

SYSTEMATIC LITERATURE REVIEW ARSITEKTUR DEEP LEARNING DAN METODE AUGMENTASI DATA UNTUK KLASIFIKASI LIMBAH PLASTIK KONDISI TIDAK IDEAL

Ahmad Taufiq Alfahruzi^{1*}

¹*Informatika, Universitas Muhammadiyah Surabaya, Surabaya, Indonesia*

*Penulis korespondensi: ah.taufiq111@gmail.com

ABSTRAK

Meningkatnya jumlah limbah plastik global mendorong kebutuhan akan sistem klasifikasi otomatis yang akurat dan andal. Berbagai penelitian berbasis deep learning telah menunjukkan kinerja yang baik dalam klasifikasi limbah plastik, namun sebagian besar pengujian masih dilakukan pada kondisi yang terkontrol. Sementara itu, kemampuan model dalam mengenali citra limbah plastik pada kondisi tidak ideal, seperti terkontaminasi, buram, atau memiliki pencahayaan rendah, masih belum banyak dikaji secara komprehensif. Penelitian ini bertujuan untuk mengidentifikasi arsitektur deep learning yang dominan, mengevaluasi metode augmentasi data dan prapemrosesan yang efektif, serta mengidentifikasi research gap pada klasifikasi limbah plastik dalam kondisi tidak ideal. Metode yang digunakan adalah Systematic Literature Review (SLR) dengan mengadopsi pedoman PRISMA. Sebanyak 35 artikel yang diperoleh dari IEEE Xplore, ScienceDirect, dan Google Scholar dianalisis berdasarkan arsitektur model, teknik augmentasi data, dataset, dan metrik evaluasi. Hasil kajian menunjukkan bahwa CNN beserta variannya, seperti MobileNet, EfficientNet, dan DenseNet, merupakan arsitektur yang paling banyak digunakan dengan akurasi 83%-99,46%, sedangkan YOLO menunjukkan kinerja unggul untuk deteksi real-time dengan mAP50 mencapai 98,03%. Teknik augmentasi data, seperti rotasi, normalisasi, dan penambahan noise sintesis, terbukti mampu meningkatkan ketahanan model terhadap variasi visual. Selain itu, ditemukan bahwa penelitian mengenai ketahanan model pada citra limbah plastik yang terkontaminasi atau terdegradasi masih terbatas, serta belum tersedia benchmark dataset standar untuk kondisi non-ideal. Temuan ini dapat menjadi referensi dalam pengembangan sistem klasifikasi limbah plastik yang lebih robust untuk penerapan di lingkungan nyata.

Kata kunci: Systematic Literature Review, Klasifikasi Limbah Plastik, Deep Learning, Augmentasi Data, Convolutional Neural Network

1 PENDAHULUAN

Produksi plastik global saat ini telah melampaui 400 juta ton per tahun. Namun, hanya sekitar 9% limbah plastik yang berhasil didaur ulang, sementara 22% sisanya berakhir di lingkungan akibat pembuangan ilegal, pembakaran terbuka, maupun pencemaran ekosistem perairan (OECD, 2022). Kondisi ini menunjukkan bahwa pengelolaan limbah plastik masih menghadapi berbagai tantangan, terutama pada tahap pemilahan yang menjadi langkah awal dalam proses daur ulang. Seiring meningkatnya volume sampah plastik, metode pemilahan secara manual dinilai semakin kurang efektif karena membutuhkan waktu, tenaga, dan biaya yang besar. Oleh karena itu, diperlukan sistem klasifikasi otomatis yang mampu mendukung proses pengelolaan limbah secara lebih efisien dan berkelanjutan. Salah satu pendekatan yang banyak dikembangkan untuk tujuan tersebut adalah deep learning. Teknologi ini mampu mempelajari karakteristik objek secara otomatis dari data citra dan telah menunjukkan performa yang baik pada berbagai tugas klasifikasi (Sarker, 2021). Dalam bidang pengelolaan limbah

plastik, deep learning berpotensi membantu proses identifikasi dan pemisahan jenis plastik secara otomatis sehingga dapat meningkatkan efisiensi proses daur ulang.

Berbagai penelitian telah menerapkan beragam arsitektur deep learning untuk klasifikasi limbah plastik. Convolutional Neural Network (CNN) beserta variannya, seperti MobileNet, EfficientNet, dan DenseNet, dilaporkan mampu mencapai tingkat akurasi antara 83% hingga 99,46% (Gao et al., 2026; Sayem et al., 2025). Untuk kebutuhan deteksi objek secara real-time, keluarga YOLO juga menunjukkan kinerja yang sangat baik dengan nilai mAP50 mencapai 98,03% pada dataset WaDaBa (Kunwar et al., 2024). Selain pengembangan arsitektur model, berbagai teknik augmentasi data seperti rotasi, normalisasi, dan penambahan noise sintesis telah digunakan untuk meningkatkan kemampuan generalisasi model terhadap variasi data masukan (Terbe et al., 2024). Pada kondisi jumlah data yang terbatas, pendekatan berbasis Generative Adversarial Network (GAN) bahkan dilaporkan mampu meningkatkan performa segmentasi hingga 5,8% (Bacchin et al., 2024).

