



PENGEMBANGAN SISTEM PEMILAHAN SAMPAH DENGAN MANAJEMEN TERINTEGRASI MENGUNAKAN MEKANISME PENALARAN KONTEKSTUAL BERBASIS *VISUAL UNDERSTANDING* DAN *GENERATIVE AI*

Fadhil Mujahid¹, Syafrijon², Yasdinul Huda³, Randi Proska Sandra⁴

¹Program Studi Informatika, Fakultas Teknik, Universitas Negeri Padang, Indonesia

^{2,3,4}Universitas Negeri Padang, Indonesia

Correspondence: E-mail: syafrijon@ft.unp.ac.id

ABSTRACT

Modern waste management requires innovative digital solutions to increase community participation and material quality. This research develops a hybrid AI ecosystem for a mobile-based Smart Bank Sampah platform, integrating YOLOv8 Nano for real-time edge detection and Llama-3.1-8B-Instant for cloud-based cognitive reasoning. Unlike traditional systems, this framework converts visual data into personalized educational instructions, ensuring waste is properly prepared before transaction. Results show that the YOLOv8 model achieves a mAP50 of 95.4% with a rapid inference time of 15–25ms on mobile devices. The system successfully generates structured contextual guidance, validated by a 100% success rate in functional Black Box testing. Furthermore, usability testing via the System Usability Scale (SUS) yielded a score of 92.17, placing the application in the Best Imaginable (Grade A) category. This study demonstrates that combining Computer Vision and Large Language Models (LLMs) significantly improves administrative transparency and environmental literacy, providing a robust infrastructure for a sustainable circular economy.

© 2026 Kantor Jurnal dan Publikasi UPI

ARTICLE INFO

Article History:

Submitted/Received 1 May 2026

First Revised 2 May 2026

Accepted 4 May 2026

First Available online 5 May 2026

Publication Date 5 May 2026

Keyword:

Circular Economy,

Edge Computing, Large

Language Models, Smart Waste

Management, YOLOv8

1. PENDAHULUAN

Masalah sampah telah bertransformasi menjadi krisis global yang semakin kompleks seiring dengan laju urbanisasi yang pesat dan dominasi model ekonomi linier berbasis konsumsi-pembuangan. Laporan *UNEP World Waste Outlook 2024* memproyeksikan timbunan sampah padat perkotaan dunia akan mencapai 3,8 miliar ton pada tahun 2050. Fenomena ini juga menjadi kendala serius di Indonesia, di mana data Sistem Informasi Pengelolaan Sampah Nasional (SIPSN) KLHK menunjukkan bahwa sekitar 68% timbunan sampah nasional masuk dalam kategori tidak terkelola (*unmanaged waste*) (Zahrah et al., 2024). Tingginya angka tersebut berakar dari paradigma tradisional *kumpul-angkut-buang* yang mengabaikan pemilahan di tingkat hulu, sehingga material yang seharusnya bernilai ekonomi justru berakhir sebagai residu di Tempat Pembuangan Akhir (TPA)

Pendekatan ekonomi sirkular pada tingkat regional, khususnya Kota Padang, menjadi landasan pengelolaan sampah yang mengandalkan dua pilar utama: Bank Sampah untuk material daur ulang berkualitas tinggi, serta pemanfaatan *Refuse Derived Fuel* (RDF) oleh PT Semen Padang melalui program Nabuang Sarok (Pradana et al., 2023). Namun, efektivitas kedua jalur ini sangat bergantung pada kualitas fisik sampah, seperti tingkat kebersihan dan kadar air. Fakta di lapangan menunjukkan adanya inefisiensi signifikan dalam manajemen operasional Bank Sampah yang disebabkan oleh pencatatan administrasi manual berbasis kertas yang rentan terhadap kesalahan rekapitulasi. Selain itu, terdapat kendala subjektivitas yang tinggi dalam penilaian mutu sampah antara nasabah dan petugas, karena tidak adanya standar baku visual dalam menilai apakah sampah tersebut tergolong bersih, kering, atau terkontaminasi (Fitri et al., 2024). Kondisi ini diperparah oleh rendahnya literasi masyarakat yang umumnya hanya mengetahui jenis material tanpa memahami konteks penanganan fisik yang diperlukan agar sampah layak disetor.

Kemajuan teknologi *Computer Vision* telah membuka peluang besar dalam otomatisasi pemilahan sampah (Chai et al., 2021). Penelitian terdahulu oleh Arvio et al. (2024) serta Putra dan Hidayat (2024) berhasil mengimplementasikan deteksi objek sampah dengan akurasi tinggi menggunakan algoritma YOLOv8 dan CNN. Namun, sistem yang dihasilkan umumnya masih bersifat statis dan terbatas pada pelabelan kelas kategorikal (*labeling only*) tanpa memberikan konteks tindak lanjut bagi pengguna (Diwan et al., 2023). Di sisi lain, pemanfaatan *Generative AI* dalam edukasi lingkungan, sebagaimana diteliti oleh Zhang et al. (2024), menunjukkan potensi besar dalam memberikan penjelasan personal, namun pendekatan berbasis teks murni berisiko menghasilkan rekomendasi yang tidak akurat karena tidak memiliki kemampuan persepsi visual terhadap objek riil (Zhang et al., 2024).

Berdasarkan kesenjangan tersebut, penelitian ini mengusulkan sebuah mekanisme Penalaran Kontekstual Hibrida (*Hybrid Contextual Reasoning*) yang mengintegrasikan kemampuan *Visual Understanding* dan *Generative AI* dalam satu ekosistem terpadu. Kebaruan penelitian ini terletak pada kolaborasi arsitektur *Edge-Cloud*, di mana algoritma YOLOv8 Nano bertindak sebagai *mata* sistem untuk deteksi objek secara lokal guna menjamin responsivitas tinggi (Terven & Cordova-Esparza, 2023), sedangkan Llama-3.1-8B-Instant berperan sebagai *otak penalaran* di sisi *cloud* untuk memberikan instruksi pengelolaan yang spesifik berdasarkan kondisi fisik sampah yang dideteksi. Melalui implementasi alur validasi bertingkat (*AI-Assisted Human Validation*), sistem ini bertujuan tidak hanya untuk mendigitalisasi siklus penyetoran sampah secara transparan, tetapi juga untuk

mentransformasi aplikasi dari alat deteksi pasif menjadi asisten keputusan cerdas yang aktif membimbing perilaku nasabah.

2. METODOLOGI

Penelitian ini menerapkan pendekatan rekayasa perangkat lunak sistematis yang mengintegrasikan disiplin *Artificial Intelligence* (AI) dengan pengembangan aplikasi *mobile* untuk menyelesaikan problematika pengelolaan sampah (Diansyah & Syafrinal, 2025). Metodologi ini dirancang secara komprehensif untuk memastikan validitas deteksi visual pada sisi perangkat (*edge*) dan keakuratan penalaran kontekstual pada sisi peladen (*cloud*).

2.1. Model Pengembangan Sistem

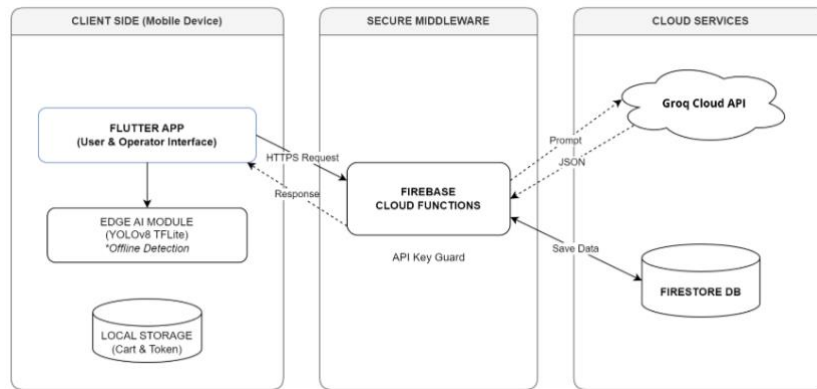
Implementasi sistem Bank Sampah Pintar menggunakan metode pengembangan *Prototype Model*. Pemilihan metode ini didasarkan pada kompleksitas integrasi teknologi hibrida (YOLOv8 dan LLM) yang memiliki tingkat ketidakpastian *output* tinggi (Aurpa et al., 2021), sehingga memerlukan validasi bertahap. Berdasarkan teori Roger S. Pressman, metodologi ini dijalankan melalui lima tahap iteratif sebagai berikut:

1. *Communication*: Peneliti melakukan identifikasi masalah dan ekstraksi kebutuhan fungsional melalui observasi standar operasional bank sampah konvensional.
2. *Quick Plan*: Perancangan arsitektur global yang menitikberatkan pada distribusi beban kerja antara perangkat lokal dan server.
3. *Modeling Quick Design*: Tahap pembuatan desain antarmuka (*mock-up*) dan perancangan struktur *prompt engineering*.
4. *Construction of Prototype*: Realisasi teknis melalui penulisan kode program, pelatihan model deep learning, dan integrasi API.
5. *Deployment, Delivery & Feedback*: Tahap uji coba langsung menggunakan sampel sampah nyata untuk mengidentifikasi anomali sistem.

