



Sistem Pencatatan Barang Masuk Gudang Berbasis Identifikasi Frekuensi Radio dan Pengenalan Visual Kondisional

Zefanya Rivaldy Fattihandel Machmud*, Ali Akbar Steven Ramschie, Ronny Evert Katuuk

Program Studi Teknik Informatika, Politeknik Negeri Manado, Manado, Indonesia

Email: ^{1,*}machmudzefanya@gmail.com, ²ali.a.s.ramschie@gmail.com, ³katuukronny@gmail.com

Email Penulis Korespondensi: machmudzefanya@gmail.com

Abstrak—Proses pencatatan barang masuk di gudang Multimart Tomohon saat ini masih sepenuhnya manual menggunakan kertas dan spreadsheet, sehingga menimbulkan empat masalah sistemik: kesalahan entri data akibat kelelahan manusia, keterlambatan pembaruan stok yang menghambat pengambilan keputusan real-time, ketidakmampuan menelusuri riwayat barang secara andal, dan tidak adanya mekanisme verifikasi silang antara jumlah yang diklaim pemasok dengan jumlah fisik yang diterima. Penelitian ini bertujuan merancang dan menguji prototipe sistem pencatatan barang masuk berbasis Internet of Things yang mengintegrasikan identifikasi frekuensi radio (RFID), sensor infrared, Optical Character Recognition (OCR), dan Convolutional Neural Network (CNN) dalam arsitektur dua box yang dihubungkan melalui belt conveyor. Metodologi pengembangan mengikuti model SDLC Prototyping yang terdiri dari lima tahapan iteratif: pengumpulan kebutuhan, desain cepat, konstruksi prototipe, evaluasi dan pengujian, serta penyempurnaan. Arsitektur MobileNetV2 dipilih sebagai backbone CNN karena menggunakan depthwise separable convolution yang menghasilkan model ringan dengan akurasi kompetitif, cocok untuk server yang juga memproses data RFID secara bersamaan. Pengujian RFID membuktikan pembacaan tag akurat pada jarak 1-4 cm dengan kecepatan conveyor lambat hingga sedang (~3-8 cm/s), sedangkan pada jarak 5-7 cm atau kecepatan tinggi (~15 cm/s) pembacaan menjadi tidak andal. Pelatihan model CNN MobileNetV2 dengan 30 foto per kelas menunjukkan konvergensi akurasi validasi hingga 100% pada epoch ke-4 hingga 5 dalam kondisi dataset kecil dan terkontrol; hasil ini bersifat kondisi-spesifik dan memerlukan pelatihan ulang penuh setiap kali kelas produk baru ditambahkan. Pengujian identifikasi real-time mengonfirmasi CNN mendominasi identifikasi produk dengan kemasan tidak terhalang (kepercayaan 94%), sementara OCR berfungsi sebagai fallback untuk kemasan yang terhalang label, dengan throughput 66,7 FPS. Kontribusi utama penelitian ini meliputi rancangan arsitektur dua box yang sekaligus menyelesaikan masalah interferensi sensor dan menghadirkan mekanisme deteksi kecurangan melalui verifikasi silang hitungan RFID dengan hitungan fisik infrared, pipeline identifikasi kondisional OCR/CNN yang mampu menangani seluruh variasi produk terlepas dari ketersediaan kode SKU, serta bukti empiris kelayakan sistem yang dapat digeneralisasikan ke konteks gudang ritel kecil hingga menengah.

Kata Kunci: IoT; RFID; OCR; CNN; MobileNetV2

Abstract—The process of recording incoming goods at the Multimart Tomohon warehouse is currently entirely manual using paper and spreadsheets, resulting in four systemic problems: data entry errors due to human fatigue, delays in stock updates that hinder real-time decision-making, the inability to reliably track item history, and the absence of a cross-verification mechanism between supplier-claimed quantities and physical quantities received. This research aims to design and test a prototype of an Internet of Things-based incoming goods recording system that integrates radio frequency identification (RFID), infrared sensors, Optical Character Recognition (OCR), and a Convolutional Neural Network (CNN) in a two-box architecture connected by a belt conveyor. The development methodology follows the SDLC Prototyping model consisting of five iterative stages: requirements gathering, rapid design, prototype construction, evaluation and testing, and refinement. The MobileNetV2 architecture was chosen as the CNN backbone because it uses depthwise separable convolution that produces a lightweight model with competitive accuracy, suitable for servers that also process RFID data simultaneously. RFID testing demonstrated accurate tag reading at distances of 1-4 cm with slow to moderate conveyor speeds (~3-8 cm/s), while at distances of 5-7 cm or high speeds (~15 cm/s) readings became unreliable. Training a MobileNetV2 CNN model with 30 photos per class on the Multimart Tomohon product dataset demonstrated convergence to 100% validation accuracy at epoch 4-5 under small, controlled dataset conditions; these results are condition-specific for Box 1 LED strip lighting and require full retraining each time a new product class is added. Real-time identification testing confirmed that the CNN dominates the identification of products with unobstructed packaging (94% confidence level), while OCR serves as a fallback for products with visible SKU codes or label-obscured packaging, with a system throughput of 66.7 FPS. The key contributions of this research are a two-box architecture that simultaneously eliminates sensor interference and enables automatic fraud detection through RFID-versus-infrared cross-verification, a conditional OCR/CNN pipeline capable of handling all product types regardless of SKU availability, and empirical evidence of system feasibility generalizable to small and medium retail warehouse contexts.

