

BAB II

TINJAUAN PUSTAKA

2.1 Penelitian yang relevan

Hasil penelitian yang relevan berfungsi untuk memperkuat posisi penelitian yang dilakukan saat ini dengan melihat hasil-hasil penelitian yang sudah dilakukan sebelumnya.

2.1.1 Deteksi Anomali Berbasis Isolation Forest pada Data Spasial

Liu, Ting, dan Zhou memperkenalkan algoritma Isolation Forest sebagai metode pembelajaran tidak terarah untuk deteksi anomali dengan cara mengisolasi data menggunakan pohon acak (F. T. Liu dkk., 2008). Algoritma ini dirancang untuk mendeteksi data yang jarang dan menyimpang tanpa memerlukan label anomali, sehingga cocok digunakan pada data dunia nyata yang tidak terannotasi secara lengkap.

Beberapa penelitian lanjutan mengadopsi Isolation Forest untuk mendeteksi anomali pada data spasial dan trajektori kendaraan. Koetsier dkk menerapkan pendekatan ini pada data pergerakan kendaraan untuk mengidentifikasi pola lintasan yang tidak wajar (Koetsier & others, 2022). Hasil penelitian menunjukkan bahwa Isolation Forest mampu mendeteksi anomali secara sensitif, namun menghasilkan false positive yang relatif tinggi jika digunakan sebagai satu-satunya metode keputusan.

Penelitian-penelitian tersebut menunjukkan bahwa Isolation Forest efektif sebagai mekanisme deteksi awal (early warning), namun masih memerlukan integrasi dengan sumber informasi lain untuk meningkatkan keandalan keputusan. Hal ini sejalan dengan pendekatan penelitian ini yang menggunakan Isolation Forest sebagai salah satu komponen dalam sistem multi-modal.

2.1.2 Analisis Kualitas Visual dan No-Reference Image Quality Assessment

Analisis kualitas visual citra telah banyak diteliti dalam konteks image quality assessment (IQA). Mittal et al. mengusulkan metode BRISQUE, yaitu pendekatan penilaian kualitas citra tanpa referensi (no-reference) yang memanfaatkan statistik alami citra (Mittal dkk., 2012). Pendekatan ini mampu menilai kualitas visual tanpa memerlukan citra pembanding, sehingga relevan untuk kondisi operasional nyata.

Penelitian lain oleh Mittal, Soundararajan, dan Bovik mengembangkan NIQE, yang sepenuhnya tidak memerlukan pelatihan berbasis opini manusia (Mean Opinion Score) (Mittal dkk., 2013). Metode ini menunjukkan bahwa kualitas visual dapat diestimasi secara objektif dari statistik citra.

Meskipun metode IQA tersebut terbukti efektif dalam berbagai konteks, sebagian besar penelitian difokuskan pada penilaian kualitas visual secara umum, bukan sebagai bagian dari sistem deteksi anomali operasional. Dalam penelitian ini, analisis kualitas visual digunakan sebagai salah satu sinyal untuk mendeteksi potensi anomali POD, dan tidak dijadikan sebagai keputusan tunggal.

2.1.3 Deteksi Objek Berbasis Deep Learning untuk Verifikasi Visual

Redmon et al. memperkenalkan algoritma YOLO (You Only Look Once) sebagai pendekatan deteksi objek real-time berbasis deep learning (Redmon dkk., 2016). Pendekatan ini memungkinkan deteksi objek secara efisien dengan satu kali proses inferensi, sehingga banyak digunakan dalam sistem vision berbasis waktu nyata.

Perkembangan terbaru dari keluarga YOLO, seperti YOLOv8, mengadopsi arsitektur anchor-free dan decoupled head untuk meningkatkan stabilitas pelatihan dan fleksibilitas penggunaan (Ultralytics, 2023). Model-model ini telah digunakan dalam berbagai aplikasi industri untuk mendeteksi objek dalam kondisi lingkungan yang beragam.

Namun, sebagian besar penelitian deteksi objek berfokus pada peningkatan akurasi visual semata. Dalam konteks POD, deteksi objek tidak selalu cukup untuk menjamin validitas bukti pengantaran tanpa mempertimbangkan titik lokasi. Oleh karena itu, penelitian ini memanfaatkan deteksi objek sebagai modul pendukung yang dapat diintegrasikan dalam kerangka multi-modal.

2.1.4 Pendekatan Multi-Modal untuk Deteksi Anomali

Pendekatan multi-modal telah banyak dikaji dalam literatur sebagai strategi untuk meningkatkan ketahanan dan kinerja sistem pembelajaran mesin. Integrasi berbagai jenis data memungkinkan sistem memperoleh representasi yang lebih kaya dan komplementer,

sehingga dapat mengurangi ambiguitas yang muncul ketika hanya mengandalkan satu sumber informasi (Baltrušaitis dkk., 2019).