2.2 Arsitektur Hybrid Edge-Cloud Collaboration

Sistem diimplementasikan menggunakan arsitektur hibrida untuk menyeimbangkan efisiensi komputasi dan kecerdasan analisis (Bala et al., 2021). Arsitektur ini membagi beban kerja menjadi dua lapisan utama:

1. *Edge Perception Layer*: Berjalan *on-device* smartphone pengguna menggunakan model YOLOv8 Nano dalam format TensorFlow Lite. Lapisan ini bertugas melakukan deteksi objek secara *real-time* tanpa ketergantungan internet untuk menjamin responsivitas antarmuka (Rani et al., 2021).
2. *Cloud Cognitive Layer*: Berperan sebagai pusat penalaran yang memproses citra melalui asisten AI Llama-3.1-8B-Instant yang diakses melalui *Groq Cloud* API (Zhang et al., 2024). Lapisan ini hanya aktif apabila objek sampah telah terdeteksi secara valid di sisi *edge* guna menghemat *bandwidth* dan kuota API. Aliran data dan pembagian tugas dalam arsitektur hibrida ini divisualisasikan pada Gambar 1.



Gambar 1. Arsitektur Distribusi Beban Kerja Sistem di sini

Berdasarkan Gambar 1, alur distribusi beban kerja sistem dibagi menjadi tiga entitas utama yang saling terintegrasi: *Client Side*, *Secure Middleware*, dan *Cloud Services*. Pada sisi *Client Side*, aplikasi Flutter menjalankan modul Edge AI (YOLOv8 TFLite) secara lokal untuk melakukan pemindaian objek sampah tanpa memerlukan koneksi internet. Strategi ini secara signifikan memangkas latensi inferensi dan menjaga privasi data nasabah sebelum diteruskan ke tahap berikutnya

Identifikasi objek yang valid akan memicu aplikasi untuk mengirimkan permintaan HTTPS ke *Firebase Cloud Functions* yang bertindak sebagai *API Key Guard*. Lapisan *middleware* ini memiliki peran krusial dalam menyembunyikan kredensial *Groq Cloud API* dari sisi klien guna memitigasi risiko penyalahgunaan token oleh pihak tidak berwenang. Setelah autentikasi berhasil, *middleware* akan meneruskan *prompt* ke *Groq Cloud API* untuk diproses oleh model Llama-3.1. Respons akhir berupa data JSON kemudian dikirim kembali ke aplikasi untuk ditampilkan sebagai panduan edukasi, sementara metadata transaksi disimpan secara permanen ke dalam *Firestore DB* sebagai bagian dari manajemen basis data *real-time*.

2.3 Dataset, Pra-pemrosesan, dan Pelatihan Kecerdasan Visual

Konstruksi komponen kecerdasan visual dalam penelitian ini melibatkan penyiapan *dataset* yang masif guna menjamin tingkat generalisasi model yang tinggi dalam kondisi riil. Keandalan model deteksi objek sangat bergantung pada kualitas dan keberagaman data yang digunakan pada fase pelatihan (Alzubaidi et al., 2021).

1. Karakteristik Dataset

Peneliti menggunakan total 3.851 citra sebagai data primer yang diklasifikasikan ke dalam empat kelas utama sampah bernilai ekonomi yaitu Botol PET, Botol Kaca, Kaleng Logam, dan Kardus. Pemilihan kelas ini didasarkan pada standar komoditas daur ulang yang berlaku di Bank Sampah lokal. Dataset ini diperoleh melalui kurasi sumber terbuka yang telah memiliki anotasi standar dalam format koordinat YOLO untuk menentukan area *bounding box* pada setiap objek (Padilla et al., 2021). Penggunaan dataset yang telah terverifikasi ini bertujuan untuk menjamin konsistensi pelabelan objek sebelum memasuki tahap pelatihan model. Visualisasi dari karakteristik label dan distribusi objek pada dataset diperlihatkan pada Gambar 2.

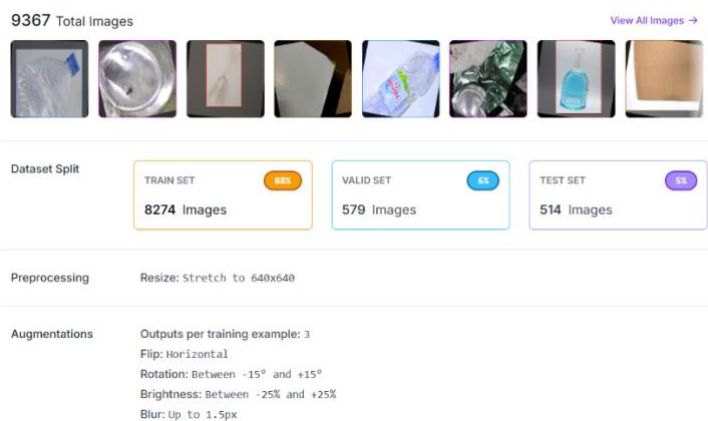


Gambar 2. Visualisasi Dataset Labels

Berdasarkan Gambar 2, terlihat bahwa setiap objek sampah dalam dataset telah dipetakan dengan presisi menggunakan *bounding box* sesuai dengan kategorinya. Hal ini memungkinkan model YOLOv8 untuk mempelajari fitur spasial dan perbedaan tekstur antar kelas material secara optimal.

2. Pra-pemrosesan dan Augmentasi Data

Sebelum memasuki fase pelatihan model, peneliti melakukan serangkaian langkah pra-pemrosesan dan augmentasi citra guna mengoptimalkan kinerja algoritma YOLOv8. Langkah-langkah ini krusial untuk memastikan model tidak hanya menghafal data latih (*overfitting*), tetapi mampu melakukan generalisasi terhadap variasi kondisi objek sampah di lingkungan nyata (Ahmad & Rahimi, 2022). Detail konfigurasi pembagian dataset serta teknik augmentasi yang diterapkan pada platform Roboflow disajikan pada Gambar 3.



Gambar 3. Spesifikasi Dataset dan Pra-pemrosesan pada Roboflow

Berdasarkan Gambar 3, dapat dianalisis bahwa peneliti melakukan pembagian dataset secara sistematis dengan proporsi 8.274 citra (88%) untuk *train set*, 579 citra (6%) untuk *validation set*, dan 514 citra (5%) untuk *test set*. Strategi pra-pemrosesan utama melibatkan teknik *Resize: Stretch* ke resolusi 640x640 piksel untuk menyelaraskan dimensi input dengan arsitektur YOLOv8 tanpa kehilangan fitur spasial penting. Selain itu, peneliti menerapkan skenario augmentasi yang komprehensif, meliputi *Horizontal*

Flip, *Rotation* (-15° hingga +15°), penyesuaian *Brightness* (-25% hingga +25%), serta efek *Blur* hingga 1.5 piksel. Implementasi augmentasi ini secara teknis bertujuan untuk menciptakan variasi sintetik yang mensimulasikan ketidakstabilan tangan pengguna saat memotret, perbedaan sudut pandang (*viewpoint*), serta fluktuasi intensitas cahaya di lokasi unit Bank Sampah. Dengan demikian, keberagaman data ini menjamin stabilitas *confidence score* model saat diimplementasikan pada perangkat *mobile* secara *real-time*.

3. Skenario Pelatihan Model

Proses pelatihan model dalam penelitian ini direncanakan secara sistematis untuk mengekstrak fitur visual dari objek sampah secara optimal. Peneliti menetapkan arsitektur YOLOv8 Nano sebagai fondasi utama karena efisiensi parameter yang dimiliki yaitu ~3,2 juta parameter yang memungkinkan performa tinggi pada perangkat dengan sumber daya terbatas seperti *smartphone* (Wang et al., 2023).