Meskipun menunjukkan hasil yang menjanjikan, sebagian besar penelitian tersebut dilakukan pada lingkungan pengujian yang relatif terkontrol. Ketika model diterapkan pada kondisi nyata, performanya sering kali mengalami penurunan akibat berbagai gangguan visual yang tidak ditemukan selama proses pelatihan. Dalam penelitian ini, kondisi tidak ideal mengacu pada citra yang memiliki pencahayaan rendah, kontaminasi pada permukaan objek, latar belakang yang kompleks, blur, noise, maupun penurunan kualitas citra akibat proses akuisisi data di lapangan. Sebagai contoh, YOLOv3 Tiny hanya mencapai akurasi sebesar 53,3% dalam mengklasifikasikan plastik transparan pada latar belakang yang kompleks (Kurniawan Saputro et al., 2024). Selain itu, MobileNetV3 dilaporkan mengalami penurunan performa pada kondisi pencahayaan rendah sebelum ditingkatkan melalui penerapan mekanisme Exponential Moving Average (EMA) (Gao et al., 2026). Penelitian lain juga menunjukkan bahwa tingkat kegelapan dan kontaminasi merupakan faktor yang paling berpengaruh terhadap penurunan performa model dibandingkan faktor lingkungan lainnya (Taneepanichskul et al., 2025). Hasil tinjauan sistematis terhadap 56 artikel yang diterbitkan pada periode 2000-2023 turut mengungkap adanya kesenjangan antara akurasi yang diperoleh di lingkungan laboratorium dan ketahanan model pada implementasi lapangan. Selain itu, belum tersedianya dataset benchmark standar untuk citra limbah plastik dalam kondisi non-ideal masih menjadi salah satu hambatan utama dalam pengembangan sistem klasifikasi berbasis kecerdasan buatan (Ramos et al., 2024).

Temuan-temuan tersebut menunjukkan bahwa penelitian mengenai klasifikasi limbah plastik masih didominasi oleh evaluasi pada dataset yang diperoleh dalam kondisi terkontrol. Sementara itu, kajian yang secara khusus membandingkan efektivitas berbagai arsitektur deep learning dan metode augmentasi data dalam menghadapi kondisi citra non-ideal masih relatif terbatas. Di sisi lain, sintesis pengetahuan mengenai faktor-faktor yang memengaruhi ketahanan model pada lingkungan nyata juga belum banyak dilakukan. Berdasarkan kondisi tersebut, penelitian ini menyusun Systematic Literature Review (SLR) dengan mengadopsi pedoman Preferred Reporting Items for Systematic Reviews and Meta-Analyses (PRISMA). Kajian ini bertujuan untuk memetakan arsitektur deep learning yang paling banyak digunakan dalam klasifikasi limbah plastik, mengidentifikasi metode augmentasi data dan teknik prapemrosesan yang efektif untuk menangani citra pada kondisi non-ideal, serta menemukan research gap yang dapat menjadi dasar pengembangan penelitian selanjutnya.

2 METODE

Penelitian ini menggunakan metode Systematic Literature Review (SLR) untuk mengidentifikasi, mengevaluasi, dan mensintesis temuan penelitian terkait penerapan deep learning pada klasifikasi limbah plastik, khususnya pada kondisi citra yang tidak ideal. Metode SLR dipilih karena mampu memberikan gambaran yang komprehensif mengenai perkembangan penelitian, tren teknologi, serta kesenjangan penelitian yang masih terbuka.

Proses kajian dilakukan pada periode April hingga Juni 2026 dengan mengadaptasi pedoman Preferred Reporting Items for Systematic Reviews and Meta-Analyses (PRISMA) sebagai kerangka kerja dalam proses identifikasi, penyaringan, seleksi, dan sintesis literatur.

Fokus kajian diarahkan pada penelitian yang membahas klasifikasi atau deteksi limbah plastik menggunakan pendekatan deep learning, terutama yang mengevaluasi performa model pada kondisi non-ideal seperti pencahayaan rendah, kontaminasi objek, latar belakang kompleks, blur, maupun degradasi kualitas citra. Berdasarkan proses seleksi yang dilakukan secara sistematis, diperoleh 35 artikel yang memenuhi seluruh kriteria penelitian dan digunakan sebagai korpus utama dalam proses analisis.

2.1 Sumber Data dan Strategi Pencarian

Pencarian literatur dilakukan pada tiga basis data ilmiah, yaitu IEEE Xplore, ScienceDirect, dan Google Scholar. IEEE Xplore dipilih karena menyediakan banyak publikasi di bidang kecerdasan buatan, computer vision, dan machine learning. ScienceDirect digunakan untuk memperoleh artikel jurnal bereputasi yang membahas pengolahan citra dan aplikasi teknologi lingkungan. Sementara itu, Google Scholar dimanfaatkan untuk memperluas cakupan pencarian, termasuk artikel konferensi dan publikasi lintas disiplin yang relevan.

Proses pencarian menggunakan kombinasi kata kunci yang disusun berdasarkan topik penelitian dan operator Boolean sebagai berikut:

("plastic waste" OR "plastic classification" OR "waste classification") AND ("deep learning" OR "convolutional neural network" OR "CNN" OR "YOLO") AND ("dirty" OR "contaminated" OR "low-light" OR "blurred" OR "degraded image" OR "suboptimal condition" OR "data augmentation")

Pencarian dibatasi pada artikel yang diterbitkan dalam rentang tahun 2020-2026. Rentang waktu tersebut dipilih karena sebagian besar perkembangan arsitektur deep learning modern, seperti EfficientNet, MobileNet generasi terbaru, dan YOLO versi terkini, berkembang pesat pada periode tersebut. Artikel yang ditemukan kemudian dikelola menggunakan perangkat lunak Mendeley untuk memudahkan proses pengelompokan referensi dan penghapusan artikel duplikat.

2.2 Kriteria Inklusi dan Eksklusi

Kriteria inklusi dan eksklusi ditetapkan sebelum proses seleksi dilakukan guna memastikan objektivitas dan konsistensi dalam pemilihan literatur. Kriteria tersebut disusun berdasarkan tujuan penelitian dan pertanyaan penelitian yang telah dirumuskan sebelumnya.