Keywords: IoT; RFID; OCR; CNN; MobileNetV2

1. PENDAHULUAN

Perkembangan teknologi Internet of Things (IoT) telah mendorong transformasi digital di berbagai sektor industri, termasuk manajemen gudang ritel. Gudang merupakan komponen kritis dalam rantai pasok, di mana akurasi dan kecepatan pencatatan barang masuk sangat menentukan efisiensi operasional secara keseluruhan (Atzori et al., 2010). Dalam konteks Industry 4.0, integrasi perangkat fisik dengan sistem informasi digital semakin diakui sebagai prasyarat bagi operasional rantai pasok yang kompetitif dan bebas dari kesalahan (Zhong et al., 2017).

Multimart Tomohon adalah sebuah toko ritel yang berlokasi di Matani tiga, Kec. Tomohon Tengah, Tomohon, Sulawesi Utara, Indonesia. Berdasarkan observasi langsung yang dilakukan dalam penelitian ini, proses penerimaan barang masuk di gudang Multimart Tomohon dilakukan sepenuhnya secara manual staf mencatat nama produk, jumlah, tanggal, informasi pemasok, dan lokasi penyimpanan di kertas atau spreadsheet. Pendekatan ini menimbulkan sejumlah masalah yang saling berkaitan. Kesalahan pencatatan akibat kelelahan manusia atau kekeliruan entri data kerap terjadi



dalam rutinitas penerimaan harian. Di saat yang sama, keterlambatan pembaruan stok menghalangi staf untuk mengambil keputusan inventaris secara real-time, sementara sulitnya menelusuri riwayat barang masuk mempersulit proses audit dan pelaporan. Yang paling kritis, tidak ada mekanisme verifikasi silang antara jumlah yang dinyatakan pemasok dengan jumlah yang benar-benar diterima secara fisik, sehingga menciptakan lingkungan yang rentan terhadap kecurangan inventaris yang sulit terdeteksi (Prasetyo & Wibowo, 2022).

Teknologi Radio Frequency Identification (RFID) menyediakan mekanisme yang sudah mapan untuk identifikasi produk secara otomatis dan tanpa kontak fisik di lingkungan gudang. Beberapa penelitian sejenis telah mengeksplorasi penerapan RFID dalam manajemen gudang. Fuentes-Penna et al. (2022) melakukan tinjauan literatur sistematis terhadap sistem manajemen gudang berbasis RFID dan menyimpulkan bahwa RFID mampu meningkatkan akurasi data inventaris secara signifikan dibanding sistem manual. Bakar et al. (2020) mengembangkan sistem manajemen gudang berbasis RFID khusus untuk usaha ritel kecil dan menengah, namun sistem yang dihasilkan hanya mengandalkan RFID tanpa mekanisme identifikasi cadangan ketika tag tidak terbaca. Murugasen & Ponnambalam (2020) mengusulkan sistem penerimaan barang otomatis yang mengombinasikan RFID dengan pemrosesan gambar dasar, tetapi tidak menangani kasus produk tanpa tag RFID maupun produk dengan kemasan serupa. Zhang et al. (2021) mengintegrasikan machine learning ke dalam sistem manajemen gudang berbasis RFID untuk meningkatkan akurasi prediksi stok, namun fokusnya pada prediksi permintaan, bukan identifikasi produk. Li et al. (2022) mengkaji integrasi computer vision dan RFID untuk otomatisasi gudang cerdas, dan menemukan bahwa kombinasi keduanya menghasilkan akurasi identifikasi yang lebih tinggi dibanding RFID saja. Namun demikian, RFID saja tidak cukup ketika tag produk tidak tersedia, ketika beberapa produk memiliki kemasan yang identik atau serupa, atau ketika jarak baca dan kecepatan konveyor melampaui batas operasional andal modul tersebut (Memon et al., 2021; Afifah et al., 2021).

Untuk mengatasi keterbatasan tersebut, penelitian ini mengintegrasikan mekanisme identifikasi visual kondisional menggunakan kamera yang dipasangkan dengan dua teknik komplementer: Optical Character Recognition (OCR) menggunakan Tesseract untuk membaca kode SKU yang tercetak pada kemasan produk, dan Convolutional Neural Network (CNN) berbasis arsitektur MobileNetV2 untuk mengklasifikasikan produk berdasarkan tampilan visual kemasannya ketika kode SKU tidak tersedia atau terhalang (Smith, 2005). MobileNetV2 dipilih karena rasio akurasi terhadap efisiensi yang menguntungkan dalam lingkungan penerapan dengan sumber daya terbatas (Howard et al., 2019). Penelitian terbaru telah menunjukkan efektivitas penggabungan RFID dengan computer vision untuk meningkatkan akurasi identifikasi di gudang (Zhang et al., 2021; Li et al., 2022). Berdasarkan kajian terhadap penelitian-penelitian tersebut, terdapat tiga celah penelitian (GAP) yang belum ditangani secara bersamaan: pertama, belum ada sistem yang menyediakan mekanisme identifikasi cadangan berbasis OCR dan CNN secara kondisional ketika RFID gagal membaca tag; kedua, tidak ada sistem yang mengimplementasikan penghitungan fisik independen sebagai verifikasi silang terhadap jumlah RFID untuk mendeteksi kecurangan pada level hardware; dan ketiga, belum ada penelitian yang secara eksplisit memisahkan unit identifikasi dan unit penghitungan dalam dua box terpisah guna mengeliminasi interferensi elektromagnetik dan optis antara komponen sensor. Penelitian ini hadir untuk mengisi ketiga celah tersebut secara terintegrasi dalam satu prototipe sistem.