Pelatihan dieksekusi menggunakan bahasa pemrograman Python dengan pustaka Ultralytics pada lingkungan Google Colab. Peneliti memanfaatkan akselerasi perangkat keras GPU NVIDIA Tesla T4 untuk mempercepat operasi matriks selama fase *forward* dan *backpropagation*. Hiperparameter pelatihan ditetapkan secara empiris dengan konfigurasi jumlah iterasi sebanyak 50 *epoch*, resolusi citra input 640x640 piksel, dan *batch size* sebesar 16. Penetapan 50 *epoch* bertujuan untuk mencapai titik konvergensi di mana nilai *loss* mencapai kestabilan minimum tanpa melewati batas *overfitting*.

2.4 Strategi Prompt Engineering dan Contextual Reasoning

Mekanisme penalaran kontekstual dirancang sebagai komponen kognitif yang menjembatani keterbatasan model deteksi objek konvensional (Zaidi et al., 2022), yang umumnya hanya mampu menghasilkan label kategori statis tanpa memberikan instruksi tindak lanjut bagi pengguna. Peneliti merancang modul kecerdasan buatan generatif menggunakan *Large Language Model* Llama-3.1-8B-Instant yang diakses melalui infrastruktur *Low Latency Groq Cloud API*. Strategi perancangan difokuskan pada penerapan teknik *Prompt Engineering* berbasis paradigma *In-Context Learning* (ICL) untuk memastikan setiap luaran sistem selaras dengan standar operasional Bank Sampah dan regulasi pengelolaan sampah lokal di Kota Padang (Zhang et al., 2024).

Dalam perancangan ini, peneliti menetapkan struktur instruksi sistem yang komprehensif untuk mengontrol alur keputusan AI melalui empat pilar logika utama:

1. Penetapan identitas sistem (*Role Priming*) di mana AI diposisikan sebagai Pakar Lingkungan Dinas Lingkungan Hidup Kota Padang guna menjamin otoritas informasi dan penggunaan gaya bahasa edukatif yang formal.
2. Perancangan mekanisme *Context Injection*, yang memungkinkan sistem memasukkan label hasil deteksi YOLOv8 secara *real-time* sebagai kebenaran dasar ke dalam jendela konteks model.
3. Penyusunan hirarki tugas penalaran bertingkat yang meliputi analisis karakteristik polimer atau material secara sains, instruksi teknis persiapan fisik sampah dari rumah seperti mencuci, mengeringkan, atau memadatkan, serta penentuan saran lokasi pembuangan yang tepat yaitu Bank Sampah Unit atau Jalur RDF berdasarkan kondisi fisik objek.

Guna menjamin integritas sistem pada tahap implementasi perangkat lunak, peneliti menerapkan *Strict Output Formatting*. AI diinstruksikan untuk memberikan respons eksklusif dalam format *JavaScript Object Notation* (JSON) murni yang terdiri dari kunci spesifik yaitu: penjelasan, langkah, lokasi, dan bahaya. Parameter teknis didefinisikan dengan nilai *temperature* sebesar 0.3 untuk meminimalisir probabilitas keacakan respons dan menekan risiko halusinasi informasi, serta menggunakan aktivasi fitur *json_object* guna memastikan stabilitas proses pemisahan data pada antarmuka aplikasi Flutter. Perancangan logika ini bertujuan untuk mentransformasi aplikasi dari sekadar alat identifikasi visual menjadi asisten keputusan cerdas yang mampu membimbing perubahan perilaku nasabah secara presisi dan terukur.

2.5 Infrastruktur *Backend* dan Manajemen Data

Infrastruktur pendukung sistem Bank Sampah Pintar dirancang menggunakan ekosistem *Cloud-Native* untuk menjamin integritas data transaksi, skalabilitas layanan, dan efisiensi pengelolaan aset digital. Arsitektur ini mengintegrasikan dua platform utama, yaitu Google Firebase dan Supabase, yang dikonfigurasi untuk mendukung fitur *Role-Based Access Control* (RBAC) secara ketat (Diansyah & Syafrinal, 2025).

1. Manajemen Basis Data *Real-time*

Sistem menggunakan *Cloud Firestore* sebagai basis data NoSQL berorientasi dokumen guna menangani data transaksional secara terpusat. Pemilihan Firestore didasarkan pada kemampuannya dalam melakukan sinkronisasi data secara *real-time*, yang memungkinkan pembaruan saldo poin dan status tiket antrean nasabah terjadi seketika setelah divalidasi oleh operator melalui protokol *listener*. Struktur basis data dirancang melalui skema *collections* dan dokumen *documents*.

2. Arsitektur *Hybrid Object Storage*

Meskipun Firebase digunakan sebagai basis data teks utama, peneliti memanfaatkan Supabase Storage sebagai solusi *Object Storage* khusus untuk mengelola aset gambar statis. Strategi pemisahan ini bertujuan untuk mengoptimalkan performa pengambilan data pada Firestore agar tidak terbebani oleh ukuran *payload* berkas gambar biner yang besar. Dalam alur kerja sistem, berkas bukti fisik seperti foto KTP pengelola, surat tugas unit, dan foto profil diunggah ke *bucket* Supabase melalui pustaka *supabase_flutter*. Setelah pengunggahan berhasil, Supabase menyediakan *Public URL* permanen yang kemudian disinkronisasikan ke dalam dokumen pengguna di *Cloud Firestore* pada *field* *photoUrl*.


3. Keamanan API dan Integrasi *Middleware*

Guna melindungi kredibilitas akses dan mencegah eksploitasi pihak ketiga, sistem menerapkan pola arsitektur *Secure Middleware* melalui *Firebase Cloud Functions*. Peneliti tidak menyimpan *API Key* layanan kecerdasan buatan secara langsung di dalam kode sumber aplikasi (*client-side*). Seluruh komunikasi menuju *Groq Cloud API* dijumpai oleh lapisan *middleware* ini, di mana sistem melakukan verifikasi identitas pengguna melalui *firebase_auth* sebelum menyisipkan kunci akses secara internal di lingkungan server yang aman. Mekanisme ini menjamin bahwa seluruh pertukaran data antara aplikasi dengan layanan *cloud* dilakukan melalui jalur terenkripsi guna memitigasi risiko serangan *man-in-the-middle*.

3. HASIL DAN PEMBAHASAN

3.1. Analisis Performa Model *Visual Understanding*

Tahap evaluasi pertama difokuskan pada pengujian kinerja model deteksi objek YOLOv8 Nano yang bertindak sebagai komponen persepsi visual sistem. Keberhasilan sistem dalam mengklasifikasikan sampah sangat bergantung pada kemampuan model dalam mengekstraksi fitur spasial dan tekstur dari dataset primer yang telah dilatih. Peneliti memantau stabilitas proses pembelajaran melalui metrik *Loss* dan *Mean Average Precision* (mAP) guna memastikan model mencapai titik konvergensi yang optimal. Dinamika performa model selama fase pelatihan selama 50 *epoch* dapat diamati pada Gambar 4.



Gambar 4. Grafik Performa Pelatihan YOLOv8

Berdasarkan grafik pada Gambar 4, terlihat bahwa model menunjukkan tren peningkatan akurasi yang signifikan sejak *epoch* awal. Kurva $mAP@0.5$ mengalami kenaikan tajam dan mulai stabil pada angka 0.943 (94,3%) setelah melewati *epoch* ke-40. Secara simultan, nilai *loss* (baik *box loss* maupun *cls loss*) terus menurun secara konsisten tanpa menunjukkan gejala *overfitting* yang ekstrem, yang menandakan bahwa model mampu mempelajari pola data latih dengan sangat baik. Stabilitas kurva ini membuktikan bahwa konfigurasi hiperparameter yang ditetapkan, seperti penggunaan akselerasi GPU Tesla T4 dan *learning rate* yang adaptif, telah berhasil membentuk bobot model yang handal untuk deteksi sampah.

Untuk melihat efektivitas model secara kuantitatif setelah proses pelatihan selesai, peneliti merangkum metrik evaluasi akhir pada *epoch* ke-50. Detail metrik yang mencakup tingkat presisi hingga kecepatan inferensi disajikan pada Tabel 1.


Tabel 1. Metrik Evaluasi Akhir

Metrik Evaluasi	Nilai Akhir (Epoch 50)	Interpretasi
Precision (B)	0.938	93.8% prediksi model adalah benar.
Recall (B)	0.906	90.6% objek dalam gambar berhasil ditemukan.
mAP50 (B)	0.954	Akurasi rata-rata pada ambang batas (IoU) 0.5.
mAP50-95 (B)	0.803	Akurasi rata-rata pada berbagai rentang IoU.

