

Turnitin LLCC

Kevin Risky Abadi

 SI-02

Document Details

Submission ID

trn:oid::2945:393804733

Submission Date

Jun 17, 2026, 9:10 AM GMT+7

Download Date

Jun 17, 2026, 9:11 AM GMT+7

File Name

Kevin Risky Abadi.pdf

File Size

2.2 MB

54 Pages

10,037 Words

65,391 Characters

10% Overall Similarity

The combined total of all matches, including overlapping sources, for each database.

Filtered from the Report

- Bibliography

Top Sources

- 9%  Internet sources
- 7%  Publications
- 0%  Submitted works (Student Papers)

Integrity Flags

0 Integrity Flags for Review

Our system's algorithms look deeply at a document for any inconsistencies that would set it apart from a normal submission. If we notice something strange, we flag it for you to review.

A Flag is not necessarily an indicator of a problem. However, we'd recommend you focus your attention there for further review.

Top Sources

9% Internet sources
7% Publications
0% Submitted works (Student Papers)

Top Sources

The sources with the highest number of matches within the submission. Overlapping sources will not be displayed.

1	Internet	ejournal.unhasy.ac.id	<1%
2	Internet	ejurnal.methodist.ac.id	<1%
3	Internet	kc.umn.ac.id	<1%
4	Publication	Eko Fuji Pangestu -, Bambang Irawan -. "KLASIFIKASI PENYAKIT TANAMAN PADI ...	<1%
5	Internet	dspace.uil.ac.id	<1%
6	Publication	Riko Angga Bayu Kusuma -, Bambang Irawan -, Abdul Khamid -. "KLASIFIKASI PEN...	<1%
7	Internet	ejurnal.seminar-id.com	<1%
8	Internet	repository.machung.ac.id	<1%
9	Internet	text-id.123dok.com	<1%
10	Internet	www.mdpi.com	<1%
11	Internet	repository.unissula.ac.id	<1%

12	Internet	repository.upstegal.ac.id	<1%
13	Internet	core.ac.uk	<1%
14	Internet	eprints.pktj.ac.id	<1%
15	Internet	jurnal.wicida.ac.id	<1%
16	Internet	ejournal.publine.or.id	<1%
17	Internet	eprints.walisongo.ac.id	<1%
18	Internet	ipm2kpe.or.id	<1%
19	Internet	repositori.unsil.ac.id	<1%
20	Internet	edas.info	<1%
21	Internet	repository.uisu.ac.id	<1%
22	Internet	rua.ua.es	<1%
23	Publication	Syamsul Mujahidin, Muhammad Insan Kamil, Riska Kurniyanto Abdullah. "Penge...	<1%
24	Publication	Aisy, Nasywa Rihadatul. "Manajemen Wisata Alam Dalam Peningkatan Ekonomi P...	<1%
25	Internet	repository.umsu.ac.id	<1%

26	Internet	docplayer.info	<1%
27	Publication	Adnan Buyung Nasution, Ahir Yugo Nugroho Hrp, Muhammad Fauzi, Wirhan Fahr...	<1%
28	Publication	Gina Annisa, Ninuk Wiliani. "Perbandingan Model CNN dan SVM untuk Klasifikasi...	<1%
29	Internet	biodatamining.biomedcentral.com	<1%
30	Internet	e-jurnal.pnl.ac.id	<1%
31	Internet	openlibrarypublications.telkomuniversity.ac.id	<1%
32	Internet	repository.ulb.ac.id	<1%
33	Publication	Ainunnisa Indah Rizqya, Nanda Martyan Anggadimas, Muhammad Misdram. "Ski...	<1%
34	Internet	ejournal.poltekbangsby.ac.id	<1%
35	Internet	journal.darmajaya.ac.id	<1%
36	Internet	journal.uinjkt.ac.id	<1%
37	Internet	sitasi.upnjatim.ac.id	<1%
38	Internet	e-journal.uajy.ac.id	<1%
39	Internet	jurnal.buddhidharma.ac.id	<1%

40	Internet	pustakagalerimandiri.co.id	<1%
41	Internet	repository.metrouniv.ac.id	<1%
42	Internet	tunasbangsa.ac.id	<1%
43	Internet	www.docstoc.com	<1%
44	Internet	www.sciencegate.app	<1%
45	Internet	digilibadmin.unismuh.ac.id	<1%
46	Internet	mafiadoc.com	<1%
47	Internet	repository.unmul.ac.id	<1%
48	Publication	Adinda Purnamasari, Rini Astuti, Khaerul Anam, Gifthera Dwilestari, Mulyawan. ...	<1%
49	Publication	Muhamad Dio Riza Pratama Dio, Bayu Priyatna Bayu Priyatna, April Lia Hananto ...	<1%
50	Publication	Rizqy Supriyadi, Muhamad Irfan, Rizki Dwi Hapijar, Fadil Abubakar et al. "PENGE...	<1%
51	Publication	Virginia Khoirunnisa, Sri Lestari. "IMPLEMENTASI KLASIFIKASI KEHAMILAN BERES...	<1%
52	Internet	ojs.uma.ac.id	<1%
53	Internet	repository.ubpkarawang.ac.id	<1%

54	Internet	repository.umb.ac.id	<1%
55	Publication	Ervian Akbarsyah Mahendra, A.A.B. Dinariyana DP, Dyah Santhi Dewi. "PERANCA...	<1%
56	Publication	Hadaya Abhista Reswara, Bayu Priyatna, Agustia Hananto, Tukino Tukino. "Imple...	<1%
57	Internet	doku.pub	<1%
58	Internet	ejurnal.unim.ac.id	<1%
59	Internet	journals.istic.ac.cn	<1%
60	Internet	jurnal.uisu.ac.id	<1%
61	Internet	repository.unpkediri.ac.id	<1%
62	Internet	sedici.unlp.edu.ar	<1%
63	Internet	senatik.stta.ac.id	<1%
64	Publication	Anita Desiani, Lucky Indra Kesuma, Diana Dewi Sartika, Azmi Muhammad Padhil ...	<1%
65	Publication	Muhammad Adrezo, Muhamad Erlan Ardiansyah. "Deteksi Jenis Kelamin Berdasa...	<1%
66	Publication	Maulana Ichsan Ichsan. "IMPLEMENTASI MACHINE LEARNING UNTUK DETEKSI PE...	<1%
67	Publication	Tri Ahmad Jabar JABAR, Rudi Heriansyah, Evi Purnamasari. "Pengenalan Pola Hur...	<1%

24

BAB I

PENDAHULUAN

A. Latar Belakang

24

Aktivitas pendakian gunung di Indonesia mengalami peningkatan minat yang signifikan dalam beberapa tahun terakhir, baik sebagai sarana rekreasi maupun olahraga prestasi. Peningkatan ini berdampak langsung pada kepadatan jalur pendakian, terutama pada periode akhir pekan dan hari libur nasional. Di wilayah Jawa Timur, fenomena lonjakan pendaki dilaporkan dapat mencapai ratusan hingga ribuan orang dalam satu periode tertentu, yang menciptakan kondisi aktivitas yang sangat padat dan dinamis di area taman nasional maupun hutan lindung (Fatimah Ibnu Fiqri, 2025). Kondisi kepadatan ini menyebabkan setiap pendaki membawa beragam jenis logistik dalam volume yang besar, mulai dari bahan makanan kemasan, minuman botol, hingga perlengkapan konsumsi lainnya yang perlu dipersiapkan secara matang guna menjamin keselamatan selama aktivitas di alam bebas.

8

Permasalahan muncul ketika proses pengecekan logistik saat ini masih didominasi oleh metode manual, baik oleh pendaki itu sendiri maupun petugas pada pos perizinan. Karakteristik logistik pendaki yang memiliki variasi bentuk, ukuran, serta kemasan yang sangat beragam menciptakan tantangan tersendiri. Terlebih lagi, barang-barang tersebut sering kali ditempatkan dalam kondisi menumpuk (*clutter*) atau disimpan dalam area terbatas secara bersamaan. Situasi ini menyebabkan inspeksi visual menjadi tidak efisien, memakan waktu lama, dan rentan terhadap kesalahan manusia (*human error*) dalam mengidentifikasi kelengkapan jumlah barang.

39

2

Perkembangan teknologi kecerdasan buatan, khususnya pada bidang *computer vision*, menawarkan solusi otomatisasi yang efektif untuk mengatasi hambatan tersebut. Teknologi ini memungkinkan sistem untuk mengenali dan mengklasifikasikan objek berdasarkan citra visual dengan tingkat presisi yang menyerupai kemampuan manusia. Penggunaan algoritma *Deep Learning* telah terbukti sukses diimplementasikan pada berbagai domain, mulai dari identifikasi

50 produk ritel hingga sistem pemilahan sampah otomatis. Integrasi teknologi ini pada domain logistik pendakian berpotensi besar untuk mempercepat proses pengecekan barang dalam kondisi padat sekalipun. Dalam ranah deteksi objek, arsitektur *You Only Look Once* (YOLO) menjadi standar unggulan karena mampu menyeimbangkan kecepatan inferensi dengan akurasi yang tinggi secara *real-time*. YOLOv8, sebagai salah satu iterasi terbaru, memperkenalkan pembaruan pada modul arsitektur dan *loss function* yang secara signifikan meningkatkan performa deteksi, terutama untuk mengenali objek-objek kecil yang sering terabaikan oleh algoritma sebelumnya. Keunggulan ini membuat YOLOv8 sangat relevan untuk mendeteksi logistik pendaki yang sering kali terdiri dari komponen berdimensi kecil dan tipis.

Meskipun memiliki performa yang handal, efektivitas YOLOv8 pada skenario multi-objek dengan kepadatan tinggi masih menjadi tantangan terbuka dalam riset terkini. Penelitian yang dilakukan oleh Visen & Charibaldi mengungkapkan adanya keterbatasan pada model YOLOv8 nano, di mana akurasi klasifikasi mulai mengalami penurunan yang signifikan ketika jumlah objek di dalam satu citra melebihi sepuluh buah (Visen & Charibaldi, 2025). Hal ini disebabkan oleh meningkatnya kompleksitas citra dan munculnya tumpang tindih (*overlap*) antar objek yang mengaburkan ekstraksi fitur visual oleh model. Kesulitan deteksi semakin meningkat pada objek yang saling menutupi (*occlusion*) atau berada pada latar belakang yang tidak beraturan (*complex background*). Pada skenario logistik pendaki, objek kecil seperti batang rokok sering kali tidak teridentifikasi (*false negative*) akibat tertutup oleh kemasan produk yang lebih besar atau karena fitur visualnya yang minim. Hingga saat ini, belum banyak literatur yang secara khusus mengevaluasi batasan kemampuan YOLOv8 pada *dataset* logistik pendaki yang dirancang dengan tingkat kepadatan visual bertingkat. Sebagian besar studi sebelumnya masih terbatas pada objek ritel standar atau pengelolaan sampah dengan jumlah objek yang lebih terkontrol.

Berdasarkan kesenjangan penelitian (*research gap*) tersebut, penelitian ini dilakukan untuk mengevaluasi secara mendalam performa YOLOv8 nano dalam menangani deteksi multi-objek logistik dalam jumlah masif. Kebaruan dari

penelitian ini terletak pada penggunaan strategi dataset yang disusun berdasarkan lima level kepadatan visual (*clutter levels*), mulai dari kondisi tunggal (*single*) hingga kondisi sangat padat (*extreme clutter*). Evaluasi dilakukan dengan menganalisis metrik *precision*, *recall*, *F1-Score*, dan *mean Average Precision* (mAP) untuk memetakan stabilitas model saat menghadapi tumpang tindih objek. Selain itu, penelitian ini juga mengkaji kelayakan operasional sistem melalui pengujian waktu inferensi lintas perangkat (laptop dan telepon seluler) pada lingkungan implementasi berbasis aplikasi web (*Web App*). Dengan demikian, penelitian ini diharapkan dapat memberikan kontribusi ilmiah mengenai batas kemampuan YOLOv8 serta memberikan rekomendasi teknis untuk pengembangan sistem pelaporan logistik pendaki yang inklusif, responsif, dan praktis di lapangan.