Inovasi hardware utama dalam penelitian ini adalah desain prototipe dua box yang terinspirasi dari sistem pemindaian bagasi di bandara. Box 1 berfungsi sebagai unit identifikasi produk, menampung RFID reader RC522, kamera, dan LED strip 5V untuk pencahayaan terkontrol, sedangkan Box 2 berfungsi sebagai penghitung barang independen menggunakan dua sensor infrared E18-D80NK. Pemisahan fisik kedua box mengeliminasi interferensi elektromagnetik dan optis antara LED strip kamera dengan sensor infrared, sekaligus memungkinkan penghitungan item fisik secara independen yang dapat diverifikasi silang terhadap jumlah yang dicatat oleh RFID. Berbeda dengan penelitian sebelumnya yang hanya menggunakan RFID sebagai satu-satunya sumber data (Bakar et al., 2020; Fuentes-Penna et al., 2022), penelitian ini menambahkan lapisan verifikasi fisik melalui sensor infrared yang memungkinkan deteksi ketidaksesuaian antara jumlah yang diklaim pemasok dengan jumlah aktual yang diterima. Verifikasi silang ini menghadirkan mekanisme deteksi kecurangan otomatis pada level hardware yang tidak ada dalam sistem gudang berbasis RFID single-box manapun yang ditinjau dalam literatur.


Tujuan penelitian ini adalah merancang dan menguji prototipe sistem pencatatan barang masuk berbasis Internet of Things yang memadukan RFID, sensor infrared, OCR, dan CNN secara kondisional dalam arsitektur dua box yang terhubung melalui belt conveyor. Sebagai pembanding, sistem manual yang saat ini digunakan di Multimart Tomohon dijadikan baseline untuk mengevaluasi peningkatan pada enam dimensi operasional: kecepatan pencatatan, akurasi data, verifikasi hitungan, kemampuan penelusuran riwayat, deteksi kecurangan, dan ketepatan waktu pembaruan stok. Dari sisi teknologi, penelitian ini memposisikan dirinya relatif terhadap sistem RFID single-source yang dikembangkan oleh Bakar et al. (2020) dan Fuentes-Penna et al. (2022) dengan menambahkan lapisan identifikasi visual kondisional dan verifikasi fisik yang absen dari pendekatan tersebut. Penelitian ini mencakup pengujian prototipe awal yang meliputi uji jarak dan kecepatan RFID pada dua rentang jarak dan tiga level kecepatan, eksperimen pelatihan model CNN pada beberapa sesi, serta pengujian identifikasi OCR/CNN secara real-time pada tiga skenario representatif, dengan metodologi pengembangan mengikuti model SDLC Prototyping (Pressman & Maxim, 2015). Penelitian ini memberikan tiga kontribusi utama. Pertama, rancangan arsitektur dua box yang menyelesaikan masalah interferensi sensor sekaligus menghadirkan mekanisme deteksi kecurangan berbasis penghitungan fisik independen melalui verifikasi silang RFID versus infrared kemampuan yang belum ditemukan pada sistem RFID single-box yang ditinjau dalam literatur. Kedua, pipeline identifikasi kondisional OCR/CNN yang mampu menangani seluruh variasi produk terlepas dari ketersediaan kode SKU, memastikan setiap item tetap teridentifikasi meskipun RFID gagal membaca tag. Ketiga, bukti empiris dari

pengujian prototipe yang memvalidasi kelayakan teknis sistem dan dapat digeneralisasikan ke konteks gudang ritel kecil hingga menengah yang serupa.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Penelitian ini mengikuti model SDLC Prototyping yang terdiri dari lima tahapan iteratif. Tahap 1 (Pengumpulan Kebutuhan): observasi langsung tiga kali kunjungan lapangan ke gudang Multimart Tomohon untuk memetakan alur kerja penerimaan barang dan wawancara terstruktur dengan tiga staf gudang serta manajer gudang. Tahap 2 (Desain Cepat): perancangan arsitektur sistem tiga lapisan (hardware, komunikasi, aplikasi), desain hardware dua box, rancangan alur kerja tujuh langkah, dan skema database MySQL empat tabel. Tahap 3 (Konstruksi Prototipe): perakitan Box 1 (RFID reader RC522, kamera, LED strip) dan Box 2 (sensor infrared E18-D80NK), pemrograman mikrokontroler ESP32, pengembangan server Python dengan OpenCV, Tesseract OCR, dan TensorFlow/MobileNetV2, serta pengembangan dasbor web. Tahap 4 (Evaluasi dan Pengujian): pengujian RFID pada dua rentang jarak dan tiga level kecepatan, pelatihan model CNN dengan eksperimen multi-sesi, dan pengujian identifikasi real-time pada tiga skenario produk. Tahap 5 (Penyempurnaan): penyesuaian parameter berdasarkan hasil pengujian, termasuk kalibrasi kecepatan belt dan ambang batas kepercayaan CNN. Alur tahapan penelitian secara keseluruhan ditunjukkan pada Gambar 1 berikut.