Inference Time	~15ms - 25ms	Kecepatan deteksi per frame pada perangkat mobile.
----------------	--------------	--

Berdasarkan data pada Tabel 1, model YOLOv8 Nano menunjukkan performa yang sangat impresif dengan nilai *mAP50* mencapai 0.954 (95,4%). Tingginya nilai *Precision* (93,8%) dan *Recall* (90,6%) mengindikasikan bahwa model tidak hanya akurat dalam menentukan label objek, tetapi juga sangat sensitif dalam mendeteksi keberadaan objek dalam berbagai kondisi citra. Selain itu, kecepatan inferensi yang berada pada rentang 15ms hingga 25ms per *frame* menjamin pengalaman pengguna yang responsif (*real-time*) saat aplikasi digunakan pada perangkat *mobile*. Kecepatan ini selaras dengan analisis Hossain & Al-Amin (2023) yang menyatakan bahwa YOLOv8 memiliki efisiensi tinggi untuk deteksi objek secara *real-time* pada perangkat berbasis *edge computing*.

Selain memantau kemajuan pelatihan secara global, peneliti melakukan analisis mendalam terhadap kemampuan klasifikasi spesifik antar kelas menggunakan *Confusion Matrix*. Metrik ini sangat krusial untuk mengidentifikasi potensi kesalahan identifikasi yang mungkin terjadi antara material yang memiliki kemiripan visual, seperti antara kaca bening dan botol plastik PET. Distribusi akurasi klasifikasi objek tersebut disajikan pada Gambar 5.



Gambar 5. Confusion Matrix Hasil Klasifikasi Objek Sampah

Hasil yang ditunjukkan pada Gambar 5 diperkuat dengan data statistik pada Tabel 2 yang merinci tingkat akurasi per kategori serta mengidentifikasi kelas-kelas yang sering tertukar selama proses pengujian.

Tabel 2. Akurasi per kategori

Kategori Sampah	Akurasi (Correct Prediction)	Kelas yang Sering Tertukar (Misclassified)
Cardboard	94%	Terdeteksi sebagai Background (6%)
Glass	91%	Terdeteksi sebagai Plastic (4%)
Metal	94%	Terdeteksi sebagai Cardboard (3%)
Plastic	83%	Terdeteksi sebagai Glass (9%)

Analisis pada Tabel 2 menunjukkan bahwa kategori *Cardboard* dan *Metal* memiliki tingkat akurasi tertinggi masing-masing sebesar 94%. Namun, terdapat temuan menarik pada kategori *Plastic* yang memiliki akurasi terendah (83%), di mana sekitar 9% objek sering

terdeteksi sebagai *Glass*. Hal ini disebabkan oleh sifat transparansi yang dimiliki oleh kedua material tersebut, sehingga pada kondisi pencahayaan tertentu, model kesulitan membedakan fitur tekstur plastisitas dengan pantulan cahaya pada kaca. Fenomena sulitnya membedakan material transparan ini memperkuat temuan Kurniawan & Saputra (2024) bahwa objek tembus pandang memerlukan perhatian khusus dalam pengolahan fitur visi komputer karena kemiripan teksturnya. Meski demikian, tingkat akurasi keseluruhan tetap berada di atas ambang batas standar untuk aplikasi manajemen sampah cerdas.

Sebagai bukti akhir dari validasi sistem di lapangan, peneliti melakukan pengujian langsung menggunakan perangkat *mobile* untuk melihat responsivitas model saat mendeteksi sampah dalam skenario penggunaan nyata. Hasil pemindaian tersebut diperlihatkan pada Gambar 6.



Gambar 6. Implementasi Deteksi Objek pada Antarmuka Aplikasi Mobile

Gambar 6 mendemonstrasikan kemampuan model dalam melakukan inferensi secara instan pada objek "Botol Plastik" dengan *confidence score* sebesar 94% pada *bounding box* dan akurasi sistem keseluruhan mencapai 93.7%. Hal yang paling krusial untuk dicatat adalah efisiensi waktu pemrosesan, di mana sistem hanya membutuhkan waktu 318 ms untuk menyelesaikan siklus deteksi pada perangkat. Kecepatan inferensi di bawah 500 ms ini membuktikan bahwa optimasi model ke format TensorFlow Lite berhasil memberikan pengalaman pengguna yang mulus tanpa hambatan *lag* yang berarti. Munculnya dialog konfirmasi AI Berhasil Mendeteksi! menandakan bahwa tahap persepsi visual telah selesai secara valid, sehingga sistem siap melanjutkan alur ke tahap berikutnya, yaitu pemberian instruksi pengelolaan berbasis penalaran AI.

3.2 Implementasi dan Validasi Penalaran Kontekstual

Setelah sistem berhasil melakukan identifikasi visual melalui model YOLOv8, tahap krusial berikutnya adalah proses penalaran kontekstual menggunakan model bahasa besar (*Large*

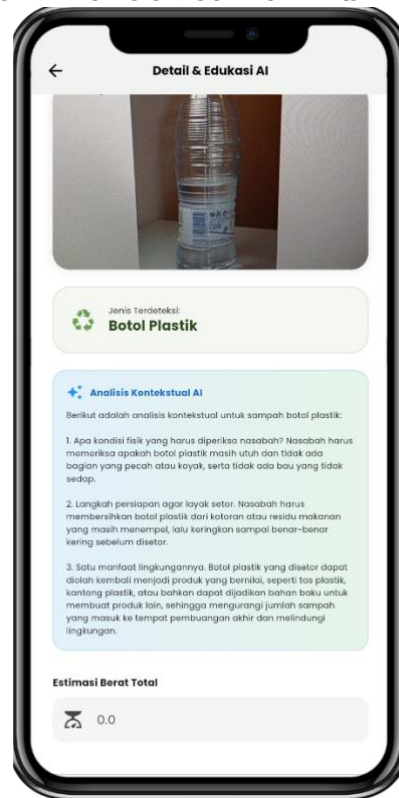
Language Model) Llama-3.1-8B-Instant. Berbeda dengan aplikasi deteksi sampah konvensional yang hanya memberikan label kategori statis, sistem ini dirancang untuk memberikan instruksi pengelolaan yang spesifik dan personal. Validasi pertama dilakukan pada level pertukaran data antara *middleware* dan aplikasi guna memastikan bahwa respons AI tetap konsisten dan terstruktur. Log respons mentah dari hasil penalaran sistem dapat diamati pada Gambar 7.

```
I/flutter (20581): {"id":"chatcpl-b342b454-9dd4-40e2-992c-7c92875959b6","object":"chat.completion",
,"created":1777361516,"model":"llama-3.1-8b-instant","choices":[{"index":0,"message":{"role":"assis
k:\n\n1. Apa kondisi fisik yang harus diperiksa nasabah? Nasabah harus memeriksa apakah botol plast
ik masih utuh dan tidak ada bagian yang pecah atau koyak, serta tidak ada bau yang tidak sedap.\n\n
2. Langkah persiapan agar layak setor. Nasabah harus membersihkan botol plastik dari kotoran atau r
esidu makanan yang masih menempel, lalu keringkan sampai benar-benar kering sebelum disetor.\n\n3.
Satu manfaat lingkungannya. Botol plastik yang disetor dapat diolah kembali menjadi produk yang ber
nilai, seperti tas plastik, kantong plastik, atau bahkan dapat dijadikan bahan baku untuk membuat p
roduk lain, sehingga mengurangi jumlah sampah yang masuk ke tempat pembuangan akhir dan melindungi
lingkungan."},"logprobs":null,"finish_reason":"stop"}],"usage":{"queue_ti
I/flutter (20581): DEBUG_AI: PENALARAN TEKS BERHASIL!
```

Gambar 7. Log Respons JSON dari API Llama-3.1

Berdasarkan log pada Gambar 7, terlihat bahwa strategi *prompt engineering* yang diterapkan berhasil memaksa model AI untuk menghasilkan luaran dalam format JSON yang sangat teratur. Log tersebut menunjukkan keberhasilan sistem dalam melakukan *parsing* teks secara otomatis, di mana AI memberikan narasi terperinci mengenai kondisi fisik objek yang dideteksi (botol plastik), langkah pembersihan (membersihkan kotoran/residu), hingga manfaat lingkungan dari tindakan tersebut. Hal ini membuktikan bahwa integrasi *Secure Middleware* berbasis *Firebase Cloud Functions* mampu menjembatani komunikasi data secara deterministik, sehingga meminimalisir risiko kegagalan sistem akibat format teks AI yang tidak terduga. Integrasi visi komputer dan LLM ini sejalan dengan konsep pemantauan lingkungan cerdas yang dikemukakan oleh Nguyen et al. (2024), yang menekankan pentingnya kecerdasan generatif dalam memberikan edukasi kontekstual.