Beberapa penelitian menggabungkan data visual dengan data sensor atau data spasial untuk mendeteksi kejadian tidak normal. Hasil penelitian tersebut menunjukkan bahwa fusion multi-modal mampu mengurangi kelemahan masing-masing modal dan memberikan representasi yang lebih kaya terhadap kondisi dunia nyata.

Penelitian ini mengadopsi prinsip multi-modal tersebut dengan mengintegrasikan kualitas visual foto dan analisis anomali lokasi dalam konteks Proof of Delivery, yang masih relatif jarang dibahas dalam penelitian sebelumnya

2.1.5 Posisi Penelitian terhadap Penelitian Sebelumnya

Penelitian yang relevan ini dilakukan untuk membandingkan penelitian sebelumnya dari jurnal dan paper yang sesuai sebagai referensi topik penelitian untuk memperkuat posisi penelitian ini sendiri. Berikut adalah beberapa contoh penelitian terdahulu tentang topik ini

Tabel 2.1 Perbandingan Penelitian Terkait Deteksi Anomali dan Verifikasi POD

No	Peneliti & Tahun	Domain	Modalitas	Strategi / Metode Utama	Fokus Penelitian	Keterbatasan terhadap Konteks POD
1	(F. T. Liu dkk., 2008)	Data umum	Numerik / Spasial	Isolation Forest (unsupervised anomaly detection)	Deteksi anomali berbasis distribusi data	Tidak mempertimbangkan konteks visual atau verifikasi operasional
2	(Koetsier & others, 2022)	Trajektori kendaraan	Spasial	Isolation Forest + trajectory analysis	Deteksi penyimpangan pola pergerakan	Tidak mengintegrasikan bukti visual pengiriman
3	(Mittal dkk., 2012)	Citra umum	Visual	BRISQUE (No-Reference Image	Penilaian kualitas citra tanpa referensi	Tidak dirancang untuk validasi operasional atau deteksi anomali lokasi

				Quality Assessment)		
4	(Redmon dkk., 2016)	Citra objek umum	Visual	YOLO (Object Detection berbasis CNN)	Deteksi objek secara real-time	Tidak mempertimbangkan kesesuaian lokasi atau konteks spasial
5	(Yi dkk., 2023)	Logistik / Pengiriman	Lokasi (GPS)	Rule-based GPS comparison	Deteksi klaim pengiriman curang	Tidak mengintegrasikan bukti visual dalam validasi
6	(Reshetova dkk., 2023)	Geospasial	Multimodal	Self-supervised multimodal representation	Deteksi anomali geospasial lintas modalitas	Kompleksitas tinggi dan tidak spesifik pada verifikasi POD
7	(Y. Liu dkk., 2025)	Video surveillance	Visual + Lokasi	Cross-attention & dynamic gating fusion	Deteksi perilaku abnormal multimodal	Membutuhkan dataset besar dan tidak fokus konteks logistik operasional
8	Penelitian ini	Proof of Delivery (Logistik)	Visual + Lokasi	Decision-level multi-modal fusion (quality + object detection + anomaly location)	Deteksi anomali POD dan evaluasi kontribusi tiap modalitas melalui ablation study	Precision masih dipengaruhi variasi kualitas data operasional

Berdasarkan Tabel 2.1, terlihat bahwa penelitian terdahulu dalam deteksi anomali dan analisis operasional dapat dikelompokkan ke dalam dua pendekatan utama, yaitu pendekatan berbasis spasial dan pendekatan berbasis visual, serta perkembangan pendekatan multimodal yang mengintegrasikan keduanya. Pengelompokan ini menunjukkan adanya diferensiasi fokus penelitian dalam memahami anomali, baik dari sisi pola pergerakan dan lokasi maupun dari sisi karakteristik visual citra.

Pendekatan spasial, seperti Isolation Forest pada data numerik dan GPS(Koetsier & others, 2022; F. T. Liu dkk., 2008), menitikberatkan pada analisis distribusi jarak, pola

trajektori, dan penyimpangan terhadap pola normal. Metode ini efektif dalam mendeteksi anomali berbasis statistik tanpa memerlukan label, sehingga sesuai untuk data berskala besar dan lingkungan operasional yang dinamis. Studi pada konteks logistik dan deteksi pengiriman curang juga menunjukkan bahwa pembandingan koordinat GPS terhadap lokasi tujuan dapat mengidentifikasi klaim pengiriman yang tidak sesuai (Y. Liu dkk., 2025). Meskipun demikian, pendekatan spasial murni memiliki keterbatasan karena tidak mempertimbangkan bukti visual sebagai representasi kondisi aktual di lapangan. Dalam konteks Proof of Delivery (POD), kesesuaian lokasi saja belum menjamin bahwa proses pengantaran telah dilakukan sesuai prosedur, karena foto dapat diambil tanpa memperlihatkan paket, dalam kondisi buram, atau tidak merepresentasikan proses penyerahan yang sah.