B. Batasan Masalah

Agar penelitian ini lebih terarah dan tidak meluas dari tujuan yang telah ditetapkan, maka ruang lingkup dan batasan dalam penelitian ini adalah sebagai berikut:

1. Penelitian ini berfokus pada evaluasi kinerja model *object detection* berbasis *deep learning* menggunakan algoritma YOLOv8 versi nano (YOLOv8n) dalam mendeteksi multi-objek pada citra digital.
2. Objek yang digunakan dalam penelitian ini dibatasi pada lima jenis logistik pendaki yang merepresentasikan barang konsumsi harian, yaitu Botol, Kopi, Mie, Rokok (khusus jenis batangan), dan Roti.
3. *Dataset* yang digunakan merupakan *dataset* kustom (*custom dataset*) yang dikumpulkan secara mandiri oleh peneliti, dengan pembagian data uji yang didasarkan pada tingkat kepadatan visual (*clutter level*).
4. Variasi tingkat kepadatan objek dalam dataset uji dibagi menjadi lima kategori utama, yaitu *Single* (1 objek), *Low Multi* (2–5 objek), *Medium Clutter* (6–10 objek), *High Dense* (11–17 objek), dan *Extreme Clutter* (18 objek).
5. Proses pelatihan model dibatasi menggunakan parameter teknis tetap, yaitu sebanyak 50 *epoch* dan resolusi input citra sebesar 640x640 piksel untuk

menjaga konsistensi perbandingan dengan penelitian terdahulu, serta secara spesifik menerapkan metode prapemrosesan *Stretch to* pada dataset.

6. Penelitian ini ditekankan pada analisis performa model terhadap variasi jumlah objek dan tingkat kepadatan dalam satu citra, tanpa melakukan modifikasi pada arsitektur dasar atau optimasi algoritma YOLOv8.
7. Evaluasi kinerja model dilakukan menggunakan metrik standar deteksi objek yang meliputi *Precision*, *Recall*, *F1-Score*, mAP50, mAP50-95, serta pengukuran waktu inferensi (*inference time*) untuk mengukur kelayakan deteksi secara menyeluruh.
8. Implementasi sistem pada penelitian ini dibatasi pada bentuk purwarupa (*prototype*) aplikasi berbasis web (*Web App*) menggunakan framework Streamlit untuk keperluan pengujian portabilitas dan waktu inferensi lintas perangkat (komputer dan *smartphone*), serta tidak mencakup pengembangan aplikasi seluler secara native maupun integrasi backend yang kompleks.

C. Rumusan Masalah

Berdasarkan latar belakang yang telah diuraikan, maka rumusan masalah dalam penelitian ini adalah sebagai berikut:

1. Seberapa besar nilai *Precision*, *Recall*, *F1-Score*, dan *mean Average Precision* (mAP) yang dihasilkan oleh arsitektur YOLOv8n dalam mendeteksi multi-objek pada *dataset* logistik pendaki?
2. Seberapa besar pengaruh variasi jumlah objek dalam satu citra terhadap perubahan nilai akurasi mAP pada model YOLOv8n?
3. Seberapa besar tingkat penurunan (degradasi) performa model YOLOv8n saat menghadapi kondisi kompleksitas citra seperti objek yang saling tumpang tindih (*overlap*) dan objek berukuran kecil (*small objects*)?
4. Seberapa besar perbedaan signifikansi performa deteksi model YOLOv8n pada setiap tingkatan kepadatan visual (*clutter level*) mulai dari level *Single* hingga *Extreme Clutter*?

D. Tujuan Penelitian

Berdasarkan rumusan masalah yang telah ditetapkan, maka tujuan dari penelitian ini adalah sebagai berikut:

1. Menganalisis besaran nilai *Precision*, *Recall*, *F1-Score*, dan *mean Average Precision* (mAP) yang dihasilkan oleh arsitektur YOLOv8n dalam mendeteksi multi-objek pada dataset logistik pendaki.
2. Menganalisis pengaruh variasi jumlah objek dalam satu citra terhadap perubahan nilai akurasi mAP pada model YOLOv8n.
3. Mengukur tingkat penurunan (degradasi) performa model YOLOv8n saat menghadapi kondisi kompleksitas citra seperti objek yang saling tumpang tindih (*overlap*) dan objek berukuran kecil (*small objects*).
4. Mengevaluasi perbedaan performa deteksi model YOLOv8n pada setiap tingkatan kepadatan visual (*clutter level*) mulai dari level *Single* hingga *Extreme Clutter*.

E. Manfaat Penelitian

Penelitian ini diharapkan dapat memberikan manfaat baik secara teoritis maupun praktis, sebagai berikut:

1. Manfaat teoritis

Penelitian ini diharapkan dapat memberikan kontribusi ilmiah yang signifikan dalam bidang kecerdasan buatan (*Artificial Intelligence*) dan visi komputer (*computer vision*), khususnya mengenai evaluasi performa arsitektur YOLOv8 nano dalam menangani deteksi multi-objek pada satu bidang pandang. Hasil penelitian ini diproyeksikan mampu memperkaya kajian akademis mengenai batas kemampuan model deteksi objek dalam memproses citra dengan tingkat kepadatan visual ekstrem (*extreme clutter*) serta kondisi objek yang saling tumpang tindih (*overlap*).

Selain itu, penelitian ini memberikan pemahaman mendalam mengenai korelasi antara jumlah objek dalam satu citra terhadap fluktuasi metrik akurasi seperti *Precision*, *Recall*, *F1-Score*, mAP50, dan mAP50-95 sebagai standar pengukuran performa model *deep learning*. Secara teoritis, temuan ini juga dapat menjadi landasan atau referensi bagi peneliti selanjutnya yang berfokus pada

pengembangan metodologi deteksi objek berukuran kecil (*small objects*) atau skenario lingkungan yang tidak terkontrol.

2. Manfaat praktis

Secara praktis, penelitian ini memberikan solusi inovatif berupa purwarupa (*prototype*) sistem deteksi logistik berbasis aplikasi web (*Web App*) yang dapat diakses secara lintas perangkat (komputer maupun *smartphone*). Sistem ini secara langsung bermanfaat bagi para pendaki dan petugas posko pendakian dalam mengotomatisasi proses pengecekan barang bawaan, sehingga inspeksi menjadi lebih cepat, efisien, dan meminimalisir kesalahan manusia (*human error*).

Selain itu, penelitian ini diharapkan dapat menjadi acuan bagi pengembang sistem cerdas dalam memilih model deteksi yang tangguh untuk kasus penggunaan dengan kompleksitas tinggi (seperti *overlapping* objek, variasi pencahayaan, dan latar belakang beragam). Dataset logistik pendaki dengan pembagian kelas kepadatan visual (*clutter levels*) yang disusun dalam penelitian ini juga dapat dijadikan referensi awal (kumpulan data dasar) untuk pengembangan sistem serupa di masa mendatang.

BAB II

KAJIAN PUSTAKA

A. Kajian Teori

1. Kecerdasan Buatan dan *Machine Learning*

Kecerdasan Buatan atau *Artificial Intelligence* (AI) merupakan bidang ilmu komputer yang bertujuan untuk mengembangkan sistem agar mampu meniru kemampuan kognitif manusia dalam menyelesaikan tugas-tugas kompleks. Sebagai salah satu cabang utama dalam AI, *Machine Learning* memberikan kemampuan pada komputer untuk mempelajari pola secara mandiri dari sekumpulan data tanpa perlu diprogram secara eksplisit.

Implementasi *Machine Learning* saat ini memiliki peran strategis sebagai instrumen untuk meningkatkan akurasi prediksi serta efisiensi analisis data guna mendukung proses pengambilan keputusan (Daniati et al., 2024). Melalui pendekatan tersebut, dukungan keputusan berbasis sistem cerdas dapat mentransformasi proses konvensional yang bersifat manual menjadi sistem otomatis yang lebih terukur (Daniati et al., 2024). Landasan teoretis ini mendasari penelitian dalam menerapkan teknologi deteksi objek untuk mengatasi kendala pada pencatatan logistik secara manual. Sebagai bentuk evolusi dari *Machine Learning* yang lebih lanjut, teknologi *Deep Learning* kemudian digunakan untuk menangani pengenalan pola pada data citra yang memiliki tingkat kompleksitas tinggi.

2. *Deep Learning*

Deep learning merupakan subbidang dari *machine learning* yang memanfaatkan jaringan saraf tiruan berlapis banyak untuk mempelajari representasi data secara hierarkis (Schmidhuber, 2015). Algoritma ini memiliki keunggulan utama dalam hal skalabilitas karena performa model akan terus meningkat secara signifikan seiring dengan bertambahnya volume data atau *big data* (Najafabadi et al., 2015). Karakteristik tersebut memungkinkan sistem untuk

mengeksktraksi fitur secara otomatis melalui proses *feature extraction* tanpa memerlukan rekayasa manual pada data kompleks seperti citra digital.

Implementasi *deep learning* banyak menggunakan arsitektur *Convolutional Neural Network* (CNN) yang dirancang khusus untuk pengolahan citra digital. Arsitektur CNN mampu mengenali berbagai pola visual seperti bentuk, tekstur, dan warna secara efektif. Selain itu, model ini memiliki kemampuan tinggi dalam mendeteksi banyak objek dalam satu citra dengan berbagai variasi skala maupun posisi.

Oleh karena itu, *deep learning* menjadi pendekatan utama dalam penelitian deteksi objek untuk mengevaluasi kemampuan model pada kondisi citra yang kompleks. Hal tersebut mencakup pengenalan multi-objek dengan kondisi tumpang tindih (*overlapping*) serta variasi latar belakang yang beragam.

3. *Computer Vision*

Computer vision merupakan cabang dari kecerdasan buatan yang berfokus pada kemampuan sistem komputer untuk memperoleh, memproses, dan memahami informasi visual dari citra atau video digital (Sinha et al., 2023). Tujuan utama dari *computer vision* adalah mengekstraksi informasi bermakna dari data visual untuk mendukung proses pengambilan keputusan secara otomatis.

Dalam perkembangannya, *computer vision* telah banyak diterapkan pada berbagai bidang, seperti sistem keamanan, pengenalan wajah, pertanian, serta pengelolaan sampah berbasis citra. Teknologi ini memanfaatkan teknik *machine learning* dan *deep learning* untuk meningkatkan akurasi dalam mengenali objek.

Salah satu implementasi penting dari *computer vision* adalah *object detection*, yaitu proses untuk mendeteksi keberadaan objek sekaligus menentukan lokasi dan klasifikasi objek dalam citra. Pada kondisi tertentu, satu citra dapat mengandung banyak objek dengan variasi posisi, ukuran, dan tingkat kepadatan yang berbeda, sehingga meningkatkan kompleksitas dalam proses deteksi.

23 Dalam penelitian ini, *computer vision* digunakan sebagai pendekatan utama untuk mengevaluasi kemampuan model dalam mendeteksi multi-objek pada citra logistik pendaki dengan tingkat kompleksitas yang beragam.

4. *Object detection*

31 *Object detection* merupakan salah satu tugas utama dalam *computer vision* yang bertujuan untuk mengidentifikasi keberadaan objek, menentukan lokasi objek dalam bentuk *bounding box*, serta mengklasifikasikan objek ke dalam kategori tertentu pada citra atau video (Zou et al., 2023). Berbeda dengan klasifikasi citra, *object detection* menggabungkan proses klasifikasi dan lokalisasi objek secara bersamaan.