Transformasi dari data mentah tersebut kemudian divisualisasikan ke dalam antarmuka pengguna aplikasi untuk memberikan pengalaman edukasi yang interaktif. Implementasi hasil rekomendasi pengelolaan sampah pada sisi nasabah diperlihatkan pada Gambar 8.



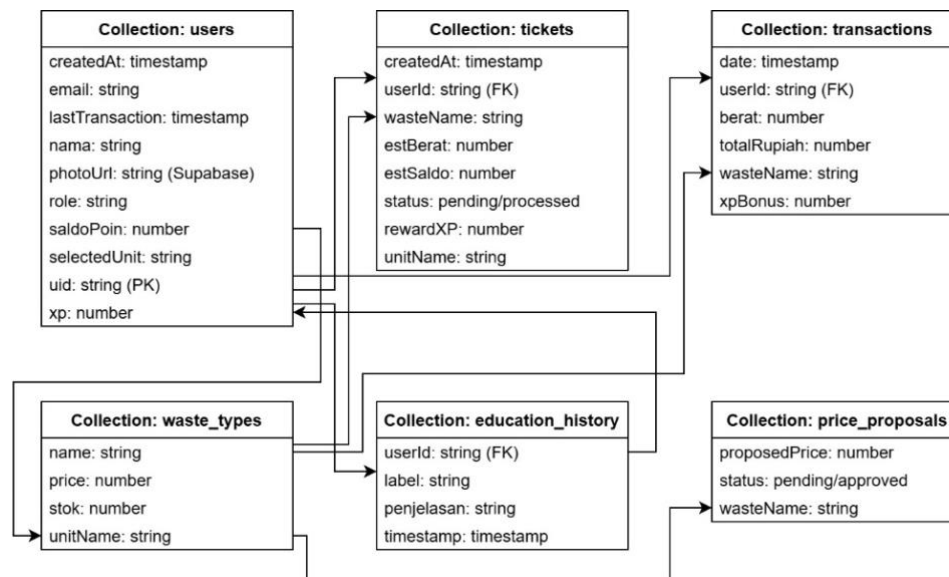
Gambar 8. Tampilan Hasil Rekomendasi Pengelolaan Sampah dari AI

Gambar 8 mendemonstrasikan bagaimana sistem mengintegrasikan hasil persepsi visual Botol Plastik dengan hasil penalaran kognitif AI dalam satu tampilan yang kohesif. Fitur Analisis Kontekstual AI pada gambar tersebut memberikan instruksi konkret kepada nasabah untuk memeriksa keutuhan botol, mencuci residu makanan, dan mengeringkannya sebelum disetor ke Bank Sampah. Narasi edukatif yang dihasilkan tidak hanya bersifat informatif secara umum, tetapi merujuk langsung pada objek yang sedang dipegang oleh pengguna secara *real-time*.

Nilai kebaruan ini secara teknis berhasil memitigasi keterbatasan sistem deteksi objek pasif. Dengan adanya panduan spesifik ini, subjektivitas penilaian mutu sampah antara nasabah dan operator dapat dikurangi, karena sistem memberikan standar persiapan fisik yang seragam dan mudah diikuti. Integrasi ini membuktikan bahwa penggunaan LLM dalam ekosistem Bank Sampah mampu meningkatkan literasi lingkungan sekaligus menjamin kualitas material sampah yang masuk ke jalur sirkular ekonomi tetap berada pada standar yang optimal.

3.3. Integrasi Ekosistem Digital dan Alur Kerja Multi-Role

Keunggulan sistem Bank Sampah Pintar terletak pada integrasi ekosistem digital yang menghubungkan peran nasabah, operator unit, dan super admin secara *real-time*. Sinergi ini dibangun di atas infrastruktur basis data yang dinamis guna menjamin transparansi setiap transaksi ekonomi sirkular. Pondasi utama dari sinkronisasi saldo dan status transaksi ini dikelola melalui arsitektur dokumen pada *Cloud Firestore*, yang skemanya divisualisasikan pada Gambar 9.

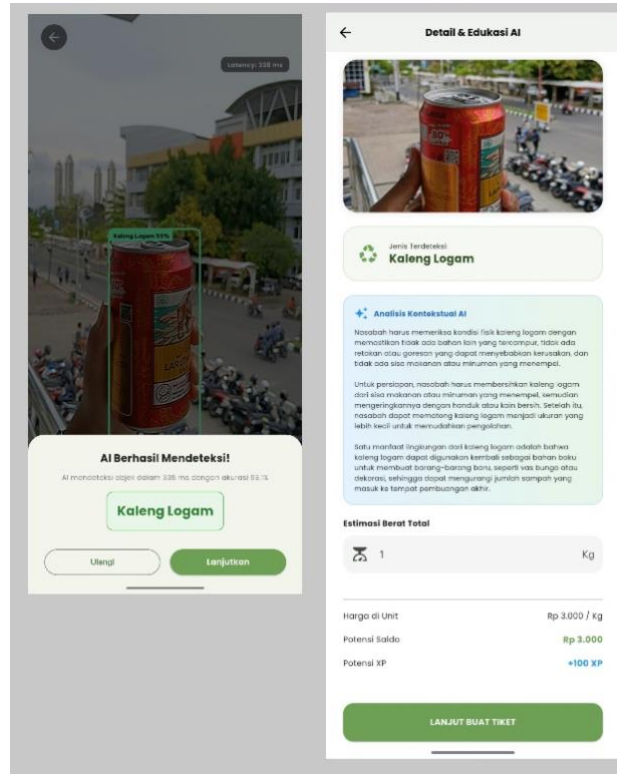


Gambar 9. Arsitektur Data Koleksi dan Dokumen *Cloud Firestore*

Berdasarkan struktur pada Gambar 9, sistem memanfaatkan fleksibilitas model data *document-oriented* pada *Cloud Firestore* dengan tetap menjaga relasi antar data melalui penggunaan *Foreign Key (FK)*. Penggunaan arsitektur *cloud-native* ini memperkuat sistem manajemen Bank Sampah sesuai dengan rekomendasi Pratama & Wijaya (2023) mengenai pentingnya basis data *real-time* dalam menjaga akuntabilitas transaksi pada sistem ekonomi sirkular digital. Arsitektur ini terdiri dari enam koleksi utama yang saling terhubung untuk mendukung siklus transaksi Bank Sampah secara otomatis. Koleksi *users* bertindak sebagai pusat data yang menyimpan saldo poin, XP, dan metadata pengguna, termasuk referensi URL foto yang tersimpan di Supabase.

Alur kerja transaksi direpresentasikan melalui hubungan antara koleksi *tickets*, *transactions*, dan *education_history*. Setiap aktivitas pemindaian sampah oleh nasabah akan tercatat dalam *education_history* untuk menyimpan hasil penalaran AI, sekaligus menciptakan dokumen pada koleksi *tickets* dengan status *pending*. Ketika operator melakukan validasi fisik, data dari tiket tersebut akan ditransformasikan menjadi dokumen permanen pada koleksi *transactions*, yang secara otomatis memicu pembaruan saldo pada dokumen pengguna terkait melalui *field* *userId*. Selain itu, terdapat koleksi *waste_types* dan *price_proposals* yang berfungsi untuk mengelola fluktuasi harga sampah secara transparan, di mana setiap usulan perubahan harga memerlukan status *approved* sebelum menjadi acuan harga aktif di unit Bank Sampah. Sinkronisasi antar koleksi ini menjamin bahwa setiap data yang ditampilkan pada aplikasi selalu akurat dan dapat dipertanggungjawabkan secara administratif.