Gambar 1. Tahapan Penelitian Model SDLC Prototyping

2.2 Kajian Pustaka RFID

Radio Frequency Identification (RFID) adalah teknologi identifikasi nirkabel yang menggunakan gelombang elektromagnetik untuk membaca dan menuliskan data pada tag atau transponder (Finkenzeller, 2010). Sistem RFID terdiri dari tiga komponen utama: reader (pembaca), antenna, dan tag. Reader RC522 yang digunakan dalam penelitian ini beroperasi pada frekuensi 13,56 MHz dan mengimplementasikan protokol komunikasi ISO/IEC 14443 untuk kartu/tag pasif. Jarak baca efektif RC522 berkisar antara 0-5 cm tergantung pada orientasi tag, material kemasan, dan kecepatan relatif antara tag dan antenna (Afifah et al., 2021). Dalam sistem manajemen gudang, RFID digunakan untuk mengotomatiskan pencatatan pergerakan barang tanpa memerlukan kontak fisik atau garis pandang langsung, sehingga memungkinkan identifikasi lebih cepat dibanding barcode konvensional (Bakar et al., 2020; Fuentes-Penna et al., 2022).



Data primer penelitian ini dikumpulkan melalui observasi langsung di gudang Multimart Tomohon dan wawancara terstruktur. Data sekunder diperoleh melalui tinjauan literatur sistematis pada artikel jurnal peer-reviewed dan prosiding konferensi tahun 2019-2023, difokuskan pada sistem RFID, CNN, dan OCR dalam konteks manajemen gudang.

2.3 Kajian Pustaka CNN dan MobileNetV2

Convolutional Neural Network (CNN) adalah arsitektur deep learning yang dirancang khusus untuk pemrosesan data grid seperti gambar, menggunakan lapisan konvolusi untuk mengekstraksi fitur hierarkis secara otomatis (LeCun et al., 1998 dalam Sandler et al., 2018). MobileNetV2, yang diperkenalkan oleh Sandler et al. (2018)(Sandler et al., 2018), adalah arsitektur CNN ringan yang menggunakan depthwise separable convolution dan inverted residual blocks untuk mengurangi jumlah parameter dan kompleksitas komputasi secara signifikan dibanding arsitektur konvensional seperti VGG atau ResNet, sambil mempertahankan akurasi yang kompetitif. Arsitektur ini dipilih dalam penelitian ini karena kemampuannya beroperasi efisien pada perangkat dengan sumber daya komputasi terbatas (Howard et al., 2019). Transfer learning dari bobot ImageNet digunakan untuk memanfaatkan fitur visual generik yang sudah dipelajari model, sehingga dataset kecil (30 gambar per kelas) dapat menghasilkan model yang fungsional untuk domain spesifik (Saragih et al., 2023; Setiawan et al., 2024).

Tabel 1. Arsitektur Sistem Tiga Lapisan

Layer	Components	Function
Hardware	ESP32 (x2), RFID RC522, Camera Module, LED Strip (5V), IR E18-D80NK (x2), DC Motor	Physical identification, counting, and transport
Communication	JGA25-370, L298N Driver, Belt Conveyor	
	WiFi 2.4 GHz, REST API, HTTP Protocol	Data transmission from ESP32 to server
Application	Python, OpenCV, Tesseract OCR, TensorFlow / MobileNetV2, MySQL, Web Dashboard	Processing, storage, and visualization

2.4 Kajian Pustaka Tesseract OCR

Optical Character Recognition (OCR) adalah teknologi untuk mengenali teks tercetak atau tulisan tangan dari gambar digital dan mengonversinya menjadi teks yang dapat diedit secara digital. Tesseract adalah mesin OCR open-source yang dikembangkan oleh Google, pertama kali dideskripsikan oleh Smith (2007)(Smith, 2005) dan saat ini berada pada versi 5.x dengan dukungan jaringan saraf tiruan berbasis LSTM untuk peningkatan akurasi pada teks kompleks. Dalam konteks manajemen inventaris, OCR digunakan untuk membaca kode SKU (Stock Keeping Unit), nomor seri, atau barcode alfanumerik yang tercetak pada kemasan produk tanpa memerlukan dataset pelatihan khusus, menjadikannya komplementer dengan CNN yang berbasis pengenalan visual (Wahyudi & Kusuma, 2022). Logika kondisional pipeline identifikasi dalam penelitian ini bekerja sebagai berikut: setelah gambar kemasan diambil oleh kamera Box 1 dan diproses melalui pra-pemrosesan OpenCV (resize, normalisasi kecerahan, noise reduction), sistem pertama-tama mendeteksi keberadaan kode SKU pada gambar; jika kode SKU terdeteksi, Tesseract OCR dijalankan untuk membaca kode tersebut dan hasilnya divalidasi terhadap database products; jika validasi OCR berhasil, produk diidentifikasi melalui jalur OCR; jika validasi OCR gagal atau kode SKU tidak terdeteksi sejak awal, CNN MobileNetV2 dijalankan untuk mengklasifikasikan produk berdasarkan visual kemasan; jika skor kepercayaan CNN melampaui ambang batas yang dikonfigurasi, produk diidentifikasi melalui jalur CNN; jika skor kepercayaan CNN di bawah ambang batas, item ditandai sebagai LOW_CONF dan memerlukan verifikasi manual oleh staf gudang. Alur logika kondisional ini secara lengkap divisualisasikan pada Gambar 2 di bagian Hasil dan Pembahasan.