Tabel 1. Kriteria Inklusi dan Eksklusi

Kriteria	Inklusi	Eksklusi
Topik	Penelitian yang membahas klasifikasi atau deteksi limbah plastik menggunakan deep learning, termasuk studi yang mengevaluasi kondisi non-ideal.	Penelitian yang tidak berkaitan dengan limbah plastik atau tidak menggunakan deep learning.
Tahun Terbit	Artikel yang diterbitkan pada tahun 2020-2026.	Artikel yang diterbitkan sebelum tahun 2020.
Jenis Publikasi	Artikel jurnal dan prosiding konferensi yang telah melalui proses peer-review.	Buku, tesis, disertasi, laporan teknis, dan artikel populer.
Aksesibilitas	Artikel tersedia dalam bentuk full text.	Artikel yang hanya menyediakan abstrak atau tidak dapat diakses secara penuh.

Bahasa	Bahasa Indonesia dan Bahasa Inggris.	Bahasa selain Indonesia dan Inggris.
Fokus Teknis	Membahas arsitektur deep learning, augmentasi data, prapemrosesan citra, atau evaluasi model.	Studi yang hanya membahas aspek sosial, ekonomi, atau kebijakan pengelolaan limbah.

2.3 Proses Seleksi Artikel

Proses seleksi artikel dilakukan dengan mengadaptasi alur PRISMA yang meliputi tahap identifikasi (identification), penyaringan (screening), penilaian kelayakan (eligibility), dan penetapan artikel akhir (included). Tahapan ini bertujuan untuk memastikan bahwa artikel yang digunakan benar-benar relevan dengan topik klasifikasi limbah plastik berbasis deep learning, khususnya pada kondisi citra yang tidak ideal.



Gambar 1. Diagram Alur Seleksi Artikel Berdasarkan PRISMA

Pada tahap identifikasi, pencarian literatur dilakukan pada basis data IEEE Xplore, ScienceDirect, dan Google Scholar menggunakan kata kunci yang telah ditetapkan. Dari proses ini diperoleh sekitar 120 artikel yang berpotensi relevan dengan topik penelitian. Selanjutnya, pada tahap penyaringan, dilakukan pemeriksaan judul dan abstrak untuk mengeliminasi artikel yang tidak sesuai dengan fokus penelitian, seperti studi yang tidak membahas limbah plastik, tidak menggunakan pendekatan deep learning, atau tidak memiliki keterkaitan dengan klasifikasi maupun deteksi citra. Setelah proses ini, sekitar 72 artikel dieliminasi.

Artikel yang lolos tahap penyaringan kemudian memasuki tahap penilaian kelayakan. Pada tahap ini, dokumen full-text ditelaah secara menyeluruh berdasarkan kriteria inklusi dan eksklusi yang telah ditetapkan pada Tabel 1. Artikel yang tidak memenuhi kriteria, seperti tidak menyediakan informasi teknis yang memadai atau tidak dapat diakses secara penuh, dikeluarkan dari proses seleksi. Hasil penilaian kelayakan menghasilkan 30 artikel yang memenuhi persyaratan awal.

Untuk memperkaya cakupan kajian, terutama terkait penelitian yang secara spesifik membahas kondisi citra non-ideal, dilakukan penelusuran tambahan menggunakan metode snowballing. Metode ini dilakukan dengan menelusuri daftar referensi dari artikel-artikel yang telah lolos seleksi. Dari proses tersebut diperoleh lima artikel tambahan yang relevan dengan fokus penelitian. Setelah seluruh tahapan seleksi selesai dilakukan, diperoleh 35 artikel yang memenuhi seluruh kriteria dan ditetapkan sebagai korpus akhir penelitian.

2.4 Ekstraksi dan Sintesis Data

Artikel yang termasuk dalam korpus akhir kemudian dianalisis menggunakan teknik ekstraksi data terstruktur. Proses ini dilakukan untuk mengumpulkan informasi yang relevan dengan tujuan penelitian dan menjawab seluruh research question yang telah dirumuskan. Data yang diekstraksi meliputi identitas artikel (penulis dan tahun publikasi), arsitektur deep learning yang digunakan, metode augmentasi data, teknik prapemrosesan citra, dataset yang digunakan, metrik evaluasi, serta karakteristik kondisi pengujian yang diterapkan.

Selain itu, informasi mengenai performa model, seperti accuracy, precision, recall, F1-score, dan mean Average Precision (mAP), juga dicatat untuk mendukung proses perbandingan antarpenelitian. Perhatian khusus diberikan pada studi yang mengevaluasi model pada kondisi citra non-ideal, seperti pencahayaan rendah, kontaminasi objek, blur, noise, maupun latar belakang yang kompleks.

Data yang telah diekstraksi kemudian disintesis menggunakan pendekatan naratif dan deskriptif-kuantitatif. Sintesis naratif digunakan untuk mengidentifikasi kecenderungan penggunaan arsitektur deep learning, metode augmentasi data, serta teknik prapemrosesan yang paling sering diterapkan dalam klasifikasi limbah plastik. Sementara itu, analisis deskriptif-kuantitatif digunakan untuk membandingkan performa berbagai arsitektur berdasarkan metrik evaluasi yang dilaporkan dan menghitung frekuensi kemunculan metode tertentu dalam korpus penelitian.

Hasil sintesis selanjutnya dikelompokkan ke dalam tiga tema utama sesuai dengan tujuan penelitian, yaitu:

1. pemetaan arsitektur deep learning yang dominan digunakan dalam klasifikasi limbah plastik
2. identifikasi metode augmentasi data dan teknik prapemrosesan yang efektif untuk menangani citra pada kondisi tidak ideal.
3. identifikasi research gap yang masih menjadi tantangan dalam pengembangan sistem klasifikasi limbah plastik berbasis deep learning.