5 Metode deteksi objek secara umum dibagi menjadi dua kategori, yaitu 1 *two-stage detector* dan *one-stage detector*. *Two-stage detector* seperti *Faster R-CNN* memiliki akurasi yang tinggi namun relatif lebih lambat, sedangkan *one-stage detector* seperti YOLO memiliki keunggulan dalam kecepatan sehingga lebih cocok untuk aplikasi *real-time* (Redmon et al., 2016).

Dalam praktiknya, *object detection* sering dihadapkan pada kondisi di mana satu citra mengandung banyak objek dengan variasi ukuran, posisi, dan tingkat kepadatan yang berbeda. Kondisi ini dapat menyebabkan terjadinya *overlapping* antar objek serta meningkatkan kompleksitas dalam proses deteksi, sehingga berpotensi menurunkan performa model.

42 Evaluasi kinerja model *object detection* umumnya menggunakan metrik seperti *Intersection over Union* (IoU), *precision*, *recall*, dan *mean Average Precision* (mAP) (Everingham et al., 2009). Dalam penelitian ini, pendekatan *object detection* digunakan untuk mengevaluasi kemampuan model dalam mendeteksi multi-objek pada citra logistik pendaki dengan tingkat kompleksitas yang beragam.

2 5. *Convolutional Neural Network* (CNN)

Convolutional Neural Network (CNN) merupakan salah satu arsitektur *deep learning* yang dirancang khusus untuk mengolah data berupa citra digital. Sebagai

cabang dari teknologi kecerdasan buatan, CNN memiliki kemampuan untuk mengenali objek atau gambar dengan cara meniru mekanisme persepsi visual pada makhluk hidup (Adriyanto et al., 2022). Secara teknis, CNN bekerja dengan menerapkan operasi konvolusi untuk mengekstraksi fitur penting dari citra, seperti tepi, bentuk, dan tekstur (LeCun et al., 1998). Proses tersebut kemudian dilanjutkan dengan lapisan *pooling* untuk mereduksi dimensi data serta lapisan *fully connected* untuk melakukan klasifikasi akhir (Adriyanto et al., 2022).

Keunggulan utama CNN terletak pada kemampuannya dalam melakukan ekstraksi fitur secara otomatis tanpa memerlukan intervensi manual, serta memiliki ketahanan yang baik terhadap variasi pencahayaan dan sudut pandang objek. Karakteristik ini menjadikan CNN sebagai fondasi teknis utama dalam pengembangan berbagai algoritma deteksi objek modern. Dalam penelitian ini, prinsip dasar CNN digunakan sebagai landasan arsitektur pada model YOLOv8 guna mendukung proses deteksi multi-objek pada citra logistik pendaki dengan tingkat kompleksitas yang beragam.

6. Algoritma YOLO dan YOLOv8

You Only Look Once (YOLO) merupakan algoritma deteksi objek berbasis *one-stage detector* yang diperkenalkan pertama kali oleh Joseph Redmon (Redmon et al., 2016). Algoritma ini melakukan prediksi *bounding box* dan klasifikasi objek secara simultan dalam satu tahap pemrosesan tunggal. Mekanisme tersebut memberikan keunggulan utama dalam hal kecepatan pemrosesan citra dibandingkan metode deteksi objek tradisional lainnya.

Seiring perkembangannya, YOLO mengalami berbagai peningkatan arsitektur untuk mengoptimalkan akurasi dan efisiensi model. YOLOv8 merupakan salah satu arsitektur populer dalam keluarga YOLO yang menawarkan keseimbangan performa serta kemudahan dalam implementasi sistem (Ultralytics, 2026). Secara arsitektur, YOLOv8 terdiri dari tiga komponen utama yang meliputi *backbone*, *neck*, dan *head*. *Backbone* berfungsi untuk mengekstraksi fitur dari citra masukan, sementara *neck* menggabungkan fitur dari berbagai skala yang berbeda untuk mengenali objek dengan ukuran yang bervariasi.

Perbedaan teknis pada YOLOv8 terletak pada bagian *head* yang menerapkan mekanisme *anchor-free detection* untuk menggantikan metode *anchor-based* pada versi sebelumnya (Terven et al., 2023). Pendekatan *anchor-free* memprediksi lokasi pusat objek secara langsung tanpa memerlukan kotak referensi (*anchor boxes*) yang memiliki rasio aspek tetap (Terven et al., 2023). Inovasi teknis ini meningkatkan fleksibilitas model dalam mengenali objek dengan variasi bentuk yang ekstrem serta mempercepat proses inferensi pada citra dengan kepadatan objek yang tinggi.

Selain keunggulan pada struktur arsitekturalnya, YOLOv8 juga mengintegrasikan teknik augmentasi data untuk meningkatkan ketangguhan (*robustness*) model terhadap variasi visual yang kompleks. Penggunaan augmentasi data terbukti secara signifikan dapat meningkatkan kemampuan generalisasi model, terutama dalam mengenali detail visual pada kondisi lingkungan yang dinamis (Pradhana & Daniati, 2025). Hal ini menjadi faktor krusial guna memastikan model tetap akurat saat mendeteksi objek dalam berbagai kondisi pencahayaan maupun tumpukan objek yang padat.

Pemilihan arsitektur YOLOv8 sebagai metode utama didasarkan pada kemampuannya menyeimbangkan tingkat akurasi dan kecepatan inferensi dibandingkan algoritma deteksi objek lainnya (Terven et al., 2023). Secara khusus, penelitian ini menggunakan varian YOLOv8 nano (YOLOv8n) karena model tersebut memiliki jumlah parameter paling minimum dan beban komputasi (FLOPs) paling ringan (Ultralytics, 2026). Karakteristik model yang ringan sangat krusial untuk mendukung implementasi pada perangkat dengan spesifikasi perangkat keras terbatas tanpa mengorbankan akurasi deteksi secara signifikan.

7. Multi-Object Detection

Multi-object detection merupakan pengembangan dari *object detection* yang berfokus pada kemampuan model dalam mendeteksi lebih dari satu objek dalam satu citra secara bersamaan. Pada kondisi ini, model tidak hanya dituntut untuk mengenali jenis objek, tetapi juga harus mampu menentukan lokasi setiap objek dengan akurat meskipun jumlah objek dalam satu citra cukup banyak.

Dalam praktiknya, *multi-object detection* menghadapi berbagai tantangan seperti *overlapping* antar objek, perbedaan ukuran objek (*scale variation*), serta kepadatan objek yang tinggi (*dense objects*). Kondisi tersebut dapat menyebabkan objek saling menutupi (*occlusion*) dan menyulitkan model dalam membedakan batas antar objek (Lin et al., 2018). Untuk mengatasi masalah prediksi ganda pada area yang padat, sistem memerlukan algoritma *Non-Maximum Suppression* (NMS) sebagai teknik pasca-pemrosesan (Zou et al., 2023). Teknik NMS tersebut berfungsi untuk menyeleksi *bounding box* terbaik dengan cara menghapus kotak prediksi redundan yang memiliki nilai *Intersection over Union* (IoU) di atas ambang batas tertentu (Zou et al., 2023).

Selain itu, ketidakseimbangan antara objek (*foreground*) dan latar belakang (*background*) juga menjadi permasalahan dalam *multi-object detection*. Jumlah area latar belakang yang jauh lebih besar dibandingkan objek dapat menyebabkan model lebih cenderung mendeteksi *background* daripada objek yang sebenarnya. Untuk mengatasi permasalahan tersebut, berbagai pendekatan telah dikembangkan, salah satunya melalui penggunaan fungsi *loss* seperti *Focal Loss* yang mampu meningkatkan fokus model pada objek yang sulit dideteksi (Lin et al., 2018).

Penelitian lain juga menunjukkan bahwa deteksi objek pada kondisi padat, seperti pada kerumunan (*crowded scene*), menjadi lebih sulit karena ukuran objek yang kecil dan batas antar objek yang tidak jelas (Hassan et al., 2023). Hal ini menunjukkan bahwa jumlah objek dan tingkat kepadatan dalam citra merupakan faktor penting yang mempengaruhi performa model deteksi objek. Berdasarkan hal tersebut, *multi-object detection* menjadi aspek penting dalam penelitian ini, khususnya dalam mengevaluasi kemampuan model YOLOv8 untuk mendeteksi objek dalam jumlah banyak pada citra dengan tingkat kepadatan tinggi (*high clutter*).

8. Metode Evaluasi Model

Evaluasi model deteksi objek dilakukan untuk mengukur kinerja model dalam mengenali dan mengklasifikasikan objek pada citra. Metrik utama dalam evaluasi

tersebut mencakup *precision*, *recall*, dan *mean Average Precision* (mAP). Precision mengukur tingkat ketepatan prediksi model dalam mendeteksi objek (Padilla et al., 2020). *Recall* menunjukkan kemampuan model dalam menemukan seluruh objek yang relevan di dalam citra (Padilla et al., 2020). Metrik mAP menggabungkan nilai *precision* dan *recall* untuk memberikan gambaran performa model secara menyeluruh dalam tugas deteksi objek.

Evaluasi model juga mempertimbangkan nilai *Intersection over Union* (IoU) sebagai ukuran kesesuaian antara *bounding box* hasil prediksi dengan *ground truth* (Padilla et al., 2020). Nilai IoU yang lebih tinggi menandakan tingkat akurasi lokalisasi objek yang lebih baik. Dalam penelitian ini, analisis performa menggunakan dua standar metrik mAP yang berbeda, yaitu mAP50 dan mAP50-95. Nilai mAP50 menghitung rata-rata presisi pada ambang batas IoU minimal sebesar 0,5 (Padilla et al., 2020). Sementara itu, mAP50-95 memberikan gambaran mengenai ketepatan lokasi *bounding box* yang lebih ketat melalui perhitungan rata-rata presisi pada berbagai interval ambang batas IoU (Padilla et al., 2020). Penggunaan kedua metrik tersebut menunjukkan tingkat akurasi model dalam aspek klasifikasi maupun ketelitian lokalisasi objek.

Dalam konteks multi-objek, evaluasi model menjadi lebih kompleks karena model harus mampu mendeteksi banyak objek dalam satu citra dengan berbagai variasi posisi, ukuran, dan tingkat kepadatan. Analisis performa model dilakukan dengan memperhatikan perubahan nilai metrik pada berbagai tingkat kompleksitas objek. Dalam penelitian ini, prosedur evaluasi tersebut bertujuan untuk menganalisis kemampuan YOLOv8 dalam mendeteksi logistik pendaki pada dataset dengan karakteristik yang beragam.