Hardware terdiri dari dua box yang dipisahkan secara fisik dan dihubungkan oleh satu belt conveyor. Box 1 (Unit Identifikasi Produk) berukuran sekitar 40×20×20 cm, dibuat dari panel akrilik atau MDF. Di dalamnya terdapat modul RFID reader RC522 yang dipasang di titik masuk conveyor, modul kamera yang diposisikan di atas permukaan conveyor, serta LED strip 5V yang dipasang di sepanjang dinding interior untuk memberikan pencahayaan yang konsisten dan terkontrol bagi pengambilan gambar terlepas dari kondisi cahaya sekitar.

2.5 Model Pengembangan SDLC Prototyping

Software Development Life Cycle (SDLC) model Prototyping adalah pendekatan pengembangan sistem yang mengutamakan pembangunan prototipe awal yang dapat dievaluasi oleh pengguna sebelum sistem final dikembangkan sepenuhnya (Pressman & Maxim, 2015). Model ini dipilih dalam penelitian ini karena kebutuhan operasional staf gudang Multimart Tomohon paling baik dielisisasi melalui siklus iteratif bangun-evaluasi-perbaiki, dibandingkan dengan pendekatan sekuensial seperti Waterfall yang mengharuskan spesifikasi kebutuhan lengkap di awal. Prototyping juga memungkinkan pengujian fisik komponen secara bertahap, RFID, CNN, dan infrared secara terpisah sebelum integrasi penuh, sehingga kesalahan desain dapat diidentifikasi dan diperbaiki lebih awal dalam siklus pengembangan.

Box 2 (Unit Penghitung Barang) berukuran sekitar 20×20×20 cm dan memuat dua sensor infrared E18-D80NK yang dipasang pada sisi berlawanan dari jalur conveyor, membentuk gerbang deteksi yang menghitung setiap item yang melintas, konsisten dengan konfigurasi penghitung infrared pada conveyor industri yang dijelaskan oleh Wibowo &


Handoko (2021). Belt konveyor digerakkan oleh motor DC JGA25-370 melalui driver L298N dengan kontrol PWM untuk pengaturan kecepatan. Rancangan hardware lengkap akan dijabarkan pada bagian Hasil dan Pembahasan.

3. HASIL DAN PEMBAHASAN

3.1 Hasil Perancangan Sistem

Berdasarkan tahapan desain yang telah dilakukan, dihasilkan arsitektur sistem tiga lapisan sebagaimana dirangkum dalam Tabel 1. Sistem dirancang dengan dua mikrokontroler ESP32 yang beroperasi secara independen: ESP32 di Box 1 menangani pembacaan tag RFID dan pengambilan gambar kamera, sedangkan ESP32 di Box 2 mengelola penghitungan sensor infrared. Keduanya mengirimkan data ke server eksternal melalui WiFi menggunakan panggilan REST API berbasis HTTP (Nurdin & Sari, 2022; Espressif Systems, 2023; Purnomo & Santoso, 2023). Server menjalankan logika pemrosesan berbasis Python untuk analisis gambar dan menyimpan seluruh catatan transaksi dalam database MySQL yang dapat diakses melalui dasbor web secara real-time.

Alur kerja sistem end-to-end terdiri dari tujuh langkah berurutan sebagaimana diilustrasikan pada Gambar 2: (1) staf gudang menempatkan item di ujung masuk belt konveyor; (2) motor DC menggerakkan belt pada kecepatan yang dikonfigurasi; (3) RFID reader RC522 di Box 1 mencoba membaca tag RFID item; (4) kamera di Box 1 menangkap gambar kemasan di bawah pencahayaan LED strip; (5) server memproses gambar melalui pipeline kondisional OCR jika kode SKU terdeteksi, CNN jika tidak; (6) sensor infrared E18-D80NK di Box 2 menghitung item secara fisik; dan (7) server membandingkan hitungan RFID dengan hitungan fisik, menandai ketidaksesuaian, dan menyimpan transaksi terverifikasi ke MySQL. Database relasional MySQL disusun dengan empat tabel: products, supplier, incoming_goods (berisi rfid_count dan physical_count untuk verifikasi silang), dan identification_log (berisi skor kepercayaan OCR/CNN untuk audit trail).