Pendekatan ini memungkinkan diperolehnya gambaran yang lebih komprehensif mengenai perkembangan penelitian sekaligus arah pengembangan yang potensial untuk penelitian selanjutnya.

3 HASIL DAN PEMBAHASAN

3.1 Gambaran Umum Korpus Penelitian

Berdasarkan proses seleksi literatur yang telah dijelaskan pada Bab 2, diperoleh 35 artikel yang memenuhi kriteria inklusi dan eksklusi. Artikel-artikel tersebut diterbitkan pada periode 2022–2026 dan menjadi korpus utama penelitian ini. Distribusi artikel berdasarkan tahun publikasi disajikan pada Tabel 2.

Tabel 2. Distribusi Artikel Berdasarkan Tahun Publikasi

Tahun	Jumlah Artikel
2022	4
2023	7
2024	10
2025	8
2026	6
Total	35

Berdasarkan Tabel 2, jumlah publikasi menunjukkan tren peningkatan dari tahun 2022 hingga mencapai puncaknya pada tahun 2024. Meskipun terjadi sedikit penurunan pada tahun 2025 dan 2026, jumlah publikasi tetap menunjukkan tingginya minat penelitian terhadap penerapan deep learning dalam klasifikasi limbah plastik.

Sebagian besar artikel berfokus pada pengembangan dan evaluasi model klasifikasi berbasis citra menggunakan berbagai arsitektur deep learning. Namun, hanya sebagian kecil penelitian yang secara khusus menguji performa model pada kondisi citra non-ideal, seperti pencahayaan rendah, kontaminasi objek, atau latar belakang yang kompleks. Temuan ini menunjukkan bahwa kajian mengenai ketahanan model pada kondisi lingkungan nyata masih relatif terbatas.

Secara umum, hasil analisis korpus menunjukkan bahwa klasifikasi limbah plastik berbasis deep learning merupakan topik yang terus berkembang dan masih memiliki peluang penelitian yang luas, terutama terkait pengujian model pada kondisi non-ideal.

3.2 Pemetaan Arsitektur Deep Learning yang Dominan

pemetaan terhadap arsitektur deep learning yang digunakan pada 35 artikel dalam korpus penelitian. Hasil pemetaan menunjukkan bahwa klasifikasi limbah plastik masih didominasi oleh keluarga Convolutional Neural Network (CNN) dan variannya, sedangkan YOLO banyak digunakan untuk deteksi objek secara real-time.

Tabel 3. Pemetaan Arsitektur Deep Learning pada Korpus Penelitian

Arsitektur	Frekuensi	Rentang Akurasi	Referensi/Penulis
CNN (umum/dasar)	14	83,18%-98,81%	(oska amanda et al., 2025; Stephen Pieters, 2025; Wang, 2024)
MobileNet (V2/V3)	9	81%-99,46%	(Gao et al., 2026; Tian et al., 2024; Zhao et al., 2022)
EfficientNet (B0/varian)	6	94,54%-97%	(Buyung et al., 2023; Feng et al., 2022; Islam et al., 2025)
YOLO (v3/v8/v11)	8	53,3%-98,03% mAP50	(Choi et al., 2023; Kunwar et al., 2024; Kurniawan Saputro et al., 2024)
ResNet (50/varian)	5	87,44%-99,80%	(Chazhoor et al., 2022; Mahale et al., 2025)
DenseNet (201/varian)	4	83,11%-99,80%	(Mahale et al., 2025; Sayem et al., 2025)
Vision Transformer/Hibrida	3	83,11-88,3%	(Mustapha et al., 2025; Sayem et al., 2025)

CNN merupakan arsitektur yang paling dominan dengan frekuensi kemunculan tertinggi. Temuan ini menunjukkan bahwa CNN masih menjadi pendekatan utama karena kemampuannya dalam mengekstraksi fitur visual secara efektif. Di antara berbagai variannya, MobileNet menjadi salah satu model yang paling banyak digunakan karena menawarkan keseimbangan antara akurasi dan efisiensi komputasi, sehingga sesuai untuk implementasi pada perangkat edge.

Selain CNN, EfficientNet, ResNet, dan DenseNet juga banyak dimanfaatkan melalui pendekatan transfer learning untuk meningkatkan performa klasifikasi. Sementara itu, keluarga YOLO mendominasi penelitian yang berfokus pada deteksi objek secara real-time karena mampu memberikan akurasi dan kecepatan inferensi yang baik. Namun, beberapa penelitian menunjukkan bahwa performa model dapat menurun ketika dihadapkan pada kondisi citra yang lebih kompleks, seperti objek transparan atau latar belakang yang tidak terkontrol.

Beberapa penelitian juga mulai mengeksplorasi arsitektur hibrida yang menggabungkan CNN dengan Transformer atau model deteksi objek. Meskipun jumlahnya masih terbatas, pendekatan ini menunjukkan potensi untuk meningkatkan kemampuan model dalam menangani variasi visual yang lebih kompleks.

Secara keseluruhan, hasil pemetaan menunjukkan bahwa CNN dan variannya masih menjadi arsitektur yang paling dominan dalam klasifikasi limbah plastik, sedangkan YOLO merupakan pilihan utama untuk deteksi objek secara real-time. Temuan ini menunjukkan bahwa pemilihan arsitektur masih menjadi faktor penting, namun efektivitasnya tetap dipengaruhi oleh karakteristik data dan kondisi pengujian yang digunakan.