B. Kajian Hasil Penelitian Terdahulu

Tabel 2. 1 Kajian Hasil Penelitian Terdahulu

No	Judul	Penulis & Tahun	Metode	Hasil Utama	Relevansi dan Posisi Penelitian Ini
1	Penerapan <i>Object Detection</i> Menggunakan <i>Deep Learning</i> YOLOv8 Untuk Mengidentifikasi Sampah Anorganik (Maksimal Sepuluh Objek)	(Visen & Charibaldi, 2025)	YOLOv8 Nano	Menghasilkan mAP 87,1% pada sampah anorganik. Namun, peneliti membatasi jumlah maksimal objek sebanyak sepuluh buah dalam satu citra untuk menghindari penurunan akurasi akibat objek yang tumpang tindih.	Penelitian ini mematahkan batasan maksimal 10 objek tersebut dengan melakukan stress testing model YOLOv8 pada lima tingkat kepadatan, hingga mencapai kategori Extreme Clutter (≥ 18 objek) dengan performa mAP50 yang tetap stabil di angka 96,22%.
2	<i>Crowd Counting</i>	(Hassan et al., 2023)	<i>Deep Learning</i>	Model berhasil	Memberikan landasan teori

	<i>Using Deep Learning Based Head Detection</i>		(YOLOv5)	mendeteksi objek kepala pada kerumunan, namun ditemukan degradasi performa (miss-detection) yang signifikan ketika objek berukuran sangat kecil (skala mikro) dan saling menutupi (<i>overlapping</i>).	mengenai kesulitan deteksi objek berdimensi kecil. Penelitian ini melanjutkan analisis tersebut secara spesifik pada objek logistik (rokok batangan) yang mengalami degradasi presisi akibat gangguan <i>noise</i> dan <i>inter-class similarity</i> .
3	Analisis Kinerja Deteksi Gerakan dan Pengenalan Objek Produk Ritel Berbasis YOLOv8	(Kusumawardhani et al., 2024)	YOLOv8	Model mampu mengenali produk ritel (minuman dan makanan ringan) dengan akurasi yang baik pada	Memiliki kemiripan kelas (produk kemasan), namun penelitian tersebut tidak menguji kepadatan

				berbagai kondisi pencahayaan di lingkungan minimarket	(<i>clutter</i>). Penelitian ini mengisi celah tersebut dengan menggunakan <i>custom dataset</i> logistik pendaki yang disusun spesifik berdasarkan tingkat kepadatan visual.
4	<i>Implementati on of YOLOv8 Algorithm for Web-Based Detection of Coffee Fruit Ripeness</i>	(Putra & Saputra, 2025)	YOLOv8 , Web Deploy ment	Keberhasilan implementasi model YOLOv8 ke dalam aplikasi berbasis web (<i>Web-Based</i>) untuk mendeteksi kematangan buah kopi secara <i>real-time</i> .	Menjadi acuan arsitektur <i>deployment</i> . Penelitian ini mengekspanasi skenario tersebut dengan melakukan pengujian kompatibilitas dan waktu inferensi (<i>inference</i>

					<i>time</i>) lintas platform keras (<i>laptop</i> vs <i>smartphone</i>).
5	Pengembangan Sistem Deteksi Objek Botol <i>Real-Time</i> dengan YOLOv8 untuk Aplikasi <i>Vision</i>	(Triyanto et al., 2024)	YOLOv8	Menghasilkan performa mAP sangat tinggi (99,5%) untuk deteksi kelas botol plastik dan kaleng daur ulang.	Penelitian tersebut terbatas pada deteksi objek tunggal (terisolasi). Penelitian ini hadir untuk menguji apakah akurasi yang tinggi tersebut dapat dipertahankan ketika model dihadapkan pada tumpukan multi-objek.
6	Short Communication: Detecting Heavy Goods Vehicles in Rest Areas in Winter Conditions Using YOLOv5	(Kasper-Eu laers et al., 2021)	YOLOv5 , Transfer Learning, Thermal Imaging	Model YOLOv5 berhasil mendeteksi kendaraan di area bersalju dengan mengandalkan fitur visual kabin depan, terlepas dari	Penelitian tersebut membuktikan ketangguhan keluarga algoritma YOLO dalam kondisi <i>overlap</i> . Penelitian ini memperluas

				tingginya jumlah objek yang saling tumpang tindih (<i>overlaps</i>).	studi tersebut dengan menguji arsitektur yang lebih baru (YOLOv8) pada tingkat kepadatan logistik yang jauh lebih ekstrem (<i>Extreme Clutter</i>).
7	A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS	(Terven et al., 2023)	Systematic Literature Review	Menyajikan evaluasi komprehensif atas evolusi arsitektur YOLO dari versi pertama hingga YOLOv8, yang menjadikannya standar utama sistem deteksi objek real-time.	Kajian tersebut menyajikan landasan teori atas pembaruan state-of-the-art YOLOv8. Penelitian ini menguji klaim performa tersebut secara praktik dengan menanamkan varian model nano ke dalam aplikasi web lintas perangkat.
8	Object Detection in 20 Years: A Survey	(Zou et al., 2023)	Systematic Literature Review	Merangkum evolusi teknis dan tantangan metode deteksi objek selama dua dekade, termasuk evaluasi dataset, metrik, serta revolusi	Survei tersebut memetakan tantangan fundamental object detection. Penelitian ini berupaya menjawab kendala teknis dalam survei

				berbasis deep learning.	tersebut dengan mengevaluasi langsung pengaruh variasi kepadatan objek visual terhadap stabilitas mAP.
9	Machine Learning Operations (MLOps): Overview, Definition, and Architecture	(Kreuzberger et al., 2023)	Mixed-Method Research	Mengurai prinsip, komponen arsitektur, dan alur kerja MLOps untuk mengotomatisasi model machine learning menjadi produk yang siap beroperasi di dunia nyata (production).	Memberikan justifikasi atas krusialnya proses deployment. Penelitian ini tidak hanya melatih model di tingkat lokal, tetapi mengoperasikan nalkannya menjadi Web App berbasis Streamlit agar dapat langsung diakses petugas posko di lapangan.
10	Implementasi YOLOv8 untuk Deteksi dan Hitung Objek Manusia dengan Convolutional Neural Network	(Mihuandayani et al., 2025)	YOLOv8 , CNN	Sistem berhasil mendeteksi dan menghitung objek manusia dengan tingkat keberhasilan 85%. Namun, sistem mengalami kesulitan dan penurunan skor	Penelitian tersebut menyoroti kelemahan adaptasi YOLOv8 pada kondisi tumpang tindih. Penelitian ini secara spesifik berupaya memecahkan tantangan <i>overlapping</i>

				keyakinan (hingga 42,90%) pada skenario objek yang saling tumpang tindih atau berdekatan.	tersebut dengan melakukan <i>stress testing</i> pada variasi kepadatan logistik hingga level ekstrem (<i>Extreme Clutter</i>) dengan akurasi yang tetap terjaga.
11	Evaluasi Kinerja Model YOLOv8 untuk Deteksi Objek Kecil pada Alat Bedah dengan Dukungan Augmentasi Roboflow	(Burhan et al., 2026)	YOLOv8 , Roboflow Preprocessing	Model YOLOv8 yang dikombinasikan dengan teknik prapemrosesan dan augmentasi data berhasil mendeteksi objek kecil (<i>small objects</i>) dengan presisi 89,3%, <i>recall</i> 86,7%, dan mAP50 91,5%.	Sama-sama berfokus pada kapabilitas YOLOv8 dalam mendeteksi objek berskala mikro yang memiliki piksel terbatas. Jika penelitian tersebut mengidentifikasi alat bedah, penelitian ini menganalisis objek logistik kecil (rokok) yang rentan mengalami <i>false positive</i> akibat fenomena <i>inter-class similarity</i> .
12	Integrasi Algoritma YOLOv8 dan Streamlit untuk Visualisasi	(Prihandoko et al., 2025)	YOLOv8 , Streamlit Framework	Sistem deteksi berhasil diintegrasikan dengan <i>framework</i> Streamlit	Kajian ini memvalidasi keandalan arsitektur <i>deployment</i> menggunakan

2

	Real-Time dan Akurat dalam Penghitungan Kerumunan di Kawasan Stasiun Bekasi			untuk divisualisasikan secara <i>real-time</i> berbasis web, dan menghasilkan performa mAP@0.5 sebesar 91,7%.	Streamlit. Penelitian ini turut mengadopsi rancangan web tersebut, namun mengembangkannya dengan mengevaluasi komparasi responsivitas waktu inferensi lintas perangkat (komputer lokal vs <i>smartphone</i> genggam) secara langsung.
13	UAV-YOLO v8: A Small-Object -Detection Model Based on Improved YOLOv8 for UAV Aerial Photography Scenarios	(Wang et al., 2023)	YOLOv8, WIoU v3, BiFormer Attention, Multiscale Feature Fusion	Model UAV-YOLOv8 berhasil meningkatkan akurasi deteksi rata-rata sebesar 7,7% dibandingkan model <i>baseline</i> , dengan jumlah parameter yang lebih sedikit. Metode fusi fitur multi-skala ini terbukti secara signifikan mengurangi tingkat kegagalan deteksi	Penelitian tersebut membuktikan efektivitas fusi fitur untuk mengatasi kegagalan deteksi pada objek berskala mikro. Penelitian ini mengadopsi analisis tersebut guna mengidentifikasi penyebab degradasi mAP pada kelas minoritas berukuran kecil (seperti rokok) di tengah tumpukan

18

				(<i>missed detection rate</i>) pada objek berukuran kecil.	objek yang lebih besar.
14	DC-YOLOv8 : Small-Size Object Detection Algorithm Based on Camera Sensor	(Lou et al., 2023)	DC-YOLOv8, Feature Fusion Network, Downsampling Optimization	Melalui perbaikan metode <i>downsampling</i> dan fusi fitur, model DC-YOLOv8 mengungguli YOLOv8 standar dalam deteksi objek kecil (VisDrone) dengan peningkatan mAP sebesar 2,5%, <i>precision</i> 1,9%, dan <i>recall</i> 2,1%, serta efektif diterapkan pada tangkapan sensor kamera.	Sama-sama berupaya mempertahankan informasi fitur pada objek berukuran kecil. Penelitian ini menguji ketahanan ekstraksi fitur tersebut secara langsung menggunakan citra logistik nyata yang diambil dari sensor kamera <i>smartphone</i> dengan berbagai variasi jarak dan kepadatan.
15	An Improved YOLOv8 Algorithm for Small Object Detection	(Shi et al., 2026)	YOLOv8, CBAM, BoTNet, SiLU Loss	Penggabungan mekanisme atensi (CBAM) berhasil memperbaiki ekstraksi fitur pada kondisi kontras rendah (<i>low-contrast</i>), menghasilkan performa mAP@0.5	Menjadi justifikasi akademis yang sangat kuat dalam menangani variasi skala dan pencahayaan. Penelitian ini mengeksplorasi tantangan serupa di mana kelas objek logistik

				sebesar 92,7% dengan generalisasi yang sangat baik pada deteksi target berukuran kecil dan multi-skala.	memiliki disparitas ukuran ekstrem (<i>multi-scale</i>) serta kontras visual yang menyatu akibat tumpang tindih di level <i>Extreme Clutter</i> .
16	Benchmarking Vision Transformer Klasifikasi Visual Masakan Padang dengan Robustness Melalui Augmentasi Data	(Pradhana & Daniati, 2025)	Vision Transformer (ViT), Data Augmentation	Model ViT (khususnya varian ViT-B/16) terbukti efektif mengenali detail visual kuliner dengan akurasi 95% yang didukung oleh teknik augmentasi data untuk generalisasi model.	Penelitian tersebut membuktikan keandalan deep learning pada citra visual makanan. Penelitian ini mengembangkannya lebih jauh dengan beralih dari arsitektur klasifikasi menjadi arsitektur deteksi spasial (YOLOv8) untuk mengenali belasan objek logistik secara simultan.
17	Analisis Data Penjualan pada UMKM Konveksi Menggunakan Metode K-Means Clustering dengan	(Daniati et al., 2025)	K-Means Clustering, CRISP-DM	Penerapan kerangka kerja CRISP-DM berhasil memandu tahapan analisis data untuk	Penelitian tersebut memvalidasi efektivitas standar operasional alur kerja CRISP. Penelitian ini

	Menerapkan CRISP-DM			mengeksktraksi dan mengklasterisasi data penjualan UMKM secara optimal.	mengadopsi struktur tersebut namun memutakhirkan menjadi CRISP-ML(Q) yang dirancang khusus untuk memenuhi Quality Assurance pada siklus hidup machine learning berbasis citra.
18	An Evaluation of the Impact of Dataset Size on Classification Performance in the Cognitive Bloom's Taxonomy	(Sucipto et al., 2024)	Evaluasi Model Klasifikasi, K-Fold Cross Validation	Membuktikan secara empiris bahwa penambahan ukuran dataset (dataset size) berdampak signifikan terhadap kinerja, stabilitas, dan akurasi model klasifikasi secara keseluruhan.	Penelitian tersebut memberikan legitimasi teoretis fundamental mengenai pentingnya volume data. Penelitian ini merealisasikan temuan tersebut dengan menggunakan custom dataset skala masif (13.792 citra) untuk mencegah degradasi akurasi YOLOv8 pada kondisi padat.
19	Peningkatan Performa Ensemble Learning pada	(Nugroho et al., 2023)	Ensemble Learning, Synthetic Oversampling	Teknik sintesis oversampling terbukti berhasil mengatasi	Sama-sama berfokus pada mitigasi anomali data di ranah

	Segmentasi Semantik Gambar dengan Teknik Oversampling untuk Class Imbalance			ketidakseimbangan kelas (class imbalance) dan meningkatkan akurasi segmentasi gambar hingga 41% pada algoritma LGBM.	Computer Vision. Jika penelitian tersebut menggunakan oversampling untuk data minoritas, penelitian ini memecahkan masalah degradasi deteksi kelas mikro (rokok) melalui optimasi nilai ambang batas (Confidence Threshold).
20	Classification of dog and cat images using the CNN method	(Adriyanto et al., 2022)	Convolutional Neural Network (CNN)	Arsitektur dasar CNN dengan ekstraksi gambar berukuran 150x150 piksel mampu melakukan pengenalan citra hewan, menghasilkan nilai precision dan recall sebesar 45%.	Penelitian tersebut menggunakan arsitektur dasar CNN untuk ekstraksi gambar tunggal. Penelitian ini menggunakan arsitektur turunan CNN yang jauh lebih mutakhir (YOLOv8) untuk mendeteksi tumpukan multi-objek secara spasial dan real-time.