Gambar 2. Alur Kerja Sistem End-to-End Pencatatan Barang Masuk

Hasil pengujian yang dirangkum pada Tabel 2 menunjukkan pola yang jelas dan konsisten: RFID reader RC522 secara andal mendeteksi tag ketika kartu berada dalam jarak 1 hingga 4 cm dari kumparan reader dan melintas pada kecepatan lambat hingga sedang. Pada kecepatan lambat (~ 3 cm/s), waktu diam kartu dalam medan elektromagnetik cukup untuk menyelesaikan handshake komunikasi ISO/IEC 14443 dan mengembalikan UID tag. Pada kecepatan sedang (~ 8 cm/s), waktu diam masih cukup secara marginal. Pada kecepatan tinggi (~ 15 cm/s), waktu diam turun di bawah durasi minimum yang diperlukan RC522, mengakibatkan pembacaan yang terlewat. Keterbatasan jarak baca 1-4 cm ini merupakan kendala hardware yang nyata dalam implementasi skala penuh; pada gudang nyata, penempatan antenna RC522 dan regulasi kecepatan belt melalui kontrol PWM pada driver L298N menjadi faktor kritis yang harus dikalibrasi secara presisi untuk memastikan setiap item melintas dalam zona baca optimal.

Tabel 2. Pengujian Scanner RFID

Distance	Speed	Result	Notes
1-4 cm	Slow	✓ Accurate	Tag read consistently on every pass
1-4 cm	Medium	✓ Accurate	Tag read consistently on every pass
1-4 cm	Fast	✗ Failed / Missed	Insufficient dwell time within read field
5-7 cm	Slow	~ Intermittent	Occasional miss; field strength borderline
5-7 cm	Medium	✗ Failed	Read unreliable at this distance
5-7 cm	Fast	✗ Failed	Tag not detected

Pengujian dilakukan menggunakan modul RFID reader RC522 yang terhubung ke mikrokontroler ESP32 di atas breadboard, dengan kartu RFID sebagai representasi tag produk. Kartu diposisikan secara vertikal di depan antenna reader pada dua rentang jarak yang berbeda untuk mengamati pengaruh jarak terhadap keberhasilan pembacaan. Gambar 3(a) menunjukkan kondisi pengujian pada jarak 3 cm antara kartu RFID dan antenna reader RC522. Pada jarak ini, kartu berhasil terbaca secara konsisten pada setiap percobaan, baik pada kecepatan lambat maupun sedang. Indikator LED merah pada modul RC522 terlihat aktif, menandakan bahwa modul sedang beroperasi dan medan elektromagnetik terbentuk dengan intensitas yang cukup untuk menyelesaikan komunikasi protokol ISO/IEC 14443 dengan tag. Gambar 3(b) menunjukkan kondisi pengujian pada jarak 6 cm, masih dalam rentang 5-7 cm yang diuji. Pada jarak ini, intensitas medan elektromagnetik yang dihasilkan antenna RC522 tidak lagi cukup untuk menginduksi tegangan pada kumparan tag secara andal, sehingga pembacaan gagal atau tidak konsisten. Perbandingan kedua kondisi pengujian ini secara visual memperjelas bahwa terdapat batas jarak fisik yang signifikan pada modul RC522, di mana penurunan jarak dari 6 cm ke 3 cm menghasilkan perbedaan performa yang sangat nyata antara gagal dan berhasil secara penuh. Hasil ini menjadi dasar penetapan rentang operasional sistem, yaitu tag RFID harus melintas dalam jarak maksimal 4 cm dari antenna reader agar pencatatan barang masuk dapat berjalan secara andal.



Gambar 3. RFID read test pada: (a) jarak 3 cm kartu terbaca dan (b) jarak 6 cm, kartu tidak terbaca


Pada rentang jarak 5 hingga 7 cm, intensitas medan elektromagnetik turun di bawah ambang deteksi andal RC522, sesuai dengan spesifikasi jarak baca maksimum sekitar 5 cm dalam kondisi optimal (Finkenzeller, 2010; Afifah et al., 2021). Dua kendala hardware utama yang ditetapkan dari hasil ini adalah: (1) belt konveyor harus dikonfigurasi pada kecepatan lambat hingga sedang melalui kontrol PWM pada driver L298N, dan (2) antenna reader RC522 harus diposisikan agar item bertag melintas dalam jarak 1-4 cm dari kumparan reader melalui dudukan antenna yang dapat disesuaikan.

Keterbatasan RFID ini juga memperkuat peran kritis pipeline identifikasi visual kondisional: ketika pembacaan RFID gagal akibat tidak adanya tag, jarak, atau faktor kecepatan, identifikasi CNN atau OCR memastikan item tetap dicatat dengan benar, mencegah entri yang tidak tercatat dalam database transaksi barang masuk.