3.3 Metode Augmentasi Data dan Pra-Pemrosesan

Analisis terhadap metode augmentasi data dan pra-pemrosesan yang digunakan dalam 35 artikel pada korpus penelitian. Hasil analisis menunjukkan bahwa metode yang digunakan dapat dikelompokkan menjadi lima kategori, yaitu augmentasi dasar, augmentasi lanjutan, augmentasi generatif berbasis Generative Adversarial Network (GAN), pra-pemrosesan citra, dan penyeimbangan kelas.

Tabel 4. Klasifikasi Metode Augmentasi dan Pra-Pemrosesan

Kategori	Teknik	Frekuensi	Dampak Terukur	Referensi/Penulis
Augmentasi Dasar	Rotasi, zoom, <i>flipping</i> , normalisasi	22	Peningkatan akurasi 2-5%	(Kunwar et al., 2024; Rahina et al., 2024)
Augmentasi Lanjutan	Injeksi <i>noise</i> sintetis, <i>cutout</i> , <i>mixup</i>	8	Peningkatan >20% pada citra berisik	(Terbe et al., 2024)
Augmentasi Generatif (GAN)	DCGAN, BigGAN, WasteGAN	4	Peningkatan 5,8% pada data terbatas	(Bacchin et al., 2024; Mahale et al., 2025)
Pra-Pemrosesan Citra	<i>Low-light enhancement</i> , CLAHE, <i>denoising</i>	6	Peningkatan 39,5% pada cahaya sangat rendah	(Gao et al., 2026; Zheng et al., 2024)
Penyeimbangan Kelas	<i>Oversampling</i> , <i>undersampling</i>	7	Mengurangi bias klasifikasi	(Chazhoor et al., 2022; Kunwar et al., 2024)

Berdasarkan Tabel 4, augmentasi dasar merupakan metode yang paling banyak digunakan. Teknik seperti rotasi, flipping, zooming, dan normalisasi diterapkan untuk meningkatkan variasi data pelatihan serta membantu model melakukan generalisasi dengan lebih baik. Meskipun peningkatan performanya relatif moderat, metode ini tetap menjadi pilihan utama karena mudah diterapkan dan tidak memerlukan biaya tambahan dalam pengumpulan data.

Beberapa penelitian juga menerapkan augmentasi lanjutan, seperti injeksi noise sintetis, cutout, dan mixup, untuk mensimulasikan kondisi lingkungan yang lebih kompleks. Hasil sintesis menunjukkan bahwa pendekatan ini lebih efektif dalam meningkatkan ketahanan model terhadap citra yang mengalami gangguan visual dibandingkan augmentasi dasar.

Pendekatan berbasis GAN digunakan untuk menghasilkan sampel sintetis yang menyerupai data asli, terutama pada kondisi jumlah data yang terbatas. Meskipun frekuensi penggunaannya masih relatif rendah, metode ini menunjukkan potensi dalam memperkaya variasi data dan mengurangi ketidakseimbangan kelas.

Selain augmentasi data, beberapa penelitian menerapkan tahap pra-pemrosesan citra, seperti low-light enhancement, CLAHE, dan denoising, untuk memperbaiki kualitas citra sebelum proses klasifikasi dilakukan. Teknik ini terbukti membantu meningkatkan performa model, terutama pada kondisi pencahayaan rendah dan citra yang terdegradasi. Sementara itu, metode oversampling dan undersampling digunakan untuk mengurangi bias akibat distribusi data yang tidak seimbang.

Secara keseluruhan, hasil sintesis menunjukkan bahwa augmentasi data dan pra-pemrosesan merupakan faktor penting dalam meningkatkan performa dan ketahanan model klasifikasi limbah plastik. Temuan ini mengindikasikan bahwa keberhasilan sistem tidak hanya ditentukan oleh arsitektur deep learning yang digunakan, tetapi juga oleh strategi pengolahan data yang diterapkan.

3.4 Penanganan Kondisi Citra Tidak Ideal

Salah satu fokus penelitian ini adalah mengidentifikasi bagaimana berbagai penelitian menangani kondisi citra non-ideal yang sering dijumpai pada lingkungan nyata. Berdasarkan hasil analisis, ditemukan empat kategori utama, yaitu pencahayaan rendah (low-light), latar

belakang kompleks, transparansi atau kemiripan material plastik, serta kontaminasi fisik pada permukaan objek.

Tabel 5. Kondisi Tidak Ideal dan Pendekatan Penanganannya

Kondisi Tidak Ideal	Jumlah Artikel	Pendekatan Utama	Akurasi Sebelum	Akurasi Sesudah
Cahaya rendah (<i>low-light</i>)	6	<i>Low-light enhancement</i> (Zero-DCE, EnlightenGAN), fusi multimodal	~60%	90,25%-99,46%
Latar belakang kompleks	5	Mekanisme atensi multi-skala (EMA), arsitektur deteksi P2	~70%	88,3%-93,3%
Transparansi & kemiripan material	4	Sensor fusion, pencitraan hiperspektral (HSI), YOLOv8	53,3%	91,7%-97%
Kontaminasi fisik (kotor)	3	Pencitraan hiperspektral, augmentasi GAN	~60%	97%-99%

Pencahayaan rendah merupakan tantangan yang paling banyak dibahas. Sebagian besar penelitian mengatasi masalah ini melalui teknik *low-light enhancement*, seperti Zero-DCE, EnlightenGAN, dan metode berbasis Transformer. Hasil yang dilaporkan menunjukkan bahwa peningkatan kualitas citra sebelum proses klasifikasi dapat meningkatkan performa model secara signifikan.