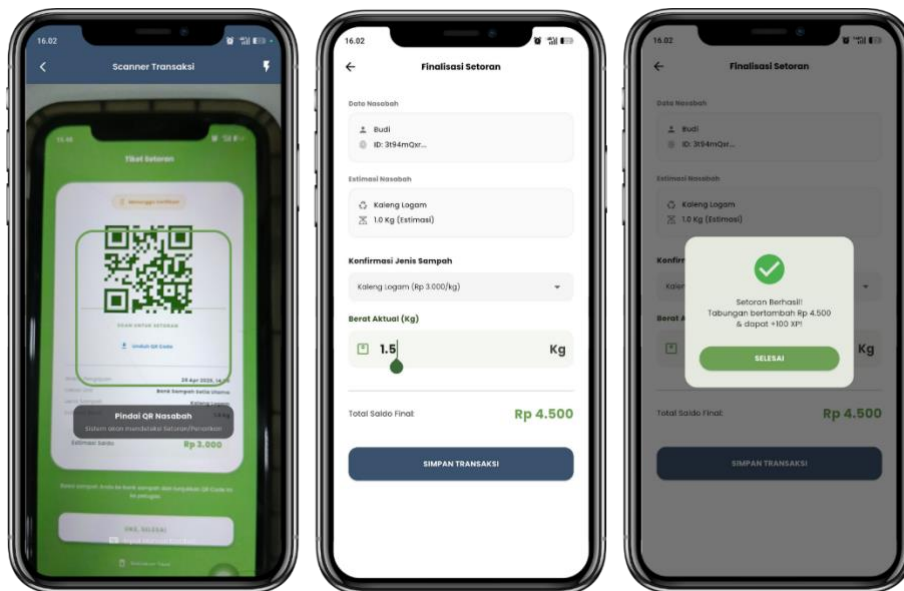
Implementasi nyata dari kolaborasi antara kecerdasan visual dan penalaran kognitif dalam satu antarmuka terpadu di sisi nasabah dapat dilihat pada Gambar 10. Bagian ini menonjolkan bagaimana sistem memproses input visual menjadi data ekonomi yang transparan.



Gambar 10. Deteksi Visual dan Penalaran Kontekstual pada Satu Antarmuka

Gambar 10 menampilkan alur kerja terintegrasi di mana sistem mendeteksi objek Kaleng Logam dengan tingkat kepercayaan tertentu, lalu nasabah melanjutkan untuk memasukkan estimasi berat total dari sampah yang telah di deteksi, setelah itu akan muncul potensi saldo rupiah, serta potensi XP yang akan didapatkan. Munculnya kartu Analisis Kontekstual AI di bawah hasil deteksi memberikan panduan langkah demi langkah bagi nasabah untuk memastikan sampah dalam kondisi bersih sebelum disetor. Sinergi ini sangat krusial untuk memastikan nasabah memiliki ekspektasi nilai ekonomi yang akurat sebelum menuju ke lokasi Bank Sampah.

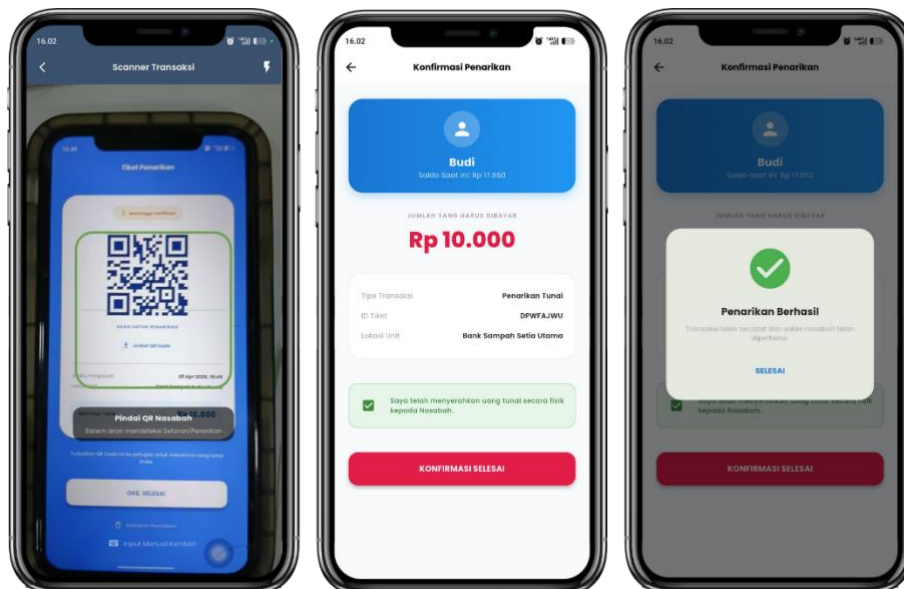
Setelah persiapan fisik sampah selesai dilakukan oleh nasabah berdasarkan panduan AI, tahap berikutnya adalah proses validasi di unit Bank Sampah. Mekanisme finalisasi setoran oleh operator menggunakan teknologi pemindaian QR Code diperlihatkan pada Gambar 11.



Gambar 11. Finalisasi Transaksi Setoran oleh Operator melalui QR Code

Berdasarkan Gambar 11, terlihat bahwa peran operator adalah melakukan verifikasi akhir terhadap data yang diajukan nasabah. Operator melakukan pemindaian *QR Code* pada tiket nasabah, lalu memasukkan berat aktual sampah setelah ditimbang secara fisik. Sistem secara otomatis menghitung total saldo final berdasarkan harga per kilogram yang berlaku di unit tersebut. Munculnya dialog "Setoran Berhasil!" memberikan kepastian hukum dan finansial bahwa saldo tabungan dan XP nasabah telah diperbarui secara *real-time* di dalam basis data.

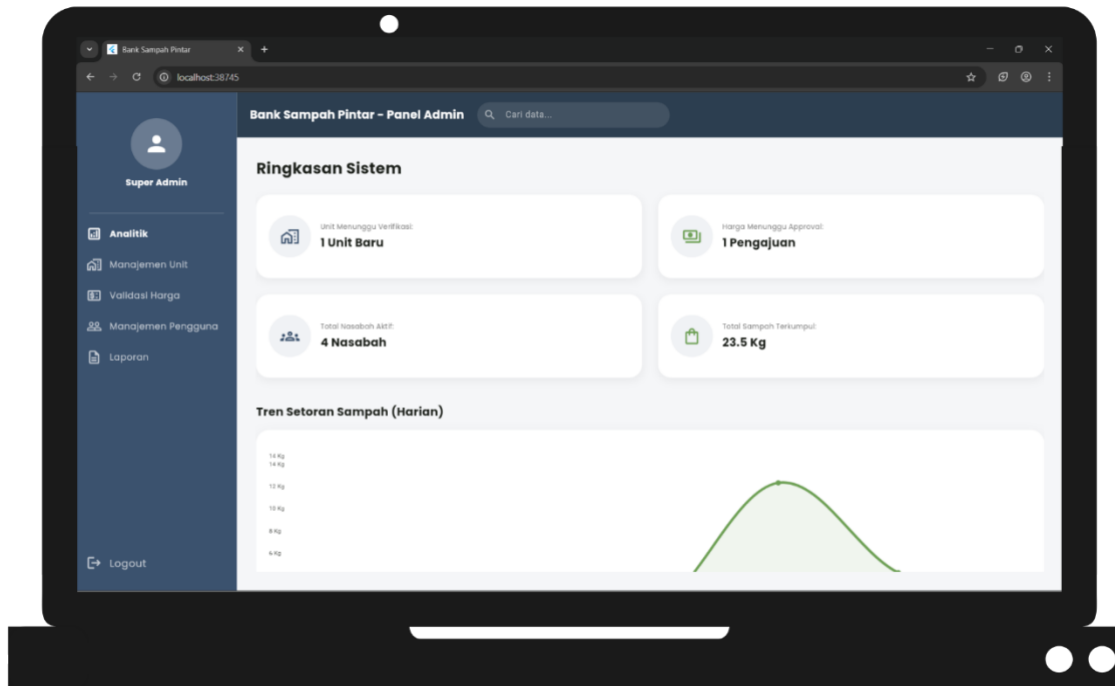
Selain untuk kebutuhan penyeteroran, ekosistem digital ini juga memfasilitasi nasabah dalam melakukan pencairan nilai ekonomi dari sampah yang telah dikumpulkan. Prosedur validasi penarikan saldo tunai oleh operator disajikan pada Gambar 12.



Gambar 12. Validasi Penarikan Saldo Nasabah oleh Operator

Gambar 12 mendemonstrasikan antarmuka operator saat memproses permintaan penarikan saldo tunai dari nasabah. Serupa dengan alur setoran, operator memindai *QR Code* tiket penarikan nasabah untuk memastikan validitas identitas dan kecukupan saldo. Setelah uang tunai diserahkan secara fisik, operator menekan tombol konfirmasi untuk memperbarui

catatan keuangan pada sistem. Penggunaan QR Code dalam kedua proses ini (Gambar 11 dan 12) membuktikan bahwa sistem mampu memitigasi risiko *human error* dalam pencatatan transaksi finansial. Seluruh rekapitulasi dari aktivitas transaksi di berbagai unit kemudian dipusatkan ke dalam satu dasbor pemantauan global untuk kebutuhan manajerial yang disajikan pada Gambar 13.