3.2 Pelatihan Model CNN

Model CNN MobileNetV2 dilatih menggunakan pendekatan transfer learning yang dijelaskan dalam metodologi. Dataset awal terdiri dari 30 foto per kelas produk, yang diambil dalam berbagai orientasi dan kondisi pencahayaan menggunakan kamera dan setup LED strip yang sama dengan unit identifikasi Box 1. Beberapa sesi pelatihan dilakukan

untuk menilai perilaku konvergensi model dan mengidentifikasi pengaruh ukuran dataset serta komposisi kelas terhadap stabilitas pelatihan. Gambar 4 dan 5 menyajikan kurva akurasi pelatihan dan loss dari dua sesi pelatihan pertama pada dataset awal dengan 30 gambar per kelas.




Gambar 4. Latihan sesi 1, akurasi and loss curves (30 images/class)




Gambar 5. Latihan sesi 2, akurasi and loss curves (30 images/class)

Pada kedua sesi, Train Accuracy konvergen ke 100% pada epoch 4-5, dan Validation Accuracy (Val Acc) mencapai dan bertahan di 100% sejak epoch 1 hingga 8. Train Loss turun tajam dari 0,60 (sesi 1) dan 0,43 (sesi 2) mendekati nol dalam 2-3 epoch, sementara Val Loss tetap konsisten mendekati nol. Penting untuk dicatat bahwa konvergensi Val Acc ke 100% ini terjadi dalam konteks dataset yang sangat kecil (30 gambar per kelas) dengan kondisi pengambilan gambar yang seragam dan terkontrol (pencahayaan LED strip konsisten di Box 1). Angka akurasi 100% pada dataset sekecil ini patut disikapi secara kritis: dalam literatur machine learning, akurasi validasi sempurna pada dataset kecil umumnya mengindikasikan salah satu dari dua kemungkinan - pertama, model berhasil memanfaatkan fitur transfer learning ImageNet yang sudah sangat kaya untuk mendiskriminasi kelas-kelas visual yang memang memiliki perbedaan tampilan yang jelas; atau kedua, terdapat risiko data leakage implisit akibat variasi dataset yang terlalu terbatas sehingga split train/validation tidak benar-benar merepresentasikan distribusi data lapangan yang sesungguhnya (Saragih et al., 2023). Untuk konteks penelitian ini, interpretasi pertama lebih mungkin karena produk-produk yang diuji memiliki kemasan yang berbeda secara visual, namun penulis mengakui bahwa validasi pada dataset yang lebih besar dan lebih beragam mencakup variasi orientasi, kondisi pencahayaan berbeda, dan kemasan yang mengalami kerusakan diperlukan sebelum angka akurasi ini dapat dianggap representatif untuk kondisi gudang nyata. Hasil ini tidak dapat digeneralisasikan secara langsung ke kondisi pencahayaan atau variasi kemasan yang berbeda. Pola konvergensi yang cepat ini mengindikasikan bahwa fitur ImageNet pra-latih MobileNetV2 menggeneralisasi secara efektif ke tugas klasifikasi kemasan produk pada dataset kecil, konsisten dengan temuan Saragih et al. (2023) dan Howard et al. (2019), namun kualitas dan diversitas dataset perlu ditingkatkan secara signifikan pada fase implementasi penuh.

Untuk mengevaluasi generalisasi ketika kategori produk baru diperkenalkan skenario yang diharapkan seiring Multimart Tomohon memperluas inventaris produknya sesi pelatihan tambahan dilakukan pada dataset yang diperluas dengan kelas produk baru. Gambar 6 dan 7 menampilkan kurva pelatihan untuk sesi-sesi tersebut.



Gambar 6. Pelatihan dengan kelas produk baru ditambahkan (percobaan pertama ketidakstabilan lebih tinggi)



Gambar 7. Pelatihan ulang dengan kelas produk baru (konvergensi yang lebih baik setelah pelatihan ulang)


Gambar 6 menunjukkan instabilitas yang jauh lebih tinggi dibandingkan sesi pelatihan awal: Val Acc berfluktuasi antara 0,65 dan 0,95 di seluruh epoch, dan Val Loss berosilasi secara signifikan sebelum menunjukkan tren menurun. Instabilitas ini disebabkan oleh ketidakseimbangan kelas kelas produk yang baru ditambahkan memiliki lebih sedikit sampel pelatihan dibanding kelas yang sudah ada dan oleh pergeseran distribusi yang terjadi ketika model harus mengakomodasi kategori visual baru tanpa pelatihan ulang penuh (Howard et al., 2019). Gambar 7 menunjukkan bahwa melakukan pelatihan ulang model secara penuh dengan dataset yang seimbang (menyamakan jumlah gambar per kelas di semua kategori) secara substansial menyelesaikan instabilitas ini: Val Acc stabil di 100% pada epoch 4, dan Val Loss konvergen mendekati nol pada epoch 3, menyerupai kurva bersih dari sesi 1 dan 2.

Hasil pelatihan ini menghasilkan dua panduan operasional penting: (1) setiap kelas produk memerlukan minimal 30 gambar pelatihan berlabel yang diambil dalam kondisi pencahayaan LED strip terkontrol yang sama dengan Box 1; dan (2) model CNN harus dilatih ulang secara penuh pada dataset yang lengkap dan seimbang setiap kali kelas produk baru ditambahkan fine-tuning parsial menimbulkan instabilitas yang menurunkan akurasi secara keseluruhan. Kebutuhan pelatihan ulang penuh ini merupakan keterbatasan operasional yang harus dipertimbangkan dalam implementasi skala gudang nyata, di mana rotasi produk terjadi secara regular. Solusi yang direkomendasikan adalah menjadwalkan sesi pelatihan ulang berkala dan mengintegrasikan antarmuka penambahan produk baru yang memandu staf gudang dalam mengumpulkan gambar pelatihan yang cukup sebelum produk baru diaktifkan dalam sistem.