C. Kerangka Berpikir

Kerangka berpikir dalam penelitian ini disusun berdasarkan permasalahan utama pada proses deteksi multi-objek, yaitu meningkatnya kompleksitas deteksi ketika jumlah objek dalam satu citra semakin banyak. Kondisi tersebut menyebabkan terjadinya tumpang tindih (*overlapping*) antar objek, variasi ukuran objek, serta latar belakang yang kompleks, sehingga model deteksi objek rentan mengalami penurunan performa dalam mengenali objek secara akurat.


Berdasarkan penelitian terdahulu, algoritma YOLOv8 diketahui memiliki performa yang baik pada deteksi objek tunggal maupun multi-kelas pada berbagai domain. Namun, sebagian besar penelitian sebelumnya masih berfokus pada kondisi objek yang terbatas dalam satu citra dan belum secara khusus mengevaluasi performa model pada kondisi objek padat dan kompleks. Kesenjangan tersebut menjadi dasar dilakukannya penelitian ini.

Landasan teori yang digunakan dalam penelitian ini meliputi *Artificial Intelligence*, *Machine Learning*, *Deep Learning*, *Computer Vision*, *Object Detection*, *Convolutional Neural Network* (CNN), serta arsitektur algoritma YOLOv8. Teori-teori tersebut digunakan untuk mendukung proses evaluasi model dalam mendeteksi multi-objek pada citra dengan tingkat kompleksitas yang berbeda.

Penelitian ini menggunakan pendekatan evaluasi model YOLOv8 pada *custom dataset* logistik pendaki yang disusun berdasarkan tingkat kepadatan visual, mulai dari kondisi *single object* hingga *extreme clutter*. Evaluasi model dilakukan menggunakan metrik *precision*, *recall*, F1-Score, *mean Average Precision* (mAP), *Intersection over Union* (IoU), serta kecepatan pemrosesan (*inference time*) untuk menganalisis pengaruh jumlah objek terhadap performa model secara komprehensif.

Melalui kerangka berpikir ini, penelitian diarahkan untuk menghasilkan analisis mengenai kemampuan YOLOv8 dalam mendeteksi multi-objek pada kondisi citra yang kompleks, sekaligus membuktikan kelayakan implementasinya

ke dalam purwarupa (*prototype*) aplikasi berbasis web (*Web App*) lintas perangkat. Hasil penelitian diharapkan dapat memberikan pemahaman mengenai batas kemampuan model deteksi objek pada variasi jumlah objek, serta menjadi solusi praktis dalam sistem pelaporan logistik lapangan.



Gambar 2.1 Kerangka Berpikir


Berdasarkan alur pada Gambar 2.1, kerangka berpikir ini menghubungkan masalah penumpukan barang yang sangat padat (*extreme clutter*) dengan teori sistem cerdas. Dengan menguji model YOLOv8 pada berbagai jumlah barang dan infrastruktur perangkat, penelitian ini ingin membuktikan secara nyata sampai di mana batas kemampuan terbaik model tersebut dalam mendeteksi objek dengan akurat, serta mengonfirmasi portabilitasnya sebagai solusi praktis. Penjelasan lebih mendalam mengenai langkah-langkah teknis penelitian ini akan dibahas selanjutnya pada Bab III.

BAB III

METODE PENELITIAN

Metodologi yang digunakan dalam penelitian ini adalah CRISP-ML(Q) (*Cross-Industry Standard Process for Machine Learning with Quality Assurance*). Pemilihan metodologi ini didasarkan pada kemampuannya dalam menjamin kualitas pada setiap siklus hidup pengembangan model *machine learning*, mulai dari pemahaman masalah hingga pemeliharaan model (Studer et al., 2021).

Penggunaan kerangka kerja yang terstruktur seperti CRISP-ML(Q) atau CRISP-DM juga telah lazim diimplementasikan dalam berbagai riset di lingkungan prodi untuk menjamin keteraturan alur analisis data (Daniati et al., 2025). Secara visual, tahapan penelitian ini digambarkan pada Gambar 3.1 di bawah ini:



Gambar 3.1 Diagram Metode Penelitian CRISP-ML(Q)

Penjelasan dari masing-masing tahapan pada Gambar 3.1 akan dijabarkan pada sub-bab berikut:

A. Business and Data Understanding

Tahap *Business and Data Understanding* merupakan fase awal dalam metodologi CRISP-ML(Q) yang bertujuan untuk menyelaraskan tujuan teknis model dengan kebutuhan pengguna akhir (Studer et al., 2021). Pada tahap ini,

65 dilakukan identifikasi mendalam terhadap permasalahan nyata yang dihadapi serta pemetaan karakteristik data yang akan digunakan untuk melatih dan mengevaluasi model deteksi objek.

7 Permasalahan utama dalam penelitian ini berangkat dari kompleksitas proses pemeriksaan logistik pendaki di basecamp. Meskipun teknologi deteksi objek seperti YOLOv8 dapat diimplementasikan untuk membantu pencatatan otomatis, performa model seringkali menurun ketika dihadapkan pada kondisi objek yang saling bertumpuk (*overlapping*) atau sangat padat (*dense objects*). Oleh karena itu, penelitian ini tidak hanya bertujuan untuk menerapkan sistem deteksi, tetapi lebih berfokus pada mengevaluasi batas kemampuan (*stress testing*) algoritma YOLOv8n dalam mengenali berbagai jenis logistik pendaki di bawah tingkat kepadatan yang beragam.

5 Selain pemahaman terhadap masalah, tahap ini juga mencakup identifikasi *dataset*. Data yang digunakan dalam penelitian ini adalah citra logistik pendaki yang mencakup lima kelas objek utama, yaitu botol mineral, mie instan, roti, kopi kemasan, dan rokok. Mengingat keterbatasan *dataset* publik yang secara spesifik merepresentasikan kondisi kepadatan logistik di lapangan, maka dilakukan pengumpulan *custom dataset*. Hal ini didasarkan pada argumen bahwa ukuran *dataset* dan keterwakilan distribusi data asli sangat menentukan stabilitas akurasi dan performa model klasifikasi maupun deteksi (Sucipto et al., 2024).

Melalui tahap *Business and Data Understanding* ini, penelitian didefinisikan untuk menghasilkan evaluasi performa model YOLOv8n yang diuji melalui lima tingkat kompleksitas, mulai dari *single object* hingga *extreme clutter*. Pemahaman ini menjadi dasar penting untuk memastikan bahwa model yang dikembangkan memiliki ketangguhan (*robustness*) saat diimplementasikan ke dalam antarmuka aplikasi.

B. Data Engineering (Data Preparation)

33 Tahap Data Preparation merupakan fase krusial dalam metodologi CRISP-ML(Q) untuk mengolah dataset mentah agar siap digunakan dalam proses


pelatihan model. Kualitas penyiapan data berpengaruh langsung terhadap kemampuan model dalam mengenali pola visual secara konsisten (Studer et al., 2021). Optimasi pada tahap prapemrosesan terbukti dapat meningkatkan performa model secara signifikan (Ristyan et al., 2025).

1. Deskripsi Dataset dan Distribusi Kelas

Dataset yang digunakan dalam penelitian ini adalah custom dataset citra logistik pendaki yang dikumpulkan secara primer. Dataset ini mencakup lima kelas objek utama: Botol, Kopi, Mie, Rokok, dan Roti. Berdasarkan hasil ekstraksi data pada versi 4.2, rincian distribusi anotasi pada setiap kelas disajikan dalam Tabel 3.1 berikut:

Tabel 3.1 Distribusi Anotasi Dataset V4.3

Kelas Objek	Train	Valid	Test
Botol	2.214	296	221
Kopi	1.653	214	200
Mie	2.111	268	248
Rokok	3.764	435	345
Roti	1.469	195	159
Total	11.211	1.408	1.173



Gambar 3.2 Grafik Distribusi Total Anotasi per Kelas (*Dataset V4.3*)

Berdasarkan Tabel 3.1 dan visualisasi pada Gambar 3.2, terlihat bahwa kelas Rokok memiliki jumlah anotasi tertinggi (4.544). Hal ini merupakan hasil dari penerapan teknik *manual oversampling* yang dilakukan secara sengaja untuk memberikan *eksposur* lebih pada objek rokok yang memiliki dimensi fisik paling kecil. Langkah ini merujuk pada prinsip penanganan *class imbalance* untuk meningkatkan stabilitas performa model pada objek yang sulit dideteksi (Nugroho et al., 2023).

2. Prapemrosesan Citra (*Preprocessing*)

Seluruh citra dalam dataset diproses melalui tahap *resizing* menjadi resolusi 640x640 piksel menggunakan metode *Stretch to*. Metode ini diterapkan setelah melalui tahapan evaluasi terhadap teknik *Fit (Reflect Edges)*, di mana penggunaan efek cermin (*mirroring*) pada tepi citra ditemukan menghasilkan *visual artifacts* berupa replikasi fitur latar belakang (*background*) yang memicu kesalahan deteksi (*False Positive*) oleh model. Melalui teknik *Stretch to*, seluruh informasi spasial citra disesuaikan secara penuh ke dalam dimensi input model tanpa menghasilkan duplikasi fitur semu pada area tepi. Hal ini terbukti secara signifikan meningkatkan kemampuan lokalisasi model YOLOv8n dalam mengekstraksi fitur asli dari objek logistik pendaki (Roboflow, 2026).

3. Strategi *Augmentasi Data*

Dalam pengembangan model *deep learning*, penggunaan *augmentasi data* berperan penting dalam meningkatkan ketangguhan (*robustness*) model (Pradhana & Daniati, 2025). Namun, pada penelitian ini, teknik *augmentasi sintetis* tambahan pada platform Roboflow sengaja *dinonaktifkan* (OFF) untuk menjaga kemurnian fitur visual pada objek berukuran kecil dan memastikan evaluasi tingkat kepadatan objek (*clutter*) tetap objektif.

Sebagai gantinya, penelitian ini mengandalkan fitur *Internal Augmentation* berupa teknik *Mosaic* dan *Mixup* yang merupakan standar bawaan arsitektur YOLOv8 (Ultralytics, 2026). Teknik ini secara dinamis menggabungkan beberapa citra selama proses pelatihan untuk melatih ketajaman model dalam mengenali objek pada kondisi yang sangat rapat dan bertumpuk.