Latar belakang yang kompleks juga menjadi faktor yang sering menyebabkan penurunan akurasi. Untuk mengatasinya, beberapa penelitian menerapkan mekanisme atensi (*attention mechanism*) dan deteksi multiskala agar model lebih mampu membedakan objek plastik dari lingkungan sekitarnya. Pendekatan ini terbukti membantu meningkatkan ketahanan model terhadap variasi latar belakang. Tantangan lainnya adalah transparansi dan kemiripan antarjenis plastik yang sering menyebabkan kesalahan klasifikasi. Beberapa penelitian menunjukkan bahwa penggunaan sensor tambahan atau pendekatan multimodal dapat memberikan hasil yang lebih baik dibandingkan penggunaan citra RGB saja.

Sementara itu, kontaminasi fisik pada limbah plastik merupakan kondisi yang paling sedikit diteliti meskipun memiliki dampak yang besar terhadap performa model. Penelitian yang ada umumnya memanfaatkan pencitraan hiperspektral atau augmentasi berbasis GAN untuk meningkatkan kemampuan model dalam mengenali plastik yang terkontaminasi.

Secara keseluruhan, hasil sintesis menunjukkan bahwa tidak terdapat satu metode yang mampu mengatasi seluruh kondisi non-ideal secara optimal. Setiap pendekatan memiliki keunggulan pada permasalahan tertentu, sehingga pemilihan metode perlu disesuaikan dengan karakteristik lingkungan yang dihadapi. Selain itu, masih terbatasnya penelitian pada kondisi kontaminasi fisik menunjukkan adanya peluang penelitian lebih lanjut untuk mengembangkan sistem klasifikasi limbah plastik yang lebih robust pada lingkungan nyata.

3.5 Perbandingan Dataset yang Digunakan

Karakteristik dataset memiliki pengaruh penting terhadap performa model klasifikasi limbah plastik karena menentukan variasi objek dan kondisi citra yang digunakan selama pelatihan maupun pengujian.

Tabel 6. Dataset Utama yang Digunakan dalam Korpus

Dataset	Jenis	Kondisi Citra	Frekuensi Penggunaan
WaDaBa	Plastik (7 kategori RIC)	Terkendali, bersih	3 artikel

TrashNet	Sampah umum (6 kategori)	Terkendali, bersih	4 artikel
Waste Classification V2	Sampah organik/anorganik	Terkendali, bersih	2 artikel
HGCD	Sampah rumah tangga	Terkendali, bersih	1 artikel
Dataset buatan sendiri	Bervariasi	Sebagian kondisi nyata	18 artikel
ZeroWaste	Sampah industri	Latar belakang kompleks	2 artikel

Sebagian besar penelitian masih menggunakan dataset yang diperoleh pada kondisi yang relatif terkontrol, seperti WaDaBa, TrashNet, Waste Classification V2, dan HGCD. Dataset tersebut umumnya memiliki pencahayaan yang baik, latar belakang sederhana, dan objek yang terpisah dengan jelas sehingga belum sepenuhnya merepresentasikan kondisi lapangan.

Selain itu, custom dataset menjadi jenis dataset yang paling banyak digunakan, yaitu pada 18 dari 35 artikel. Meskipun memungkinkan penyesuaian terhadap kebutuhan penelitian, penggunaan dataset buatan sendiri sering kali menyulitkan reproduksi dan perbandingan hasil antar penelitian karena karakteristik datanya tidak seragam.

Dataset yang memuat kondisi lingkungan yang lebih kompleks, seperti ZeroWaste, masih digunakan secara terbatas. Akibatnya, sebagian besar model dievaluasi pada kondisi yang relatif ideal, sementara pengujian pada kondisi non-ideal, seperti pencahayaan rendah, kontaminasi, latar belakang kompleks, dan objek transparan, masih jarang dilakukan.

Temuan ini menunjukkan bahwa ketersediaan dataset benchmark yang merepresentasikan kondisi nyata masih menjadi tantangan dalam penelitian klasifikasi limbah plastik berbasis deep learning. Oleh karena itu, pengembangan dataset standar untuk kondisi non-ideal diperlukan agar evaluasi dan perbandingan performa model dapat dilakukan secara lebih objektif.

3.6 Identifikasi Kesenjangan Penelitian

Salah satu tujuan utama penelitian ini adalah mengidentifikasi kesenjangan penelitian (research gap) yang masih terdapat pada pengembangan sistem klasifikasi limbah plastik berbasis deep learning. Berdasarkan sintesis terhadap 35 artikel yang dianalisis, ditemukan beberapa isu yang masih belum banyak dieksplorasi dan berpotensi menjadi arah penelitian pada masa mendatang.

Kesenjangan pertama berkaitan dengan masih terbatasnya penelitian yang secara khusus mengevaluasi performa model pada limbah plastik yang terkontaminasi atau berada dalam kondisi lingkungan nyata. Hasil analisis pada Subbab 3.4 menunjukkan bahwa hanya sebagian kecil penelitian yang menguji model menggunakan citra plastik yang kotor, tertutup residu, atau mengalami degradasi visual akibat proses penggunaan dan pembuangan. Sebagian besar penelitian masih menggunakan citra yang relatif bersih dan diperoleh dalam lingkungan yang terkontrol. Kondisi ini menyebabkan tingginya akurasi yang dilaporkan belum tentu mencerminkan performa model ketika diterapkan pada sistem pemilahan limbah di lapangan.