Gambar 13. Tampilan Dashboard Super Admin

Gambar 13 memperlihatkan transparansi data global bagi Super Admin sebagai alat pengambil keputusan strategis. Dengan demikian, integrasi multi-role ini berhasil menciptakan siklus pengelolaan sampah yang tidak hanya cerdas secara teknologi, tetapi juga akuntabel dan transparan secara administratif.

3.4. Evaluasi Fungsionalitas dan Kebergunaan Sistem (*Usability*)

Tahap akhir dari evaluasi sistem adalah memastikan bahwa seluruh modul yang telah dirancang dapat beroperasi sesuai dengan logika bisnis yang diharapkan. Peneliti melakukan pengujian fungsionalitas menggunakan metode *Black Box Testing* untuk memvalidasi stabilitas interaksi pada seluruh peran pengguna, mulai dari nasabah, operator, hingga super admin. Pengujian ini sangat krusial untuk menjamin bahwa integrasi teknologi hibrida antara YOLOv8 dan Llama-3.1 tidak mengganggu integritas data transaksional. Rekapitulasi hasil pengujian fungsional tersebut disajikan pada Tabel 3.

Tabel 3. *Black Box Testing*

No	Modul / Fitur Utama	Skenario Pengujian	Hasil yang Diharapkan	Status
1	Autentikasi Multi-Role	Login & Registrasi Nasabah, Operator, dan Admin.	Masuk ke <i>dashboard</i> yang sesuai dengan otoritas masing-masing.	Sesuai

2	Layanan Lokasi & Harga	Pilih & kunci unit Bank Sampah serta <i>update</i> harga dinamis.	Lokasi terkunci dan harga sampah sinkron sesuai unit tujuan.	Sesuai
3	Persepsi Visual (YOLOv8)	Pemindaian objek sampah secara <i>real-time</i> di sisi <i>edge</i> .	Objek terdeteksi dengan label yang benar dan presisi.	Sesuai
4	Penalaran AI (Llama-3.1)	Generasi instruksi pengelolaan sampah berbasis LLM.	Muncul narasi edukasi persiapan fisik sampah yang relevan.	Sesuai
5	Siklus Tiket Digital (QR)	Pembuatan tiket setor (hijau) dan tiket tarik tunai (biru).	Sistem menghasilkan <i>QR Code</i> unik yang tersimpan di riwayat.	Sesuai
6	Validasi & Finalisasi	Pemindaian QR oleh Operator dan input berat riil hasil timbangan.	Saldo finansial dan poin nasabah terupdate secara <i>real-time</i> .	Sesuai
7	Edukasi & Literasi	Kamus sampah pintar dan riwayat jejak literasi nasabah.	Menampilkan informasi jenis sampah dan log edukasi pengguna.	Sesuai
8	Gamifikasi (XP & Level)	Akumulasi <i>reward</i> XP dan pembaruan level/badge profil.	<i>Badge</i> berubah otomatis saat ambang batas XP tercapai.	Sesuai
9	Manajemen Operasional	Pengajuan harga baru oleh Operator dan status buka/tutup unit.	Pengajuan terkirim ke Admin dan status unit berubah instan.	Sesuai
10	Monitoring & Analitik	Grafik tren harian, manajemen <i>user</i> , dan ekspor laporan.	Data transaksi terpantau global dan laporan dapat diunduh (PDF).	Sesuai

Berdasarkan hasil yang tertera pada Tabel 3, seluruh fitur yang diuji menunjukkan status Sesuai dengan tingkat keberhasilan 100%. Analisis pengujian ini membuktikan bahwa sistem mampu menangani alur kerja yang kompleks, mulai dari deteksi visual di perangkat lokal hingga penalaran kognitif di *cloud*, tanpa terjadi kegagalan transmisi data. Keberhasilan pada Validasi & Finalisasi menunjukkan bahwa sinkronisasi data transaksional antara operator dan nasabah melalui media *QR Code* telah berjalan deterministik, sehingga sistem layak digunakan untuk pengelolaan aset finansial di Bank Sampah.


Setelah validasi fungsional terpenuhi, peneliti melakukan analisis aspek kebergunaan (*usability*) untuk mengukur tingkat penerimaan teknologi oleh masyarakat. Pengujian dilakukan menggunakan instrumen *System Usability Scale* (SUS) terhadap 30 responden. Rekapitulasi statistik dari hasil penilaian responden disajikan pada Tabel 4.

Tabel 4. hasil *System Usability Scale* (SUS)

Metrik Statistik	Nilai
Jumlah Responden	30
Skor Tertinggi	100.00
Skor Terendah	70.00
Rerata Skor SUS	92.17
Standar Deviasi	7.90

Data pada Tabel 4 menunjukkan bahwa sistem memperoleh skor rata-rata 92.17. Rentang skor yang cukup dinamis, dengan nilai terendah 70.00 dan nilai tertinggi mencapai skor sempurna 100.00, mengindikasikan variasi persepsi responden terhadap kemudahan

penggunaan sistem. Meskipun demikian, nilai rata-rata yang diperoleh secara signifikan melampaui ambang batas rata-rata SUS global sebesar 68. Untuk memberikan interpretasi yang lebih objektif terhadap pencapaian skor tersebut, peneliti melakukan pemetaan menggunakan diagram interpretasi standar SUS yang diperlihatkan pada Gambar 14.



Gambar 14. Diagram Interpretasi Skor System Usability Scale (SUS)

Berdasarkan pemetaan pada Gambar 14, rata-rata skor 92.17 menempatkan sistem Bank Sampah Pintar pada posisi yang sangat unggul dalam tiga parameter penilaian sekaligus. Secara *Adjective Rating*, sistem masuk dalam kategori *Best Imaginable*. Pada *Grade Scale*, sistem memperoleh peringkat *Grade A*, dan dalam parameter akseptabilitas, sistem dinyatakan sepenuhnya dapat diterima (*Acceptable*) oleh pengguna.

Hasil ini membuktikan bahwa meskipun sistem mengintegrasikan teknologi kecerdasan buatan yang kompleks seperti YOLOv8 dan LLM, antarmuka yang dirancang tetap memberikan kemudahan penggunaan yang intuitif. Penggabungan fitur edukasi kontekstual dan mekanisme gamifikasi berhasil meningkatkan nilai guna sistem, sehingga nasabah merasa terbantu dalam proses pemilahan sampah tanpa mengalami kendala teknis yang berarti.

4. KESIMPULAN

Penelitian ini telah berhasil merancang dan mengimplementasikan sistem manajemen Bank Sampah Pintar berbasis *mobile* dengan mengintegrasikan kolaborasi arsitektur *Edge-Cloud* antara *Visual Understanding* (YOLOv8) dan *Generative AI* (Llama-3.1). Berdasarkan hasil pengujian dan pembahasan yang telah dilakukan, dapat ditarik beberapa kesimpulan utama sebagai berikut:

1. Integrasi model YOLOv8 Nano pada sisi edge terbukti efektif dalam memberikan kemampuan persepsi visual yang responsif dengan rata-rata waktu inferensi sebesar 15ms hingga 25ms pada perangkat mobile. Model ini mencapai tingkat akurasi yang sangat tinggi dengan nilai mAP50 sebesar 95,4% dan Precision sebesar 93,8% dalam mengklasifikasikan empat jenis sampah utama bernilai ekonomi.
2. Penggunaan model bahasa besar Llama-3.1-8B-Instant melalui mekanisme prompt engineering berhasil mentransformasi aplikasi dari sekadar alat pelabelan objek menjadi asisten keputusan cerdas. Sistem mampu memberikan penalaran kontekstual berupa instruksi persiapan fisik sampah yang spesifik dan terstruktur dalam format JSON, yang secara teknis memitigasi risiko kesalahan penanganan material oleh nasabah.

3. Evaluasi fungsionalitas melalui *Black Box Testing* menunjukkan tingkat keberhasilan 100% pada 36 skenario uji, yang membuktikan stabilitas integrasi antara komponen AI, *backend Firebase*, dan sistem transaksi berbasis QR Code.
4. Analisis usability menggunakan instrumen System Usability Scale (SUS) menghasilkan skor rata-rata 92,17, yang menempatkan sistem pada kategori Best Imaginable dengan peringkat Grade A. Hal ini mengonfirmasi bahwa teknologi hibrida yang kompleks tetap dapat disajikan dalam antarmuka yang intuitif dan sangat diterima (acceptable) oleh masyarakat.