Sebaliknya, pendekatan berbasis visual berfokus pada analisis citra untuk memahami konten dan kualitas bukti visual. Penelitian mengenai no-reference image quality assessment seperti BRISQUE (Mittal dkk., 2012) menunjukkan bahwa kualitas citra dapat dinilai tanpa referensi pembandingan, sehingga memungkinkan deteksi kondisi buram atau degradasi visual. Selain itu, perkembangan deep learning dalam deteksi objek, seperti YOLO (Redmon dkk., 2016), memungkinkan identifikasi objek secara real-time dengan akurasi tinggi. Dalam konteks pengiriman, pendekatan visual juga digunakan untuk meningkatkan akurasi validasi lokasi melalui pengenalan marker visual atau deteksi target tertentu (Nugraha & Abidin, 2025; Vadduri dkk., 2023). Meskipun mampu meningkatkan validasi berbasis citra, pendekatan visual murni tetap tidak mengevaluasi kesesuaian spasial antara lokasi pengambilan citra dan alamat tujuan, sehingga berpotensi menghasilkan validasi parsial yang tidak mencerminkan kondisi operasional secara menyeluruh.

Perkembangan lebih lanjut menunjukkan adanya upaya integrasi multimodal melalui pembelajaran representasi lintas modalitas. Pendekatan seperti self-supervised multimodal anomaly detection (Reshetova dkk., 2023) dan integrasi fitur berbasis cross-attention dengan dynamic gating (Y. Liu dkk., 2025) menunjukkan bahwa representasi bersama dari data visual dan spasial dapat meningkatkan sensitivitas sistem terhadap ketidaksesuaian antar modalitas. Pendekatan ini secara konseptual lebih komprehensif karena mampu memodelkan korelasi lintas sumber informasi. Namun demikian, sebagian

besar penelitian tersebut dikembangkan dalam domain geospasial skala besar atau video surveillance dengan kompleksitas model yang tinggi, kebutuhan komputasi besar, dan dataset multimodal yang terkurasi secara ekstensif. Implementasi pendekatan tersebut dalam konteks operasional Proof of Delivery yang bersifat industri dan memiliki keterbatasan label serta variasi kualitas data belum banyak dilaporkan secara eksplisit.

Pola umum yang dapat disimpulkan dari literatur tersebut adalah bahwa penelitian terdahulu cenderung mengembangkan metode secara single-modal atau mengadopsi pendekatan multimodal kompleks pada domain umum. Belum banyak penelitian yang secara spesifik mengintegrasikan analisis kualitas citra dan anomali lokasi dalam satu kerangka sistem yang dirancang untuk kebutuhan verifikasi operasional Proof of Delivery. Dalam praktik operasional logistik, validasi POD menuntut kombinasi antara bukti visual yang representatif dan kesesuaian lokasi yang akurat. Dengan demikian, masing-masing pendekatan terdahulu umumnya hanya merepresentasikan sebagian aspek validasi operasional dan belum sepenuhnya mengakomodasi kebutuhan sistem verifikasi multimodal yang aplikatif.

Selain itu, aspek evaluasi eksperimental juga menunjukkan kesenjangan. Ablation study, yang bertujuan untuk mengukur kontribusi masing-masing komponen sistem terhadap peningkatan performa, masih jarang diterapkan dalam konteks sistem operasional logistik berbasis deteksi anomali POD. Banyak penelitian berfokus pada peningkatan akurasi atau performa teknis model secara keseluruhan, tanpa menganalisis secara eksplisit kontribusi setiap modalitas terhadap precision dan recall. Padahal, dalam sistem operasional logistik, trade-off antara precision dan recall memiliki implikasi langsung terhadap beban verifikasi manual dan risiko anomali yang terlewat. Sistem dengan recall tinggi namun precision rendah dapat meningkatkan beban kerja verifikasi, sedangkan precision tinggi dengan recall rendah berpotensi melewatkan anomali penting. Oleh karena itu, evaluasi berbasis precision–recall trade-off menjadi aspek krusial dalam konteks aplikasi nyata.

Berdasarkan kesenjangan tersebut, penelitian ini memposisikan diri sebagai upaya integratif yang mengembangkan sistem deteksi anomali berbasis multi-modal dengan menggabungkan analisis kualitas citra dan anomali lokasi dalam konteks Proof of Delivery. Berbeda dengan pendekatan single-modal yang hanya mengevaluasi satu aspek validasi, serta berbeda pula dengan pendekatan multimodal kompleks berbasis

representasi tingkat lanjut, penelitian ini mengadopsi strategi integrasi yang lebih implementatif melalui decision-level fusion. Pendekatan ini memungkinkan penggabungan skor dari masing-masing modalitas secara terstruktur dan transparan, sehingga sesuai dengan kebutuhan operasional industri logistik.