Kesenjangan kedua adalah belum tersedianya dataset benchmark yang secara khusus dirancang untuk merepresentasikan berbagai kondisi citra non-ideal. Sebagaimana ditunjukkan pada Subbab 3.5, mayoritas penelitian masih menggunakan dataset dengan kondisi pencahayaan yang baik, latar belakang sederhana, dan objek yang telah dipisahkan secara jelas. Selain itu, penggunaan dataset buatan sendiri masih mendominasi korpus penelitian. Akibatnya, proses perbandingan performa antar model menjadi sulit dilakukan karena setiap penelitian menggunakan karakteristik data dan skenario pengujian yang berbeda. Temuan ini menunjukkan perlunya pengembangan dataset standar yang mencakup variasi pencahayaan,

tingkat kontaminasi, latar belakang kompleks, transparansi material, serta berbagai bentuk degradasi citra yang umum ditemukan pada lingkungan nyata.

Kesenjangan ketiga berkaitan dengan masih terbatasnya integrasi antara teknik peningkatan kualitas citra dan sistem klasifikasi limbah plastik. Hasil analisis pada Subbab 3.3 dan 3.4 menunjukkan bahwa metode low-light enhancement, denoising, dan teknik perbaikan citra lainnya mampu meningkatkan performa model secara signifikan pada kondisi tertentu. Namun, sebagian besar penelitian peningkatan kualitas citra masih berkembang secara terpisah dari penelitian klasifikasi limbah plastik. Integrasi kedua pendekatan tersebut dalam satu pipeline yang terpadu masih relatif jarang ditemukan, padahal berpotensi meningkatkan ketahanan model terhadap berbagai kondisi non-ideal.

Kesenjangan keempat berkaitan dengan keterbatasan penelitian mengenai model ringan (lightweight models) pada lingkungan operasional nyata. Hasil pemetaan arsitektur pada Subbab 3.2 menunjukkan bahwa beberapa model dengan performa terbaik umumnya memiliki kompleksitas komputasi yang tinggi. Di sisi lain, model yang lebih ringan seperti MobileNet menawarkan efisiensi yang lebih baik untuk implementasi pada perangkat edge dan sistem tertanam. Meskipun demikian, kajian mengenai ketahanan model ringan terhadap kondisi pencahayaan rendah, kontaminasi fisik, maupun latar belakang kompleks masih relatif terbatas. Padahal karakteristik tersebut sangat penting untuk mendukung implementasi sistem klasifikasi limbah plastik secara langsung di lapangan.

Berdasarkan keempat kesenjangan tersebut, penelitian selanjutnya dapat diarahkan pada pengembangan dataset benchmark kondisi non-ideal, integrasi teknik peningkatan kualitas citra dengan model klasifikasi, serta evaluasi model ringan pada berbagai skenario lingkungan nyata. Upaya tersebut diharapkan dapat menghasilkan sistem klasifikasi limbah plastik yang tidak hanya memiliki akurasi tinggi pada lingkungan laboratorium, tetapi juga mampu mempertahankan performanya ketika diterapkan pada kondisi operasional yang sesungguhnya.

4 KESIMPULAN

Berdasarkan hasil Systematic Literature Review terhadap 35 artikel ilmiah, dapat disimpulkan bahwa Convolutional Neural Network (CNN) beserta variannya merupakan arsitektur deep learning yang paling dominan digunakan dalam klasifikasi limbah plastik, sedangkan YOLO menjadi pendekatan utama untuk deteksi objek secara real-time. Selain pemilihan arsitektur, penggunaan augmentasi data dan teknik pra-pemrosesan terbukti berperan penting dalam meningkatkan kemampuan model untuk menghadapi variasi kondisi citra. Teknik augmentasi lanjutan, metode berbasis Generative Adversarial Network (GAN), serta low-light enhancement menunjukkan potensi yang baik dalam meningkatkan ketahanan model pada kondisi non-ideal.

Hasil kajian juga menunjukkan bahwa sebagian besar penelitian masih menggunakan dataset dan skenario pengujian yang relatif terkontrol, sehingga kemampuan model pada kondisi nyata, seperti pencahayaan rendah, kontaminasi permukaan, latar belakang kompleks, dan degradasi kualitas citra, masih belum banyak dievaluasi. Selain itu, belum tersedianya dataset benchmark standar untuk kondisi non-ideal menjadi kendala dalam membandingkan performa antar model secara objektif. Oleh karena itu, penelitian selanjutnya disarankan untuk mengembangkan dataset yang lebih representatif terhadap kondisi lapangan, mengintegrasikan teknik peningkatan kualitas citra dengan sistem klasifikasi, serta mengevaluasi model ringan pada perangkat edge guna mendukung implementasi sistem klasifikasi limbah plastik yang lebih robust dan aplikatif.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada dosen pembimbing serta seluruh pihak yang telah memberikan arahan, masukan, dan dukungan selama proses penyusunan penelitian ini.

Ucapan terima kasih juga disampaikan kepada berbagai penyedia basis data ilmiah yang menjadi sumber literatur dalam penelitian ini sehingga kajian dapat dilaksanakan dengan baik.