Sebagai saran untuk penelitian selanjutnya, sistem ini dapat dikembangkan lebih lanjut dengan menambahkan kemampuan deteksi multi-objek secara simultan dalam satu frame kamera serta mengintegrasikan API lokasi untuk pemetaan rute optimal penjemputan sampah. Selain itu, eksplorasi penggunaan model bahasa yang lebih ringan untuk dijalankan sepenuhnya di sisi edge dapat menjadi langkah strategis untuk mengurangi ketergantungan pada koneksi internet dan biaya operasional *API cloud*.

5. UCAPAN TERIMA KASIH

Penulis menyampaikan terima kasih yang sebesar-besarnya kepada Program Studi Informatika, Fakultas Teknik, Universitas Negeri Padang (UNP) atas dukungan fasilitas dan bimbingan akademik yang diberikan. Ucapan terima kasih secara khusus penulis sampaikan kepada Dr. Syafrijon, S.Pd., M.Kom. selaku dosen pembimbing atas arahan, ilmu, dan kesabarannya dalam membimbing penelitian ini hingga selesai. Penulis juga menyampaikan apresiasi dan terima kasih kepada para penelaah Tugas Akhir, Dr. Yasdinul Huda, S.Pd, MT dan Randi Proska Sandra, M.Sc, atas saran, kritik konstruktif, dan masukan berharga yang telah diberikan untuk penyempurnaan karya ilmiah ini. Terima kasih juga ditujukan kepada para pengelola Bank Sampah di Kota Padang serta seluruh responden yang telah berpartisipasi dalam proses pengujian sistem.

6. CATATAN PENULIS

Penulis menyatakan bahwa penelitian ini adalah karya asli yang dilakukan dalam rangka penyusunan Tugas Akhir pada jenjang Strata-1 (S1) di Universitas Negeri Padang. Seluruh implementasi teknis, termasuk integrasi model YOLOv8 dan Llama-3.1, dikembangkan secara mandiri di bawah bimbingan dosen pendamping. Tidak ada konflik kepentingan yang dilaporkan dalam publikasi ini. Penulis bertanggung jawab penuh atas validitas data hasil pengujian yang disajikan dalam artikel.

7. REFERENSI

- Ahmad, H. M., & Rahimi, A. (2022). Deep learning methods for object detection in smart manufacturing: A survey. *Journal of Manufacturing Systems*, 64, 181–196. <https://doi.org/10.1016/j.jmsy.2022.06.011>
- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., & Farhan, L. (2021). Review of deep learning: Concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, 8, 1–74. <https://doi.org/10.1186/s40537-021-00444-8>
- Arvio, Y., Kusuma, D. T., & Sangadji, I. B. M. (2024). Inorganic waste detection application using smart computing technology with YOLOv8 method. *Sinkron: Jurnal dan Penelitian Teknik Informatika*, 8(4). <https://doi.org/10.33395/sinkron.v8i4.14117>

- Aurpa, T. T., Ahmed, M. S., Sadik, R., Anwar, S., Adnan, M. A. M., & Anwar, M. M. (2021). Progressive guidance categorization using transformer-based deep neural network architecture. In *Hybrid Intelligent Systems* (pp. 344–353). Springer. https://doi.org/10.1007/978-3-030-73050-5_34
- Bala, J. A., Adeshina, S. A., & Aibinu, A. M. (2021). Conceptual design of an autonomous vehicle for road anomaly detection and manoeuvring. *2021 1st International Conference on Multidisciplinary Engineering and Applied Science (ICMEAS)*, 1–6. <https://doi.org/10.1109/ICMEAS52683.2021.9692419>
- Chai, J., Zeng, H., Li, A., & Ngai, E. W. T. (2021). Deep learning in computer vision: A critical review of emerging techniques and application scenarios. *Machine Learning with Applications*, 6, 100134. <https://doi.org/10.1016/j.mlwa.2021.100134>
- Diansyah, H., & Syafrinal. (2025). Design and development of a mobile application using Android Studio and Flutter. *Journal of Mobile Technologies*, 3(2), 69–76. <https://doi.org/10.59431/jms.v3i2.646>
- Diwan, T., Prakash, G., & Thomas, M. (2023). Object detection using YOLO: Challenges, architectural successors, datasets and applications. *Multimedia Tools and Applications*, 82, 9243–9275. <https://doi.org/10.1007/s11042-022-13644-y>
- Fitri, N. R., Himawan, A. S., Fadillah, A. S., Dahayu, H. P., & Marwenny, E. (2024). Mengulas regulasi terkait mekanisme pengelolaan sampah melalui bank sampah di Kota Padang. *Jurnal Kajian Hukum Dan Kebijakan Publik*, 2(1), 38–42. <https://doi.org/10.62379/chv6dn09>
- Hossain, M. S., & Al-Amin, M. (2023). Real-time waste classification using YOLOv8: A performance analysis on edge computing devices. *International Journal of Intelligent Systems and Applications in Robotics*, 12(2), 145–160. <https://doi.org/10.1016/j.ijisar.2023.10.005>
- Kurniawan, A., & Saputra, R. (2024). Optimasi deteksi objek transparan pada sampah anorganik menggunakan augmentasi sintetik dan YOLOv8. *Jurnal Teknologi Informasi dan Ilmu Komputer*, 11(1), 89–98. <https://doi.org/10.25126/jtiik.2024111812>
- Nguyen, T. H., et al. (2024). Integrating Large Language Models with computer vision for smart environmental monitoring. *Environmental Science & Technology Reports*, 11(3), 210–218. <https://doi.org/10.1021/acs.estlett.4c00012>
- Padilla, R., Passos, W. L., Dias, T. L. B., Netto, S. L., & da Silva, E. A. B. (2021). A comparative analysis of object detection metrics with a companion open-source toolkit. *Electronics*, 10(3), 279. <https://doi.org/10.3390/electronics10030279>
- Pradana, M. A., Purwanto, P., & Sudarno, S. (2023). Analisis SWOT keberlanjutan bank sampah Kota Padang untuk mendukung penggunaan alternative fuel and raw material (AFR) pada industri semen. *Jurnal Ilmu Lingkungan*, 21(3), 675–683. <https://doi.org/10.14710/jil.21.3.675-683>
- Pratama, I. G. S., & Wijaya, I. M. S. (2023). Rancang bangun sistem informasi bank sampah berbasis cloud-native dengan arsitektur real-time database. *Jurnal Nasional Teknologi dan Sistem Informasi*, 9(2), 112–121. <https://doi.org/10.25077/teknosi.v9i2.350>

- Rani, M. R., Mustafar, M. Z. C., Ismail, N. H. F., Mansor, M. S. F., & Zainuddin, Z. (2021). Road peculiarities detection using deep learning for vehicle vision system. *IOP Conference Series: Materials Science and Engineering*, 1068, 012001. <https://doi.org/10.1088/1757-899X/1068/1/012001>
- Terven, J., & Cordova-Esparza, D. (2023). A comprehensive review of YOLO architectures in computer vision: From YOLOv1 to YOLOv8. *Machine Learning and Knowledge Extraction*, 5(4), 1680–1716. <https://doi.org/10.3390/make5040083>
- Wang, M. H., Yu, Y., Lin, Z., Zeng, P., Liu, H., Liu, Y., Hu, W., Fang, X., Jiang, X., Chen, G., Hou, G., Chong, K. K., & Yu, X. (2023). Optimizing Real-Time Trichiasis Object Detection: A Comparative Analysis of YOLOv5 and YOLOv8 Performance Metrics. *2023 9th International Conference on Systems and Informatics (ICSAI)*, 1–5. <https://doi.org/10.1109/ICSAI61474.2023.10423285>
- Zahrah, Y., Yu, J., & Liu, X. (2024). How Indonesia's cities are grappling with plastic waste: An integrated approach towards sustainable plastic waste management. *Sustainability*, 16(10), 3921. <https://doi.org/10.3390/su16103921>
- Zaidi, S. S. A., Ansari, M. S., Aslam, A., Kanwal, N., Asghar, M., & Lee, B. (2022). A survey of modern deep learning based object detection models. *Digital Signal Processing*, 126, 103514. <https://doi.org/10.1016/j.dsp.2022.103514>
- Zhang, C., Zhang, C., Li, C., & Qiao, Y. (2024). A survey on generative AI and large language models: Recent advances and future trends. *Expert Systems with Applications*, 238, 122268. <https://doi.org/10.1016/j.eswa.2023.122268>