Dengan demikian, kontribusi penelitian ini terletak pada:

1. Pengembangan model evaluasi berbasis precision–recall trade-off yang secara eksplisit mempertimbangkan implikasi operasional dalam sistem verifikasi POD.
2. Evaluasi sistematis terhadap pendekatan single-modal dan multi-modal dalam satu kerangka eksperimen terkontrol melalui ablation study.
3. Analisis kuantitatif trade-off antara precision dan recall yang dikaitkan langsung dengan kebutuhan operasional logistik, khususnya dalam konteks penyaringan awal (pre-filter) anomali POD.

2.2 Landasan Teori

2.2.1 Proof of Delivery dalam Sistem Logistik

Proof of delivery (PoD) adalah bentuk tanda terima pengiriman yang menegaskan penerima barang telah menerima barang yang benar. Tanda terima ini, atau tagihan konfirmasi, digunakan ketika penerima barang ingin mengembalikan barang, atau mengajukan klaim kerusakan. Dalam bentuk POD yang paling dasar, pengemudi pengiriman akan mengumpulkan tanda tangan dari penerima, dengan tanggal dan waktu ketika penerima menerima paketnya. Bukti pengiriman idealnya juga menyertakan alamat penerima dan deskripsi paket atau barang.

Gambar 2.1 Contoh POD Elektronik

Steven Clarke	
Reference ID:	D353848474
Quantity:	1
Window:	11:25am - 2:30pm
Duration:	5 mins
Planned Arrival:	11:25
Completed Time:	Jan 22, 2021 11:42 AM
Received By:	S. Clarke
Dispatched Notes:	Leave the package at the reception even if no one present and record photo POD
Driver Notes:	Met secretary in her way to lunch and left package with her.



Sebagai istilah industri, proses POD berlaku untuk pengiriman kargo dan kargo. Di sini kita akan meninjau manfaat, kegunaan, dan fitur POD untuk pengiriman barang seperti komoditas dan barang dagangan.

POD memiliki peran strategis sebagai dasar kepercayaan antara perusahaan logistik dan pelanggan, serta sebagai bahan evaluasi internal terhadap kepatuhan SOP dan performa kurir (Bowersox dkk., 2013). Ketidaksesuaian atau manipulasi bukti POD dapat berdampak pada meningkatnya komplain pelanggan, kesulitan audit, serta menurunnya kualitas layanan.

Dengan memantau kondisi fisik produk POD:

1. Memastikan penerima yang tepat menerima barang dari pengirim yang tepat (sangat penting jika pembeli bukan penerima barang)
2. Dapat mengidentifikasi kapan dan di mana terjadi kesalahan dalam hal pengiriman yang terlewat atau klaim kerusakan (misalnya paket dikirim dengan kerusakan atau dalam kondisi buruk)
3. Membantu menyelesaikan sengketa klaim pengiriman, terutama dengan transaksi e-commerce

Biasanya pengemudi atau kurir menunjukkan dokumen pengiriman untuk disetujui oleh penerima, dengan tanda tangan ini yang menyatakan bahwa semua barang kiriman yang diharapkan ada dan tidak rusak. Bukti pengiriman ini memberi penjual dokumentasi yang diperlukan untuk memverifikasi pemenuhan pesanan dan akurasi faktur.

2.2.2 Machine Learning

Machine Learning adalah cabang dari kecerdasan buatan yang memungkinkan komputer belajar dari data tanpa secara eksplisit deprogram (Mitchell, 1997). Dalam Machine learning, algoritma dan model statistik digunakan untuk menganalisis data dan menemukan pola atau hubungan yang berguna, yang kemudian digunakan untuk membuat prediksi atau mengambil keputusan. Ada tiga jenis Machine learning diantaranya supervised learning, unsupervised learning dan reinforcement learning (Alzubi dkk., 2018).

2.2.2.1 Supervised Learning

Supervised learning adalah jenis pembelajaran di mana model mempelajari hubungan antara input dan output yang telah diberikan. Dalam supervised learning, data latih terdiri dari pasangan input-output. Model belajar untuk memetakan input ke output yang tepat (Alzubi dkk., 2018). Tujuan dari supervised learning adalah untuk mempelajari pola atau aturan yang dapat digunakan untuk memprediksi output yang benar untuk input yang belum pernah dilihat sebelumnya. Contoh aplikasi Supervised Learning adalah klasifikasi dan regresi (Widaningsih, 2019).