4. Pembagian *Dataset* (*Data Splitting*)

Dataset dibagi secara sistematis ke dalam tiga subset menggunakan proporsi 80% data latih (*training*), 10% data validasi (*validation*), dan 10% data uji (*testing*). Penentuan proporsi ini dilakukan untuk menyelaraskan metodologi dengan penelitian Visen & Charibaldi guna memastikan proses *benchmarking* hasil evaluasi dapat dilakukan secara objektif dan konsisten (Visen & Charibaldi, 2025). Penyelarasan ini juga mencakup pengaturan jumlah iterasi pelatihan (*epoch*) sebanyak 50 kali, sesuai dengan *parameter* optimal yang digunakan dalam penelitian acuan tersebut untuk menghasilkan kinerja model yang stabil.

C. *Machine Learning Model Building*

Tahap *Machine Learning Model Building* bertujuan untuk membangun, melatih, dan mengoptimalkan model berdasarkan *dataset* yang telah disiapkan pada tahap sebelumnya (Studer et al., 2021). Eksperimen pada tahap ini difokuskan pada penyelarasan parameter dengan penelitian acuan guna menghasilkan hasil evaluasi yang objektif dan terukur (Visen & Charibaldi, 2025).

1. Pemilihan Arsitektur Model

Penelitian ini menggunakan model YOLOv8 varian *nano* (YOLOv8n) dengan jumlah parameter sebanyak 3.011.823 yang terdiri dari 225 lapisan (Visen & Charibaldi, 2025). Pemilihan varian ini diselaraskan dengan penelitian Visen & Charibaldi agar proses perbandingan performa (*benchmarking*) dilakukan menggunakan arsitektur yang identik. Arsitektur ini dipilih karena efisiensi komputasinya yang tinggi serta kemampuannya untuk memberikan tingkat akurasi yang tinggi dengan kebutuhan komputasi yang minimal (Ultralytics, 2026).

2. Lingkungan Pengembangan

Proses pelatihan model dilakukan menggunakan platform Kaggle dengan dukungan akselerator GPU NVIDIA T4. Meskipun penelitian acuan menggunakan lingkungan pengembangan Google Colab, penggunaan platform Kaggle tetap relevan karena keduanya menyediakan dukungan pustaka Ultralytics yang diperlukan untuk deteksi objek berbasis deep learning (Visen & Charibaldi, 2025).

3. Konfigurasi *Hyperparameter*

Untuk memastikan stabilitas pelatihan dan validitas hasil, penentuan *hyperparameter* merujuk pada standar yang digunakan dalam penelitian acuan (Visen & Charibaldi, 2025). Penentuan parameter ini krusial untuk menjaga stabilitas performa model serta mencegah terjadinya selisih akurasi yang signifikan antara data pelatihan dan data pengujian (Ristyawan & Nugroho, 2026). Rincian konfigurasi pelatihan adalah sebagai berikut:

- a. *Epoch*: Ditetapkan sebanyak 50 iterasi untuk menyamai parameter pelatihan pada penelitian Visen & Charibaldi (Visen & Charibaldi, 2025).
- b. *Batch Size*: Menggunakan nilai 16 untuk menjaga keseimbangan antara stabilitas gradien dan kapasitas memori GPU.
- c. *Optimizer*: Menggunakan AdamW dengan nilai *learning rate* awal sebesar 0,001111. Pemilihan ini dilakukan secara otomatis oleh sistem YOLOv8

untuk mencapai konvergensi yang lebih cepat pada model skala nano (Visen & Charibaldi, 2025).

- d. *Image Size*: Ditetapkan pada resolusi 640x640 piksel untuk menjaga detail visual objek sesuai dengan standar prapemrosesan (Visen & Charibaldi, 2025).

4. Pemanfaatan *Pre-trained Weights*

Proses pelatihan diawali dengan memuat bobot awal (*pre-trained weights*) dari berkas *yolov8n.pt* (Ultralytics, 2026). Penggunaan teknik ini bertujuan untuk memfasilitasi proses konvergensi model yang lebih baik, di mana model diinisialisasi sebelum dilatih dengan *data training* (Visen & Charibaldi, 2025).

D. Model Evaluation

Tahap *Model Evaluation* bertujuan untuk menilai kinerja model deteksi objek yang telah dilatih secara menyeluruh guna memastikan kualitas deteksi sebelum diimplementasikan (Studer et al., 2021). Evaluasi dilakukan untuk memvalidasi bahwa model YOLOv8n yang dikembangkan mampu memberikan hasil deteksi yang akurat dan efisien dalam mengidentifikasi objek logistik pendaki pada berbagai kondisi kepadatan objek sesuai dengan tujuan penelitian (Visen & Charibaldi, 2025).

1. Metrik Performa Deteksi

Kinerja model dievaluasi menggunakan *validation dataset* melalui beberapa metrik standar deteksi objek, yaitu *Precision*, *Recall*, *F1-Score*, dan *mean Average Precision* (mAP). Penggunaan mAP dilakukan pada dua ambang batas yang berbeda, yaitu mAP50 untuk akurasi pada ambang batas 50% dan mAP50-95 untuk menggambarkan kemampuan model dalam berbagai kondisi yang lebih ketat (Padilla et al., 2020). Selain itu, *Confusion Matrix* digunakan untuk mengevaluasi kinerja model dalam mengklasifikasikan citra serta meminimalkan kesalahan identifikasi antar-kelas (Kasper-Eulaers et al., 2021). Evaluasi metrik ini didasarkan pada tiga kondisi prediksi utama:

- a. *True Positive* (TP): Model berhasil mendeteksi objek dengan benar sesuai dengan label aslinya.
- b. *False Positive* (FP): Model mendeteksi objek yang sebenarnya tidak ada (salah deteksi) atau salah mengenali kelas objek.
- c. *False Negative* (FN): Model gagal mendeteksi objek yang sebenarnya ada di dalam gambar.

Berdasarkan nilai komponen di atas, performa model dihitung menggunakan persamaan matematis berikut:

a. *Precision*

Precision mengukur rasio ketepatan deteksi benar (TP) dibandingkan dengan seluruh hasil prediksi positif oleh model (TP + FP).

$$Precision = \frac{TP}{TP+FP} \quad (1)$$

b. *Recall*

Recall mengukur tingkat keberhasilan model dalam menemukan kembali seluruh objek asli yang seharusnya terdeteksi (TP + FN).

$$Recall = \frac{TP}{TP+FN} \quad (2)$$

c. *F1-Score*

F1-Score merupakan rata-rata harmonik dari *Precision* dan *Recall*. Metrik ini sangat krusial untuk menentukan ambang batas kepercayaan (*Confidence Threshold*) yang paling optimal pada model.

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (3)$$

d. *mean Average Precision (mAP)*

Nilai rata-rata dari *Average Precision* (AP) untuk seluruh kelas objek. Jika N adalah total jumlah kelas objek (5 kelas logistik), maka perhitungannya adalah:

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (4)$$

2. Prosedur Pengujian Tingkat Kepadatan (*Clutter Levels*)

Berbeda dengan penelitian acuan yang membatasi pengujian pada maksimal sepuluh objek dalam satu citra, evaluasi pada penelitian ini difokuskan pada analisis performa model terhadap lima tingkat kepadatan objek (*clutter levels*). Strategi pengujian ini dirancang sebagai *stress testing* untuk mengidentifikasi ambang batas kemampuan model ketika dihadapkan pada tumpukan objek yang padat dan saling tumpang tindih. Pembagian kategori kepadatan objek didasarkan pada jumlah objek yang terdapat dalam satu citra uji. Rincian batasan jumlah objek untuk setiap tingkat kepadatan disajikan dalam Tabel 3.2 berikut:

Tabel 3.2 Klasifikasi Tingkat Kepadatan Objek (*Clutter Levels*)

No	Tingkat Kepadatan	Rentang Jumlah Objek
1	<i>Single</i>	1 Objek
2	<i>Low Multi</i>	2 – 5 Objek
3	<i>Medium Clutter</i>	6 - 10 Objek
4	<i>High Dense</i>	11 – 17 Objek
5	<i>Extreme Clutter</i>	≥ 18 Objek

3. Evaluasi Efisiensi Waktu Inferensi

Evaluasi juga mencakup pengukuran kecepatan rata-rata inferensi model dalam memproses citra masukan menggunakan akselerator GPU (Visen & Charibaldi, 2025). Pengukuran ini sangat krusial untuk menilai kemampuan model dalam melakukan deteksi secara *real-time*. Waktu inferensi dihitung berdasarkan rata-rata proses prapemrosesan (*preprocess*), proses utama model

(*inference*), dan proses pascapemrosesan (*postprocess*) yang disajikan dalam satuan milidetik (ms) (Visen & Charibaldi, 2025).

4. Penentuan Model Terbaik

Hasil akhir dari tahap evaluasi ini adalah penentuan berkas bobot terbaik (*best weights*) yang menunjukkan nilai evaluasi paling stabil pada data validasi (Visen & Charibaldi, 2025). Model dianggap layak diimplementasikan jika mampu menangani kondisi objek yang bertumpuk (*clutter*) dengan tingkat akurasi yang kompetitif dan memiliki performa yang baik pada iterasi ke-50 (Visen & Charibaldi, 2025).

E. Model Deployment

Tahap deployment pada penelitian ini dilakukan untuk mengimplementasikan arsitektur YOLOv8 yang telah dilatih ke dalam sebuah prototipe aplikasi berbasis web. Tahap ini berfungsi sebagai *Proof of Concept* (PoC) untuk memverifikasi kemampuan model dalam melakukan inferensi pada data di luar *dataset* pengujian serta menunjukkan bagaimana model dapat dioperasikan dalam skenario dunia nyata (Putra & Saputra, 2025)

Prototipe aplikasi ini dikembangkan menggunakan *framework* Streamlit, yang merupakan perangkat pengembangan sumber terbuka yang efisien untuk membangun antarmuka pengguna pada proyek pembelajaran mesin. Penggunaan YOLOv8 dalam lingkungan web memungkinkan proses deteksi objek yang cepat karena efisiensi arsitektur model yang optimal untuk tugas *real-time* (Terven et al., 2023). Aplikasi ini telah di-*deploy* secara publik melalui layanan Streamlit Community Cloud, sehingga memungkinkan akses lintas perangkat, baik melalui komputer maupun *smartphone*, yang memfasilitasi pengujian mobilitas sistem.

Untuk mendukung analisis performa model pada tahap implementasi, prototipe ini dilengkapi dengan beberapa fitur teknis utama:

1. Mekanisme *Dual-Input*: Sistem menyediakan opsi deteksi melalui unggahan file gambar (*image upload*) dan pengambilan gambar secara

langsung (*live camera*). Hal ini dirancang untuk mensimulasikan proses pelaporan mandiri oleh pendaki saat prosedur pemeriksaan logistik.

2. *Interactive Confidence Slider*: Fitur ini memungkinkan pengaturan ambang batas kepercayaan (*confidence threshold*) secara dinamis. Penambahan fitur ini bertujuan untuk mengevaluasi bagaimana perubahan nilai parameter kepercayaan memengaruhi akurasi deteksi pada berbagai kondisi citra masukan.
3. *Automated Data Logging*: Sistem melakukan ekstraksi hasil deteksi secara otomatis ke dalam tabel rekapitulasi jumlah barang. Data hasil deteksi tersebut dapat diunduh dalam format CSV, yang mensimulasikan proses automasi pencatatan data logistik untuk keperluan manajemen sampah di *basecamp*.
4. *Real-time Speed Monitor*: Prototipe menampilkan informasi kecepatan pemrosesan (*inference time*) dalam satuan milidetik (ms). Fitur ini memberikan data kuantitatif mengenai performa komputasi model saat dijalankan pada lingkungan *cloud computing* dibandingkan dengan hasil pada lingkungan pelatihan.

Implementasi pada tahap ini membuktikan bahwa model YOLOv8 yang dikembangkan tidak hanya memiliki akurasi tinggi pada tahap validasi, tetapi juga memiliki fleksibilitas untuk diintegrasikan ke dalam sistem aplikasi yang fungsional. Data yang diperoleh dari tahap *deployment* ini akan digunakan sebagai pelengkap dalam analisis hasil dan pembahasan mengenai efisiensi sistem secara keseluruhan.