DAFTAR PUSTAKA

- Bacchin, A., Barcellona, L., Terreran, M., Ghidoni, S., Menegatti, E., & Kiyokawa, T. (2024). WasteGAN: Data Augmentation for Robotic Waste Sorting through Generative Adversarial Networks. <https://doi.org/10.1109/IROS58592.2024.10802403>
- Buyung, I., Qomaruddin Munir, A., Wijaya, N. S., Listyalina, L., Pengolahan Karet dan Plastik, T., & ATK Yogyakarta, P. (2023). Identifying Types of Waste as Efforts in Plastic Waste Management Based on Deep Learning. *Jurnal Informatika Dan Teknologi Informasi*, 20(3), 362–372. <https://doi.org/10.31515/telematika.v20i3.10804>
- Chazhoor, A. A. P., Ho, E. S. L., Gao, B., & Woo, W. L. (2022). Deep transfer learning benchmark for plastic waste classification. *Intelligence and Robotics*, 2(1), 1–19. <https://doi.org/10.20517/ir.2021.15>
- Choi, J., Lim, B., & Yoo, Y. (2023). Advancing Plastic Waste Classification and Recycling Efficiency: Integrating Image Sensors and Deep Learning Algorithms. *Applied Sciences (Switzerland)*, 13(18). <https://doi.org/10.3390/app131810224>
- Feng, Z., Yang, J., Chen, L., Chen, Z., & Li, L. (2022). An Intelligent Waste-Sorting and Recycling Device Based on Improved EfficientNet. *International Journal of Environmental Research and Public Health*, 19(23). <https://doi.org/10.3390/ijerph192315987>
- Gao, D. M., Song, J. Q., Fu, Z. Q., Liu, Z., & Li, G. (2026). Utilizing Multimodal Logic Fusion to Identify the Types of Food Waste Sources. *Sensors*, 26(3). <https://doi.org/10.3390/s26030851>
- Islam, Md. M., Hasan, S. M. M., Hossain, Md. R., Uddin, Md. P., & Mamun, Md. Al. (2025). Towards sustainable solutions: Effective waste classification framework via enhanced deep convolutional neural networks. *PLoS ONE*, 20(6). <https://doi.org/10.1371/journal.pone.0324294>
- Kunwar, S., Owabumoye, B. R., & Alade, A. S. (2024). Plastic Waste Classification Using Deep Learning: *Insights from the WaDaBa Dataset*.
- Kurniawan Saputro, A., Ulum, M., Syahnurrokhim Khabibiy, O., Fiqi Ibadillah, A., Alfita, R., Hardiwansyah, M., Raya Telang, J., Telang Inda, P., Kamal, K., & Timur, J. (2024). Identification Types of Plastic Waste Based On The Yolo Method. <https://doi.org/10.33086/atcsj.v7i1.6219>
- Mahale, Y., Khan, N., Kulkarni, K., Gite, S., Pradhan, B., Alamri, A., Lee, C.-W., K., N., & Bachute, M. (2025). A comprehensive approach for waste management with GAN-augmented classification. *PeerJ Computer Science*, 11, e3156. <https://doi.org/10.7717/peerj-cs.3156>
- Mustapha, A. A., Saruchi, S., Atifah, Supriyono, H., & Solihin, M. I. (2025). A Hybrid Deep Learning Model for Waste Detection and Classification Utilizing YOLOv8 and CNN †. *Engineering Proceedings*, 84(1). <https://doi.org/10.3390/engproc2025084082>
- OECD. (2022). *Global Plastics Outlook*. OECD Publishing. <https://doi.org/10.1787/de747aef-en>
- oska amanda, R., Pradana Nst, E., Bardi, J., & Rukmana Manday, D. (2025). Implementasi Dan Deteksi Tong Sampah Pintar Menggunakan Esp8266 dengan Algoritma CNN. 9, 2025. <https://doi.org/10.47002/metik.v9i2.1083>

- Rahina, M., Pambayun, B., & Azhar, Y. (2024). Implementasi Data Augmentation untuk Klasifikasi Sampah Organik dan Non Organik Menggunakan Inception-V3. In *Jurnal Informatika Sunan Kalijaga* (Vol. 9, Number 3).
- Ramos, E., Lopes, A. G., & Mendonça, F. (2024). Application of Machine Learning in Plastic Waste Detection and Classification: A Systematic Review. In *Processes* 12(8). Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/pr12081632>
- Sarker, I. H. (2021). Deep Learning: A Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions. In *SN Computer Science* 2(6). Springer. <https://doi.org/10.1007/s42979-021-00815-1>
- Sayem, F. R., Islam, M. S. Bin, Naznine, M., Nashbat, M., Hasan-Zia, M., Kunju, A. K. A., Khandakar, A., Ashraf, A., Majid, M. E., Kashem, S. B. A., & Chowdhury, M. E. H. (2025). Enhancing waste sorting and recycling efficiency: robust deep learning-based approach for classification and detection. *Neural Computing and Applications*, 37(6), 4567–4583. <https://doi.org/10.1007/s00521-024-10855-2>
- Stephen Pieters, L. (2025). *Development Of Automatic Waste Classification System Using Cnn Based Deep Learning To Support Smart Waste Management*. 10(1), 2025.
- Taneepanichskul, N., Hailes, H. C., & Miodownik, M. (2025). Using hyperspectral imaging and machine learning to identify food-contaminated compostable and recyclable plastics. *UCL Open Environment*, 7. <https://doi.org/10.14324/111.444/ucloe.3237>
- Terbe, D., Orzó, L., Bicsák, B., & Zarándy, Á. (2024). Hologram Noise Model for Data Augmentation and Deep Learning. *Sensors*, 24(3). <https://doi.org/10.3390/s24030948>
- Tian, X., Shi, L., Luo, Y., & Zhang, X. (2024). Garbage Classification Algorithm Based on Improved MobileNetV3. *IEEE Access*, 12, 44799–44807. <https://doi.org/10.1109/ACCESS.2024.3381533>
- Wang, J. (2024). Application research of image classification algorithm based on deep learning in household garbage sorting. *Heliyon*, 10(9). <https://doi.org/10.1016/j.heliyon.2024.e29966>
- Zhao, Y., Huang, H., Li, Z., Yiwang, H., & Lu, M. (2022). Intelligent garbage classification system based on improve MobileNetV3-Large. *Connection Science*, 34(1), 1299–1321. <https://doi.org/10.1080/09540091.2022.2067127>
- Zheng, S., Ma, Y., Pan, J., Lu, C., & Gupta, G. (2024). *Low-Light Image and Video Enhancement: A Comprehensive Survey and Beyond*. <http://arxiv.org/abs/2212.10772>