2.2.2.2 Unsupervised Learning

Supervised Unsupervised learning adalah jenis pembelajaran di mana model mempelajari struktur dari data tanpa bantuan dari output yang benar. Dalam unsupervised learning, data latih terdiri dari input tanpa output yang benar. Model belajar untuk menemukan pola atau struktur dari data (Alzubi dkk., 2018). Tujuan dari Unsupervised Learning adalah untuk menemukan struktur atau grup dalam data yang dapat membantu pemahaman terhadap data tersebut (Widaningsih, 2019). Contoh aplikasi Unsupervised Learning adalah clustering dan reduksi dimensi.

2.2.3 Deep Learning

Deep Learning atau Pembelajaran Dalam adalah salah satu cabang dari Machine Learning yang memanfaatkan Jaringan Syaraf Tiruan untuk mengimplementasikan permasalahan dengan dataset yang besar. Teknik Deep Learning memberikan arsitektur yang sangat kuat untuk Supervised learning. Model pembelajaran dapat dengan menambah lapisan lebih banyak dapat mewakili data citra berlabel yang lebih baik. Deep Learning banyak digunakan pada komunitas penelitian dan industry dalam membantu pemecahan masalah dengan data yang besar seperti Computer Vision, Speech Recognition, dan Natural Language Processing (Nurhikmat, 2018)

2.2.4 Isolation Forest

Isolation Forest merupakan algoritma deteksi anomali berbasis pembelajaran tidak terarah yang bekerja dengan cara mengisolasi observasi melalui pembentukan pohon acak (F. T. Liu dkk., 2008). Observasi yang lebih mudah terisolasi dianggap sebagai anomali.

Keunggulan Isolation Forest antara lain:

1. Tidak memerlukan label anomali,
2. Efisien untuk dataset berukuran besar
3. Mampu menangani distribusi data yang kompleks.

Beberapa penelitian menunjukkan bahwa Isolation Forest efektif digunakan untuk mendeteksi anomali pada data spasial dan trajektori kendaraan (Oktay & others, 2021). Namun, algoritma ini cenderung menghasilkan tingkat false positive yang tinggi jika digunakan secara tunggal, sehingga memerlukan integrasi dengan sumber informasi lain.

2.2.5 Object Detection dan YOLO


Deteksi objek merupakan salah satu cabang utama computer vision yang bertujuan untuk mengidentifikasi dan menentukan lokasi objek tertentu dalam sebuah citra. Model berbasis deep learning, khususnya keluarga YOLO (You Only Look Once), telah banyak digunakan karena efisiensi dan kemampuannya dalam melakukan deteksi secara real-time (Redmon dkk., 2016).




YOLOv8 merupakan generasi terbaru dari keluarga YOLO yang mengadopsi arsitektur anchor-free dan decoupled head, sehingga menawarkan performa yang lebih stabil dan fleksibel (Ultralytics, 2023). Dalam konteks POD, deteksi objek dapat digunakan untuk memastikan keberadaan paket dalam foto sebagai bukti visual tambahan.


2.2.6 Flowchart

Flowchart adalah alat visual yang merepresentasikan alur kerja atau proses dalam bentuk diagram, sering digunakan dalam pemrograman dan sistem untuk merencanakan, menganalisis, dan memahami langkah-langkah penyelesaian suatu tugas. Flowchart terdiri dari berbagai simbol dengan fungsi spesifik, seperti oval untuk awal/akhir proses, persegi panjang untuk langkah atau tindakan, diamond untuk pengambilan keputusan, paralelogram untuk input/output data, dan panah sebagai penghubung alur. Simbol-simbol ini mempermudah pemahaman alur logika yang terstruktur dan terorganisasi. Fungsi utama flowchart meliputi perencanaan proses, analisis algoritma, memfasilitasi komunikasi antara pengguna dan pembuat sistem, serta mempercepat identifikasi dan perbaikan kesalahan dalam program. Sebagai alat perancangan yang efektif, flowchart mempermudah penjelasan dan pemahaman alur kerja kepada berbagai pihak yang terlibat (Cahyaningtyas dkk., 2025)

Tabel 2.2 Flowchart Simbol-simbol

Simbol	Nama	Keterangan
	Terminal	Simbol untuk menunjukkan awal, akhir dan pemberhentian dalam suatu proses atau program.
	Proses manual	Simbol yang menunjukkan pengolahan yang dilakukan secara manual.
	Proses dengan komputer	Simbol yang menunjukkan pengolahan yang dilakukan dengan komputer.

	Arus dokumen atau proses	Simbol untuk menunjukkan arah aliran dokumen atau proses.
	On-page connector	Simbol untuk menggambarkan proses pada halaman yang sama.
	Off-page connector	Simbol untuk menggambarkan proses pada halaman yang berbeda.
	Keputusan	Simbol untuk kondisi yang menggambarkan langkah pengambilan keputusan.
	On-line keying	Simbol yang menyatakan input dengan menggunakan mesin yang mempunyai keyboard.
	Dokumen	Simbol yang menyatakan input berasal dari dokumen dalam bentuk tulisan tangan atau output dicetak dengan komputer.
	Beberapa tembusan dari satu dokumen	Simbol yang menyatakan dokumen yang sama dicetak beberapa kali dengan computer.
	Input / Output	Simbol yang menyatakan proses input dan output di dalam bagan alir program.