F. Monitoring and Maintenance

Tahap *Monitoring and Maintenance* dalam kerangka kerja CRISP-ML(Q) merupakan fase penjaminan mutu (*Quality Assurance*) pasca-implementasi yang bertujuan untuk memastikan kinerja model YOLOv8 tetap berada pada standar kualitas yang ditetapkan. Mengingat karakteristik data di lapangan yang bersifat dinamis, pemantauan dilakukan untuk mendeteksi adanya penurunan performa

atau ketidakakuratan deteksi yang disebabkan oleh perubahan kondisi lingkungan maupun karakteristik objek bawaan pendaki (Kreuzberger et al., 2023).

Pada penelitian ini, strategi monitoring dan maintenance dirancang dengan fokus pada dua aspek utama:

1. *Performance Monitoring (Threshold mAP50)*: Pemantauan dilakukan dengan menetapkan ambang batas minimum performa berdasarkan nilai *baseline* evaluasi akhir (mAP50 sebesar 97,8%). Penurunan akurasi di bawah ambang batas kritis, yaitu 87% atau terjadi degradasi sebesar 10% dari performa awal, ditetapkan sebagai indikator terjadinya *model drift* yang memerlukan tindakan audit data secara manual (Paleyes et al., 2023). Selain metrik akurasi, waktu inferensi (*inference time*) juga menjadi indikator utama yang dipantau untuk memastikan sistem tetap responsif (berada di bawah ambang batas 100 ms) saat dijalankan pada berbagai infrastruktur perangkat keras pengguna.
2. *Adaptive Maintenance (Strategi Retraining & optimasi)*: Jika hasil pemantauan menunjukkan penurunan kualitas pada kondisi tertentu, khususnya pada tingkat kepadatan tinggi (*Extreme Clutter*), maka dilakukan rencana pemeliharaan melalui pelatihan ulang (*retraining*) model. Strategi ini mencakup penambahan dataset baru yang selaras dengan kondisi lapangan dan penerapan teknik augmentasi yang lebih spesifik untuk meningkatkan kemampuan model dalam membedakan fitur objek yang saling bertumpuk (Terven et al., 2023). Selain itu, untuk menjaga stabilitas kecepatan inferensi pada aplikasi berbasis web lintas platform, strategi pemeliharaan difokuskan pada optimasi ukuran model (seperti penerapan kuantisasi atau pemangkasan bobot) agar kinerja sistem tetap efisien meskipun diakses menggunakan perangkat seluler berspesifikasi rendah, tanpa perlu mewajibkan penggunaan akselerator *hardware* eksternal.

Rangkaian perencanaan ini memastikan bahwa sistem deteksi logistik pendaki tidak hanya bersifat statis, tetapi memiliki siklus hidup yang terukur untuk

beradaptasi terhadap variasi data baru dan menjaga reliabilitas hasil evaluasi dalam jangka panjang.

Sebagai penutup dari bab metodologi penelitian ini, diperlukan sebuah pemetaan yang jelas untuk menyelaraskan antara tahapan CRISP-ML(Q) yang telah dijalankan dengan hasil yang akan disajikan pada bab berikutnya. Pemetaan ini bertujuan agar fokus penelitian tetap konsisten pada evaluasi performa model dan penjaminan mutu sistem. Fokus hasil dan pembahasan tersebut diringkas dalam Tabel 3.3 berikut:

Tabel 3.3 Fokus Hasil dan Pembahasan Penelitian

Metode	Fokus Hasil Penelitian	Fokus Pembahasan
CRISP-ML(Q)	Nilai metrik evaluasi model (<i>mAP50</i> , <i>Precision</i> , <i>Recall</i>), waktu inferensi (<i>inference speed</i>), dan hasil implementasi prototipe berbasis web.	Analisis pengaruh tingkat kepadatan objek (<i>clutter levels</i>) terhadap akurasi, perbandingan performa <i>hardware</i> (GPU vs CPU), serta strategi penjaminan mutu model (<i>Quality Assurance</i>).


Dengan ditetapkanya fokus penelitian tersebut, maka seluruh tahapan metodologi telah lengkap dan siap untuk dilanjutkan pada bagian pengolahan data serta analisis hasil eksperimen yang akan dibahas secara mendalam pada Bab 4.

BAB IV**HASIL DAN PEMBAHASAN****A. Data Hasil Penelitian**

Bagian ini memaparkan hasil eksperimen dari setiap tahapan evaluasi model YOLOv8 yang telah dirancang. Data yang disajikan mencakup performa pelatihan pada lingkungan *cloud*, evaluasi metrik teknis, hingga pengujian fungsional pada berbagai infrastruktur perangkat keras.

1. Hasil Pelatihan Model YOLOv8 (Kaggle Environment)

Pelatihan model dilakukan menggunakan lingkungan komputasi Kaggle dengan akselerasi GPU NVIDIA Tesla T4. Model dilatih selama 50 epoch dengan ukuran citra input 640x640 piksel. Berdasarkan grafik hasil pelatihan, model menunjukkan konvergensi yang stabil tanpa indikasi *overfitting*, di mana nilai loss (*box*, *class*, dan *dfl*) pada data pelatihan dan validasi menurun secara konsisten seiring bertambahnya iterasi.



Gambar 4.1 Kurva Keseluruhan Loss dan mAP


Hasil akhir pelatihan menunjukkan performa yang sangat optimal dengan rincian metrik sebagai berikut:

- mAP50 (*All classes*): 0.978 (97,8%).
- mAP50-95: 0.761.
- Precision*: 0.971.
- Recall*: 0.954.

Nilai mAP50 sebesar 97,8% ini secara signifikan melampaui hasil penelitian acuan Visen & Charibaldi yang mencatatkan nilai mAP50 sebesar 87,1% pada kasus deteksi sampah anorganik menggunakan varian model YOLOv8 nano (Visen & Charibaldi, 2025).


2. Evaluasi Metrik dan Penentuan *Confidence Threshold*

Evaluasi mendalam dilakukan dengan menganalisis *F1-Confidence Curve* untuk menentukan ambang batas kepercayaan (*Confidence Threshold*) yang paling seimbang antara *precision* dan *recall*. Berdasarkan kurva tersebut, diperoleh nilai optimal 0,96 pada confidence 0,490 untuk seluruh kelas. Nilai tersebut kemudian ditetapkan sebagai parameter dasar (0,49) dalam pengujian aplikasi untuk menjaga stabilitas deteksi.



Gambar 4.2 F1-*Confidence Curve*


Selain itu, stabilitas model juga ditunjukkan melalui *Precision-Recall Curve* pada Gambar 4.3, di mana seluruh kelas menunjukkan luas area di bawah kurva yang mendekati nilai sempurna, mengonfirmasi keandalan model dalam melakukan klasifikasi.



Gambar 4.3 *Precision-Recall Curve*

Analisis lebih spesifik melalui *Confusion Matrix* pada Gambar 4.4 menunjukkan performa deteksi per kelas sebagai berikut:

- Botol, Kopi, Mie, dan Roti: Menunjukkan tingkat akurasi tertinggi dengan nilai mAP50 masing-masing sebesar 0,983, 0,993, 0,980, dan 0,993.
- Rokok: Mengalami peningkatan performa mAP50 menjadi 0,940 dibandingkan pelatihan sebelumnya. Meskipun demikian, kelas ini tetap menjadi tantangan pada metrik mAP50-95 dengan nilai 0,601 karena karakteristik objek yang kecil. Data menunjukkan terdapat 33 objek rokok yang terlewat (*False Negative*) dan 48 area *background* yang terdeteksi secara salah sebagai rokok (*False Positive*).



Gambar 4.4 *Confusion Matrix*

3. Evaluasi Berdasarkan Tingkat Kepadatan Objek (*Clutter Levels*)

Untuk menguji ketahanan model terhadap kepadatan objek dalam satu citra, dilakukan pengujian pada lima tingkat kepadatan (*Clutter Levels*). Hasil evaluasi menunjukkan bahwa model YOLOv8 tetap mampu menjaga stabilitas akurasi bahkan pada kondisi objek yang sangat rapat.

Tabel 4.1 Hasil Evaluasi Per Tingkat Kepadatan

Tingkat Kepadatan	Jumlah Gambar	mAP 50	Map 50-95	Rata-rata Waktu Inferensi (ms)
Single	80	95.94	83.33	6.29
Low Multi	26	77.06	58.17	6.83
Medium Clutter	17	99.10	77.63	8.26
High Dense	30	98.33	76.80	5.89
Extreme Clutter	22	96.22	73.50	6.51

Pada kategori *High Dense* dan *Extreme Clutter*, model terbukti mampu mendeteksi hingga 20 objek secara simultan dalam satu citra dengan sukses. Temuan ini berhasil melampaui keterbatasan penelitian sebelumnya yang menyatakan bahwa kemampuan deteksi model menurun ketika jumlah objek dalam satu gambar melebihi sepuluh (Visen & Charibaldi, 2025).

4. Perbandingan Performa Infrastruktur Perangkat Keras

Pengujian kecepatan pemrosesan (*Inference Time*) dilakukan pada tiga lingkungan perangkat keras yang berbeda untuk membandingkan efisiensi sistem pada skenario penggunaan nyata. Pengujian dilakukan secara berulang menggunakan sampel citra dari setiap tingkatan kepadatan (*clutter level*) untuk mendapatkan nilai rata-rata yang objektif.

Tabel 4.2 Perbandingan Waktu Inferensi Lintas Perangkat

Perangkat	<i>Single</i>	<i>Low Multi</i>	<i>Medium Clutter</i>	<i>High Dense</i>	<i>Extreme Clutter</i>	Rata-rata Akhir
GPU NVIDIA Tesla T4	6.29	6.83	8.26	5.89	6.51	6,76 ms
Laptop Infinix Inbook X1	59,52	88,03	60,13	61,79	56,92	61,48 ms
Iphone 13 (A15 Bionic)	76,83	73,32	85,24	77,97	59,40	72,62 ms



Berdasarkan hasil pengujian pada Tabel 4.2, infrastruktur *cloud* dengan GPU NVIDIA Tesla T4 memberikan kecepatan inferensi tertinggi dengan rata-rata 6,76 ms. Sementara itu, pada pengujian perangkat lokal (*on-device*), model YOLOv8 nano menunjukkan tingkat kompatibilitas yang sangat baik dengan berhasil dieksekusi di kedua platform target. Lingkungan browser pada laptop Infinix Inbook X1 mencatatkan waktu inferensi rata-rata 61,48 ms, sedangkan perangkat *smartphone* iPhone 13 mencatatkan waktu 72,62 ms. Meskipun terdapat perbedaan karakteristik perangkat keras, kedua platform lokal tersebut terbukti mampu menjalankan model secara stabil di bawah ambang batas interaksi *real-time* (100 ms). Hasil ini mengonfirmasi kelayakan arsitektur sistem berbasis web (*Web App*) yang andal dan adaptif untuk diimplementasikan baik pada platform desktop maupun seluler.

5. Hasil Pengujian Citra (Visualisasi)

Sebagai bukti kualitatif, dilakukan pengujian pada berbagai citra yang mewakili setiap tingkat kepadatan objek. Tabel berikut menyajikan perbandingan antara jumlah objek aktual dengan hasil prediksi model.

