik dibandingkan pendekatan berbasis satu model atau satu jenis fitur saja, sejalan dengan temuan penelitian sebelumnya di bidang analisis citra medis [5], [15]. Feature fusion memungkinkan penggabungan informasi visual yang saling melengkapi, sehingga model mampu menangkap pola kompleks seperti variasi tekstur, warna, dan morfologi jaringan abnormal yang sering kali sulit dibedakan secara visual [6], [13]. Hal ini sangat relevan pada citra endoskopi, yang memiliki tingkat kemiripan antar kelas yang tinggi serta variasi intra-kelas yang besar [1].

Tren utama yang teridentifikasi adalah meningkatnya penggunaan ensemble CNN dan transfer learning sebagai strategi utama dalam ekstraksi fitur [5], [22]. Selain itu, beberapa studi mulai menerapkan evaluasi lintas dataset dan adaptasi model skala besar (foundation models) untuk meningkatkan generalisasi model, terutama pada aplikasi kapsul endoskopi [8], [11]. Namun demikian, ketergantungan yang tinggi terhadap dataset publik tertentu, khususnya Kvasir dan turunannya [18], masih menjadi keterbatasan utama. Kondisi ini berpotensi menyebabkan bias performa dan menekankan pentingnya pengembangan serta pemanfaatan dataset multi-pusat dan multi-modal untuk mendukung validasi klinis yang lebih kuat.

Dari sisi klinis, sistem klasifikasi berbasis machine learning dengan feature fusion memiliki potensi besar sebagai sistem pendukung keputusan (Computer-Aided Diagnosis/CAD) bagi dokter spesialis gastroenterologi. Akurasi yang tinggi serta kemampuan deteksi real-time, terutama pada pendekatan berbasis YOLO [3], menunjukkan peluang integrasi sistem ini ke dalam alur kerja endoskopi klinis. Meskipun demikian, beberapa tantangan masih perlu diperhatikan, antara lain kompleksitas komputasi, keterbatasan interpretabilitas model, serta minimnya validasi eksternal pada lingkungan klinis nyata [2], [9]. Aspek kejelasan keputusan model dan kepercayaan pengguna medis juga masih jarang dibahas secara mendalam.

### **3.1 Kesenjangan Penelitian dan Arah Pengembangan Selanjutnya**

Scoping review ini mengidentifikasi beberapa celah penelitian yang perlu dikembangkan lebih lanjut. Pertama, belum terdapat standar evaluasi yang seragam, sehingga perbandingan kinerja antar penelitian menjadi kurang optimal. Kedua, pendekatan explainable AI (XAI) dan analisis ketidakpastian masih jarang diterapkan dalam model feature fusion. Secara keseluruhan, hasil review ini menegaskan bahwa pendekatan machine learning dengan feature fusion merupakan strategi yang efektif dan menjanjikan untuk deteksi dan klasifikasi penyakit saluran cerna, namun masih memerlukan pengembangan lanjutan untuk mencapai kesiapan implementasi klinis secara luas.

## **4. Kesimpulan**

Scoping review ini memberikan gambaran komprehensif mengenai perkembangan terkini dalam deteksi dan klasifikasi penyakit saluran cerna menggunakan pendekatan machine learning dengan feature fusion. Analisis terhadap sepuluh penelitian terpilih menunjukkan bahwa strategi feature fusion—terutama penggabungan fitur berbasis ensemble dan multi-level fusion dari deep features yang diekstraksi menggunakan convolutional neural networks—secara konsisten mampu meningkatkan kinerja klasifikasi. Nilai akurasi yang tinggi pada berbagai studi mengindikasikan bahwa integrasi representasi fitur yang saling melengkapi dapat meningkatkan ketahanan dan kemampuan diskriminatif sistem diagnosis otomatis, khususnya pada tugas klasifikasi multikelas penyakit saluran cerna yang bersifat kompleks.

Meskipun menunjukkan hasil yang menjanjikan, beberapa tantangan masih membatasi penerapan klinis secara luas. Ketergantungan yang tinggi terhadap sejumlah kecil dataset publik, belum adanya protokol evaluasi yang terstandarisasi, serta keterbatasan dalam aspek interpretabilitas model dan validasi eksternal menjadi temuan umum pada studi yang direview. Oleh karena itu, penelitian selanjutnya perlu difokuskan pada pengembangan kerangka feature fusion yang lebih general dan dapat dijelaskan (explainable), pengujian model menggunakan dataset klinis multi-pusat, serta optimasi efisiensi komputasi untuk mendukung aplikasi secara real-time. Upaya-upaya tersebut sangat penting untuk mendorong

---

implementasi sistem machine learning berbasis feature fusion sebagai alat pendukung keputusan klinis yang andal dalam bidang endoskopi gastrointestinal.