	Penyimpanan online	Simbol yang menggambarkan data yang disimpan dalam file online yang dapat diakses secara langsung, seperti disk
	Tampilan	Simbol yang menyatakan peralatan output yang digunakan yaitu layer, monitor dan sebagainya.

2.2.7 Python

Bahasa Program Python yaitu bahasa pemrograman yang sanggup dengan cara langsung (interpretatif) melaksanakan serangkaian instruksi tujuan umum memanfaatkan metode berorientasi objek (pemrograman berorientasi objek) serta memakai semantik dinamis buat menentukan keterbacaan sintaks. Yang lain menginterpretasikan bahasa program Python sebagai bahasa yang kemampuan dengan cara kemampuan baik penulisan kode yang sungguh jelas, dan juga memiliki pustaka standar yang dikembangkan para programmer Python dan juga komprehensif.

Python adalah bahasa pemrograman yang sederhana untuk dipelajari dan dipahami, dibangun untuk dikembangkan agar mudah dikuasai. Bahasa pemrograman Python sangat menarik, dan penting untuk mempelajari. Kedua, bahasa pemrograman Python dirancang dengan cara langsung yang nyaman untuk dipahami oleh kebanyakan orang. Bahasa Python memiliki memori dan struktur penyimpanan yang dikendalikan secara dinamis. Tidak hanya itu, dalam bahasa pemrograman Python, aplikasi mendapatkan perubahan secara berkala. Apalagi bahasa pemrograman Python memiliki beberapa fasilitas pendukung yang penting. Berbagai sistem operasi termasuk Debian, Windows, Mac OS, Android, Symbian OS, Amiga dan Palm juga biasanya menggunakan python (Munthe dkk., 2021)

2.2.8 Google Collab

Layanan berbasis cloud Google Research, Google Colaboratory, atau Colab, memungkinkan pengguna menulis dan menjalankan kode Python langsung melalui browser. Colab dirancang khusus untuk mendukung aktivitas pembelajaran mesin

(machine learning), analisis data, dan pendidikan, serta sangat membantu dalam penelitian yang membutuhkan daya komputasi besar. Colab memberikan solusi bagi pengguna yang tidak memiliki perangkat keras dengan kapasitas komputasi yang memadai, seperti GPU (Graphics Processing Unit) atau TPU (Tensor Processing Unit), dengan menyediakan akses gratis ke sumber daya komputasi tersebut. Selain itu, Colab dibangun di atas platform Jupyter Notebook, yang merupakan lingkungan interaktif populer untuk pengembangan berbasis Python.

Pengguna tidak perlu melakukan instalasi atau konfigurasi lingkungan secara manual, karena berbagai pustaka penting seperti TensorFlow, Keras, PyTorch, Numpy, Scipy, Pandas, dan Scikit-learn sudah tersedia secara pre-instal. Kemudahan ini memungkinkan peneliti dan praktisi untuk fokus pada pengembangan model tanpa terganggu oleh kendala teknis terkait instalasi perangkat lunak. Colab juga mendukung kolaborasi secara real time, di mana notebook dapat dibagikan antar anggota tim seperti halnya dokumen di Google Docs.

Fitur ini memudahkan peneliti untuk berkolaborasi dalam proyek yang sama tanpa perlu khawatir tentang sinkronisasi data atau konfigurasi perangkat. Selain itu, Colab memungkinkan eksekusi perintah bash langsung dari notebook, memberikan fleksibilitas tambahan dalam pengelolaan lingkungan komputasi. Secara keseluruhan, Google Colab menjadi pilihan ideal bagi para peneliti yang memerlukan platform komputasi berbasis cloud untuk mendukung riset dan eksperimen tempat pembelajaran mesin serta kecerdasan buatan.(Naik dkk., 2022).

2.2.9 Deteksi Anomali (Anomaly Detection)

Deteksi anomali adalah proses identifikasi pola atau observasi yang menyimpang secara signifikan dari mayoritas data lainnya. Anomali sering kali berkaitan dengan kejadian yang jarang terjadi, kesalahan sistem, atau perilaku tidak wajar(Chandola dkk., 2009).

Pendekatan deteksi anomali secara umum dapat dikategorikan menjadi tiga jenis utama:

1. Pendekatan berbasis threshold
2. Pendekatan berbasis pembelajaran terawasi (supervised), dan

3. Pendekatan berbasis pembelajaran tidak terarah (unsupervised).

Dalam konteks data operasional logistik, ketersediaan label anomali yang terbatas membuat pendekatan pembelajaran tidak terarah menjadi lebih relevan.