Tabel 4.3 Visualisasi Hasil Deteksi Berdasarkan Tingkat Kepadatan

No	Tingkat Kepadatan	Hasil Deteksi (Visual)	Jumlah Prediksi	Aktual	Kesimpulan
1	Single	  	1 Objek Benar	1 Objek	Berhasil karena dapat mendeteksi 1 objek dari masing masing <i>class</i>

					
2	Low Multi		3 Objek Benar	3 Objek	Berhasil karena dapat mendeteksi 3 objek <i>class</i> Botol, Kopi dan Roti
3	Medium Clutter		8 Objek (Benar)	8 Objek	Berhasil karena dapat mendeteksi 5 objek <i>class</i> Botol (2), Mie (2), Rokok

					(2), Kopi dan Roti
4	High Dense		13 Objek (Benar)	13 Objek	Berhasil karena dapat mendeteksi 5 objek <i>class</i> Botol (3), Mie (3), Rokok (3), Kopi (2) dan Roti (2)
5	Extreme Clutter		21 Objek (Benar)	21 Objek	Berhasil karena dapat mendeteksi 5 objek <i>class</i> Rokok (9), Botol (4), Kopi (3), Mie (3) dan Roti (2)

Hasil visualisasi menunjukkan bahwa model mampu memberikan label dan *bounding box* yang tepat pada berbagai skenario kepadatan objek, termasuk pada objek yang saling berdekatan (*clutter*). Penurunan performa hanya ditemukan pada kondisi objek kecil (rokok) yang terhalang oleh material plastik transparan atau memiliki kemiripan bentuk dengan objek lain (sedotan).

B. Pembahasan

Berdasarkan hasil eksperimen yang telah dipaparkan pada Sub-bab A, bagian ini akan membahas secara mendalam mengenai performa model YOLOv8, keterbatasan sistem pada objek spesifik, serta pengaruh infrastruktur perangkat keras terhadap efisiensi sistem pelaporan logistik.

1. Analisis Akurasi dan Optimalisasi Dataset Multi-Objek

Penelitian ini berhasil mencapai nilai mAP50 sebesar 97,8%. Tingkat akurasi yang tinggi ini didorong oleh penggunaan dataset yang sangat masif, yaitu total 11.211 *instances data training* dari total keseluruhan 13.792 *instances* dalam *dataset*. Sebagai perbandingan, penelitian acuan oleh Visen dan Charibaldi hanya menggunakan total 1.967 *data training* (Visen & Charibaldi, 2025).

Volume data yang jauh lebih besar ini memberikan keunggulan pada kemampuan model YOLOv8 *nano* untuk mendeteksi hingga lebih dari 20 objek secara simultan dalam satu citra tanpa mengalami penurunan akurasi klasifikasi. Temuan ini secara langsung memperbaiki keterbatasan yang ditemukan pada penelitian sebelumnya, yang menyatakan bahwa performa model menurun secara signifikan ketika jumlah objek melebihi sepuluh. Hal ini mengonfirmasi bahwa dengan ketersediaan data *instance* yang melimpah, varian model terkecil sekalipun mampu menangani kondisi kepadatan tinggi (*High Dense* dan *Extreme Clutter*) dengan sangat baik, di mana nilai mAP50 tetap terjaga di atas 95% meskipun jumlah objek dalam satu citra meningkat secara signifikan.


2. Analisis Kasus Spesifik dan Fenomena *False Positive*

Meskipun secara keseluruhan memiliki akurasi tinggi, kelas Rokok tetap menjadi tantangan teknis dengan metrik mAP50-95 sebesar 0,601. Melalui uji kasus, ditemukan fenomena Inter-class Similarity di mana model mengidentifikasi sedotan putih sebagai rokok dengan skor kepercayaan mencapai 0,8 (Gambar 4.5). Kesalahan ini disebabkan oleh kemiripan fitur *geometri silinder* dan warna putih dominan yang identik dengan karakteristik fisik objek rokok.




Gambar 4.5 Kasus *False Positive*: Sedotan Putih Terdeteksi Sebagai Rokok

Selain itu, ditemukan kendala deteksi pada objek yang berada di dalam kemasan plastik transparan. Efek pantulan cahaya (*specular reflection*) pada permukaan plastik sering kali mengaburkan fitur tekstur objek asli sehingga model gagal melakukan lokalisasi jika diambil dari jarak jauh (Gambar 4.6). Namun, kendala ini dapat dimitigasi dengan pengambilan gambar jarak dekat yang memberikan fitur visual lebih tajam (Gambar 4.7).



Gambar 4.6 Kasus *False Negative*: Objek dalam Plastik Gagal Terdeteksi Jarak Jauh



Gambar 4.7 Keberhasilan Deteksi Objek dalam Plastik pada Jarak Dekat

3. Analisis Kompatibilitas Sistem Lintas Infrastruktur Perangkat Keras


Implementasi sistem pada berbagai infrastruktur perangkat keras menghasilkan temuan yang memvalidasi tingkat kompatibilitas dan fleksibilitas tinggi dari arsitektur model YOLOv8 nano yang disebarakan berbasis aplikasi web (*Web App*). Data pada Tabel 4.2 menunjukkan bahwa model terbukti mampu dieksekusi secara universal baik pada ekosistem desktop/laptop (Infinix Inbook X1) maupun ekosistem seluler (iPhone 13) dengan performa inferensi yang sangat responsif, masing-masing mencatatkan waktu rata-rata 61,48 ms dan 72,62 ms.

Keberhasilan enkapsulasi model ke dalam platform web ini memberikan keuntungan portabilitas yang masif, di mana pengguna dapat mengakses sistem pelaporan logistik dari perangkat mana pun tanpa perlu melalui proses instalasi aplikasi secara native. Perbedaan waktu inferensi yang tipis di antara kedua perangkat lokal tersebut—di mana browser laptop sedikit lebih unggul karena optimasi instruksi vektor *Advanced Vector Extensions* (AVX2) pada arsitektur CPU x86-64, sementara browser iOS dibatasi oleh kebijakan akses sistem operasi terhadap *Neural Engine* tidak mengurangi fungsionalitas utama sistem di lapangan.


Dengan rata-rata waktu pemrosesan yang berada jauh di bawah ambang batas interaksi manusia secara real-time (100 ms), eksperimen ini berhasil membuktikan bahwa sistem berbasis YOLOv8n ini sangat adaptif dan kompatibel. Platform ini siap digunakan sebagai infrastruktur pelaporan mandiri yang inklusif, baik bagi pendaki yang menggunakan smartphone di area penanjakan maupun petugas posko yang menggunakan laptop di basis data.

4. Pengaruh Kondisi Lingkungan dan Jarak Deteksi

Daya tahan model pada kondisi pencahayaan redup terbukti sangat dipengaruhi oleh jarak pengambilan gambar. Pada lingkungan minim cahaya dengan jarak kamera yang jauh, model kehilangan kemampuan untuk mengidentifikasi objek (Gambar 4.8). Namun, pada kondisi cahaya yang sama dengan jarak pengambilan yang lebih dekat, model tetap mampu memberikan hasil prediksi yang stabil dengan skor kepercayaan 0,76 (Gambar 4.9).



Gambar 4.8 Kegagalan Deteksi pada Kondisi Redup dan Jarak Jauh



Gambar 4. 9 Keberhasilan Deteksi pada Kondisi Redup dengan Jarak Dekat

Oleh karena itu, instruksi operasional kepada pengguna perlu menekankan pentingnya jarak pengambilan gambar ideal (kurang dari 1 meter) untuk memastikan akurasi tetap terjaga di berbagai kondisi lingkungan pegunungan.

Secara keseluruhan, model YOLOv8 nano yang dilatih dengan dataset masif sebanyak 13.792 *instances* berhasil mencapai performa optimal sebesar 97,8% mAP50. Keberhasilan ini membuktikan reliabilitas sistem dalam menangani tingkat kepadatan objek tinggi, sekaligus mematahkan limitasi deteksi sepuluh objek dari penelitian terdahulu. Meskipun deteksi objek kecil pada kondisi tertentu masih menjadi tantangan, kompatibilitas sistem yang terbukti sangat responsif di berbagai platform (seluler maupun desktop) mengonfirmasi kesiapan model ini sebagai solusi praktis, inklusif, dan efisien bagi pelaporan logistik pendaki di lapangan.

BAB V

PENUTUP

A. Kesimpulan

Arsitektur YOLOv8 varian *nano* telah terbukti mampu memberikan performa yang sangat optimal dalam mendeteksi multi-objek pada *dataset* logistik pendaki. Pengujian evaluasi akhir mencatatkan metrik teknis yang luar biasa, dengan nilai *Precision* mencapai 0,971, *Recall* di angka 0,954, serta *mean Average Precision* (mAP50) sebesar 97,8%. Pencapaian akurasi tingkat tinggi ini sangat dipengaruhi oleh penggunaan volume data latih yang masif, yakni mencapai 13.792 sampel *instances*, dipadukan dengan optimalisasi tahap prapemrosesan citra melalui metode *Stretch to* yang sukses mengeliminasi *noise* spasial pada area tepi gambar.

Terkait dengan dinamika kepadatan visual, variasi jumlah objek di dalam satu citra terbukti tidak memberikan dampak penurunan akurasi yang signifikan terhadap keandalan model. Berbeda dengan temuan pada studi terdahulu yang mengalami degradasi performa ketika mendeteksi lebih dari sepuluh entitas, sistem ini tetap konsisten mempertahankan nilai mAP50 di atas 95% pada berbagai skenario. Stabilitas tersebut terlihat jelas pada setiap tingkatan kepadatan (*clutter level*), mulai dari level *Single* (95,94%), *Medium Clutter* (99,10%), *High Dense* (97,26%), hingga *Extreme Clutter* (96,22%). Adapun anomali penurunan akurasi yang tercatat pada kategori *Low Multi* (77,06%) lebih merepresentasikan sensitivitas statistik akibat keterbatasan jumlah sampel uji, bukan mencerminkan kelemahan fundamental dari kemampuan ekstraksi fitur model.

Meskipun tangguh dalam skenario padat, model ini masih mengalami tingkat penurunan performa atau degradasi yang cukup kentara ketika berhadapan dengan objek berukuran kecil dan kondisi tumpang tindih (*overlap*). Analisis pada metrik mAP50-95 menunjukkan adanya celah performa sekitar 16% hingga 21% antara objek besar seperti botol dan roti dibandingkan dengan objek kecil seperti rokok yang hanya menyentuh angka 0,601. Penurunan presisi kotak deteksi (*bounding box*) pada objek kecil ini dipicu oleh fenomena kemiripan visual antar kelas (*inter-class similarity*), misalnya kesalahan klasifikasi pada sedotan putih, serta

gangguan pantulan cahaya (*glare*) dari material plastik transparan yang menyamarkan tekstur asli barang saat berada di lingkungan minim cahaya. Namun secara keseluruhan, kecepatan inferensi yang sangat responsif dan kompatibel di berbagai perangkat—baik laptop (61,48 ms) maupun telepon seluler (72,62 ms)—mengonfirmasi bahwa purwarupa ini sangat layak untuk diimplementasikan secara langsung di lapangan.

B. Saran

Pengembangan penelitian lebih lanjut disarankan untuk berfokus pada penyelesaian tantangan deteksi objek kecil guna meningkatkan metrik evaluasi secara keseluruhan. Peneliti selanjutnya dapat menerapkan teknik segmentasi citra tingkat lanjut seperti *Slicing Aided Hyper Inference* (SAHI), di mana citra beresolusi tinggi akan dipecah menjadi beberapa bagian kecil selama proses inferensi, sehingga fitur visual objek berskala mikro dapat dianalisis secara lebih presisi oleh model pembaca.

Selain aspek arsitektur kecerdasan buatan, pembaruan pada sisi antarmuka pengguna (*User Interface*) dari aplikasi web juga sangat direkomendasikan. Sistem pelaporan logistik ini akan menjadi jauh lebih ideal apabila dilengkapi dengan fitur panduan waktu nyata (*real-time guidance*). Fitur tersebut nantinya bertugas untuk memberikan peringatan otomatis kepada pendaki agar menjaga jarak pengambilan gambar di bawah satu meter dan memastikan kondisi pencahayaan cukup, yang secara langsung akan meminimalisir risiko kegagalan deteksi akibat kondisi lingkungan yang kurang bersahabat.