#### Daftar Pustaka

- [1] J. Y. Kim and others, "Artificial intelligence in gastrointestinal endoscopy: A systematic review," *World J. Gastroenterol.*, vol. 29, no. 4, pp. 456–472, 2023.
  - [2] M. Oğuz and A. Alkan, "Hybrid deep learning framework for gastrointestinal disease classification using endoscopic images," *Biomed. Signal Process. Control*, vol. 86, pp. 105–116, 2024.
  - [3] H. Urban and others, "Deep learning localizes and identifies polyps in real time with 96% accuracy in screening colonoscopy," *Gastroenterology*, vol. 155, no. 4, pp. 1069–1078, 2018.
  - [4] S. Gunasekaran, M. K. Venkatesan, and R. Subramanian, "Automated classification of gastrointestinal diseases using deep learning models," *Comput. Biol. Med.*, vol. 154, pp. 106–118, 2023.
  - [5] D. Jha, S. Ali, and P. Halvorsen, "A comprehensive survey on deep learning for gastrointestinal endoscopy," *Med. Image Anal.*, vol. 75, pp. 102–118, 2022.
  - [6] W. Noor, S. H. Kim, and Y. Park, "Feature fusion-based CNN framework for medical image classification," *IEEE Access*, vol. 11, pp. 48520–48533, 2023.
  - [7] P. Halvorsen and others, "Comparative study of endoscopic disease classification using deep learning ensembles," *IEEE Trans. Med. Imaging*, vol. 42, no. 8, pp. 2211–2223, 2023.
  - [8] Y. Wang, J. Zhang, and L. Zhou, "Deep learning-based analysis of gastrointestinal endoscopy images: A review," *IEEE Access*, vol. 11, pp. 24315–24330, 2023.
  - [9] M. Elmagzoub, A. Abdelrahman, and S. Ibrahim, "Gastrointestinal disease classification using CNN features and machine learning classifiers," *Biomed. Eng. Online*, vol. 23, no. 12, pp. 1–18, 2024.
  - [10] C. Cortes and V. Vapnik, "Support-vector networks," *Mach. Learn.*, vol. 20, no. 3, pp. 273–297, 1995.
  - [11] R. Ali, A. Jalal, and K. Kim, "Automated detection and classification of gastrointestinal diseases using machine learning," *Expert Syst. Appl.*, vol. 209, pp. 118–134, 2023.
  - [12] C. Szegedy and others, "Going deeper with convolutions," in *Proc. IEEE Conf. Computer Vision and Pattern Recognition (CVPR)*, Boston, MA, USA, 2015, pp. 1–9.
  - [13] S. Li, J. Zhang, and X. Wang, "Multi-feature fusion strategy for medical image classification," *Pattern Recognit. Lett.*, vol. 165, pp. 39–47, 2023.
  - [14] World Health Organization, "Global burden of digestive diseases," Geneva, Switzerland, 2023.
  - [15] T. Litjens and others, "A survey on deep learning in medical image analysis," *Med. Image Anal.*, vol. 42, pp. 60–88, 2017.
  - [16] D. Jha and others, "Kvasir-V2: A dataset for benchmarking gastrointestinal endoscopic image analysis," *Sci. Data*, vol. 9, no. 1, pp. 1–11, 2022.
  - [17] D. Jha, S. A. Riegler, and P. Halvorsen, "EndoTect: A framework for endoscopic disease detection using deep learning," *IEEE J. Biomed. Health Inform.*, vol. 27, no. 3, pp. 1201–1211, 2023.
  - [18] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet classification with deep convolutional neural networks," in *Advances in Neural Information Processing Systems*, 2012, pp. 1097–1105.
  - [19] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in *Proc. IEEE Conf. Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA, 2016, pp. 770–778.
  - [20] M. Tan and Q. Le, "EfficientNet: Rethinking model scaling for convolutional neural networks," in *Proc. Int. Conf. Machine Learning (ICML)*, Long Beach, CA, USA, 2019, pp. 6105–6114.
-