2.2.10 Global Positioning System (GPS)

GPS atau Global Positioning System, merupakan sebuah alat atau sistem yang dapat digunakan untuk menginformasikan penggunaanya dimana lokasinya berada (secara global) di permukaan bumi yang berbasis satelit. Data dikirim dari satelit berupa sinyal radio dengan data digital. Dimanapun pengguna tersebut berada, maka GPS bisa membantu menunjukkan arah. Layanan GPS ini tersedia gratis (Mahdia & Noviyanto, 2013).

Data spasial geografis, seperti koordinat lintang dan bujur (latitude–longitude), banyak digunakan untuk memantau pergerakan dan aktivitas kendaraan atau kurir. Namun, variasi kondisi lapangan menyebabkan data spasial memiliki karakteristik yang kompleks dan tidak selalu mengikuti pola linier.

2.2.10.1 Ambang batas Jarak (Distance Threshold)

Pendekatan paling sederhana dalam mendeteksi anomali lokasi adalah dengan menggunakan ambang batas jarak tertentu antara titik aktual dan titik referensi. Meskipun mudah diimplementasikan, pendekatan ini memiliki keterbatasan signifikan karena tidak mampu menangkap variasi konteks operasional yang sah, seperti perbedaan akses lokasi atau kebijakan penempatan barang (Koetsier & others, 2022).

Pendekatan berbasis threshold cenderung menghasilkan false positive atau false negative yang tinggi ketika diterapkan pada data dunia nyata dengan distribusi yang heterogen.

2.2.11 Analisis Kualitas Visual Citra

Kualitas visual citra merupakan aspek penting dalam sistem berbasis pengolahan citra, terutama ketika citra digunakan sebagai bukti atau dasar pengambilan keputusan. Pada konteks POD, kualitas visual yang rendah, seperti blur atau pencahayaan buruk, dapat mengurangi keandalan bukti pengantaran.

2.2.11.1 Computer Vision Classic

Pendekatan klasik dalam analisis kualitas citra sering kali menggunakan fitur statistik sederhana, seperti variansi Laplacian, untuk mendeteksi blur pada citra (Ferzli & Karam, 2009). Metode ini bersifat ringan dan mudah diimplementasikan, namun hanya mampu menangkap aspek kualitas visual tertentu.

Meskipun sederhana, pendekatan ini masih relevan sebagai baseline dalam sistem analisis citra, terutama ketika keterbatasan data atau sumber daya komputasi menjadi pertimbangan.

2.2.11.2 No-Reference Image Quality Assessment (NR-IQA)

Pendekatan No-Reference Image Quality Assessment (NR-IQA) bertujuan menilai kualitas citra tanpa memerlukan citra referensi. Metode seperti BRISQUE dan NIQE menggunakan fitur statistik alami citra untuk mengestimasi tingkat kualitas visual (Mittal dkk., 2012, 2013).

Pendekatan NR-IQA lebih fleksibel dibandingkan metode klasik, namun sering kali memerlukan penyesuaian tambahan agar sesuai dengan konteks operasional tertentu, seperti foto POD yang memiliki variasi kondisi lingkungan yang tinggi.

2.2.12 Multi-Modal dan Fusion

Dalam konteks deteksi anomali, penggabungan beberapa modal—seperti informasi visual dan spasial—berpotensi meningkatkan kemampuan sistem dalam mengidentifikasi pola yang tidak wajar. Kombinasi sumber data yang saling melengkapi dapat meningkatkan sensitivitas terhadap anomali sekaligus menjaga stabilitas sistem terhadap variasi kondisi operasional, dibandingkan pendekatan single-modal yang lebih rentan terhadap keterbatasan masing-masing modal (Baltrušaitis dkk., 2019).

Fusion multi-modal dapat dilakukan pada berbagai tingkat, seperti:

1. Data-level fusion,
2. Feature-level fusion, dan
3. Decision-level fusion.

Dalam penelitian ini, fusion dilakukan pada tingkat keputusan (decision-level fusion) dengan menggabungkan skor dari masing-masing modul. Pendekatan ini dipilih karena fleksibel dan memungkinkan penyesuaian bobot sesuai dengan kebutuhan operasional.

2.2.13 Evaluasi Model

Evaluasi model merupakan tahapan penting dalam penelitian machine learning untuk mengukur kinerja sistem dalam melakukan klasifikasi atau deteksi. Dalam permasalahan deteksi anomali, pemilihan metrik evaluasi harus mempertimbangkan karakteristik data dan konsekuensi kesalahan klasifikasi (Chandola dkk., 2009). Oleh karena itu, penelitian ini menggunakan metrik precision, recall, F1-score, dan Area Under Curve (AUC) untuk memberikan gambaran performa model secara komprehensif.

Dalam konteks deteksi anomali Proof of Delivery, evaluasi model tidak hanya berfokus pada akurasi, tetapi juga pada kemampuan sistem dalam meminimalkan kesalahan klasifikasi yang dapat berdampak pada proses verifikasi operasional. Oleh karena itu, penelitian ini menggunakan beberapa metrik evaluasi yang umum digunakan dalam klasifikasi biner dan deteksi anomali, yaitu precision, recall, F1-score, dan Area Under Curve (AUC).

2.2.13.1 Precision

Precision mengukur proporsi prediksi positif yang benar terhadap seluruh prediksi positif yang dihasilkan model. Metrik ini penting untuk menilai tingkat false positive yang dihasilkan sistem. Precision banyak digunakan dalam evaluasi klasifikasi biner, terutama pada kondisi data tidak seimbang (Powers, 2011). Precision mengukur proporsi prediksi positif yang benar terhadap seluruh prediksi positif yang dihasilkan oleh model. Metrik ini penting untuk menilai tingkat kesalahan positif (false positive) yang dihasilkan sistem. Secara matematis, precision dirumuskan sebagai:

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}}$$

dimana TP adalah true positive dan FP adalah false positive (Chandola dkk., 2009).

Dalam konteks operasional logistik, precision berkaitan dengan seberapa banyak data yang ditandai sebagai anomali benar-benar merupakan anomali.

2.2.13.2 Recall

Recall mengukur proporsi data positif yang berhasil terdeteksi oleh model terhadap seluruh data positif yang sebenarnya ada. Dalam konteks deteksi anomali, recall menjadi metrik yang penting karena berkaitan dengan kemampuan sistem dalam meminimalkan kasus anomali yang terlewat (Chandola dkk., 2009). Recall mengukur proporsi data positif yang berhasil terdeteksi oleh model terhadap seluruh data positif yang sebenarnya ada. Recall dirumuskan sebagai:

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}}$$

dimana FN adalah false negative (Chandola dkk., 2009).

Dalam sistem deteksi anomali, recall menjadi metrik yang penting karena menunjukkan kemampuan sistem dalam mendeteksi seluruh potensi anomali, sehingga meminimalkan risiko kasus terlewat.

2.2.13.3 F1-Score

F1-score merupakan rata-rata harmonik antara precision dan recall yang digunakan untuk menyeimbangkan kedua metrik tersebut. F1-score sangat relevan pada kasus klasifikasi dengan distribusi kelas yang tidak seimbang (Powers, 2011).

F1-score merupakan rata-rata harmonik dari precision dan recall yang digunakan untuk menyeimbangkan kedua metrik tersebut, terutama pada kondisi data tidak seimbang (imbalanced data). F1-score dirumuskan sebagai:

$$\text{F1} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

Metrik ini umum digunakan dalam evaluasi klasifikasi biner untuk memberikan gambaran performa yang lebih seimbang antara precision dan recall (Chandola dkk., 2009).

2.2.13.4 Area Under Curve (AUC)

AUC dihitung berdasarkan kurva Receiver Operating Characteristic (ROC), yang menggambarkan hubungan antara true positive rate dan false positive rate. AUC digunakan untuk mengevaluasi kemampuan model dalam membedakan antara kelas positif dan negatif secara keseluruhan. Interpretasi dan penggunaan ROC-AUC dalam evaluasi model dijelaskan secara komprehensif oleh (Fawcett, 2006).

Area Under Curve (AUC) merupakan metrik evaluasi yang mengukur kemampuan model dalam membedakan antara kelas positif dan negatif secara keseluruhan. AUC dihitung berdasarkan kurva Receiver Operating Characteristic (ROC), yang menggambarkan hubungan antara true positive rate dan false positive rate. Nilai AUC yang mendekati 1 menunjukkan kemampuan diskriminasi model yang baik, sedangkan nilai mendekati 0,5 menunjukkan performa yang setara dengan tebakan acak (Chandola dkk., 2009).

Tabel 2.3 Kategori Dari Hasil Nilai AUC

Nilai AUC	Kategori
0.90 – 1.00	Excellent classification
0.80 – 0.90	Good classification
0.70 – 0.80	Fair classification
0.60 – 0.50	Poor classification
0.50 – 0.60	Failure classification

2.2.13.5 Ablation Study

Ablation study merupakan metode evaluasi yang digunakan untuk menganalisis kontribusi masing-masing komponen dalam suatu sistem dengan membandingkan performa ketika komponen digunakan secara terpisah maupun ketika digabungkan. Pendekatan ini umum digunakan dalam penelitian machine learning untuk mengidentifikasi pengaruh setiap modul terhadap kinerja sistem secara keseluruhan.

Dalam penelitian ini, ablation study dilakukan dengan membandingkan pendekatan single-modal dan multi-modal untuk mengevaluasi kontribusi integrasi informasi visual dan lokasi terhadap peningkatan performa deteksi anomali Proof of Delivery.