3.3 Pengujian Identifikasi CNN dan OCR Secara Real-Time


Setelah pelatihan model, sistem diuji untuk identifikasi produk secara real-time menggunakan webcam dan pipeline server yang dijelaskan dalam metodologi. Tiga skenario pengujian representatif dievaluasi untuk menilai perilaku sistem di seluruh rentang jenis produk dan objek yang diharapkan dalam penggunaan gudang.

Skenario pertama menguji identifikasi CNN untuk produk terdaftar dengan kemasan yang tidak terhalang. Gambar 8 memperlihatkan hasilnya.



Gambar 8. Hasil identifikasi CNN, kotak Infinix Note 50 Pro terdeteksi dengan kepercayaan 94% (mode CNN, bounding box kuning)

Sistem berhasil mengidentifikasi kotak Infinix Note 50 Pro dengan skor kepercayaan CNN sebesar 94%, ditampilkan sebagai 'Box [94%]' dengan bounding box kuning dan indikator mode 'CNN' di sudut kiri atas. Skor kepercayaan tinggi ini menunjukkan bahwa model MobileNetV2 yang telah dilatih secara andal mengenali produk dengan visual kemasan yang khas ketika wajah produk penuh terlihat dan diterangkan dengan baik. Sistem berjalan pada 66,7 FPS selama pengujian ini, menunjukkan bahwa pipeline identifikasi visual menambahkan latensi yang dapat diabaikan pada alur kerja pencatatan secara keseluruhan. Skenario kedua menguji perilaku penolakan sistem ketika objek tidak terdaftar dihadapkan pada kamera. Gambar 9 memperlihatkan hasilnya.



Gambar 9. Hasil LOW_CONF, objek tidak terdaftar (tangan) diberi label 'Tidak dikenali' dengan kepercayaan 57% (bounding box oranye)

Ketika sebuah tangan (objek tidak terdaftar di luar kelas pelatihan) dihadapkan pada kamera, sistem dengan benar menahan identifikasi positif, menampilkan 'Tidak dikenali (57%) [57%]' dengan bounding box oranye dan indikator 'LOW_CONF'. Mekanisme ambang batas kepercayaan sistem di mana identifikasi ditandai sebagai LOW_CONF daripada diterima berhasil mencegah penetapan false positive objek yang tidak relevan ke suatu kelas produk. Perilaku ambang batas ini sangat penting untuk penggunaan gudang, di mana objek bukan produk (tangan, bahan kemasan, clipboard) mungkin sering memasuki bingkai kamera selama proses penerimaan. Skenario ketiga menghadirkan produk terdaftar yang kemasannya sebagian terhalang oleh label harga atau SKU yang ditempelkan pada permukaan depannya. Gambar 10 memperlihatkan hasilnya.



Gambar 10. Hasil LOW_CONF, produk terdaftar (earphone Robot) dengan label penutup, 'Tidak dikenali' dengan kepercayaan 71%, memicu fallback OCR

Produk earphone merek Robot, yang termasuk dalam dataset pelatihan, dikembalikan sebagai 'Tidak dikenali (71%) [71%]' dengan klasifikasi LOW_CONF. Penyebabnya adalah terhalangnya visual kemasan produk yang khas oleh label yang ditempelkan, yang mencegah CNN mengekstraksi fitur visual yang telah dipelajari dari kelas produk tersebut. Skenario ini secara langsung memvalidasi rasionalitas desain untuk fallback OCR: label itu sendiri mengandung barcode SKU atau kode teks yang dapat dibaca mesin, yang dapat dibaca Tesseract OCR secara independen dari visual kemasan. Dalam pipeline kondisional, hasil CNN LOW_CONF memicu eskalasi otomatis ke pemrosesan OCR, memungkinkan identifikasi yang benar dari kode SKU label bahkan ketika visual kemasan terhalang.

Secara keseluruhan, ketiga skenario pengujian mengonfirmasi peran komplementer CNN dan OCR dalam pipeline identifikasi kondisional. CNN adalah metode identifikasi utama dan yang diutamakan untuk produk dengan visual kemasan yang jelas dan tidak terhalang sebagaimana dibuktikan oleh deteksi Infinix dengan kepercayaan 94%. OCR adalah metode sekunder yang diperlukan untuk produk yang kode SKU-nya lebih mudah diakses atau terlihat dibanding visual kemasan sebagaimana dibuktikan oleh kasus earphone Robot. Struktur kondisional adaptif ini konsisten dengan kerangka identifikasi hibrida yang dijelaskan oleh Li et al. (2022), Wahyudi & Kusuma (2022), dan Ramadhan et al. (2023), dan merepresentasikan peningkatan praktis dibanding pendekatan identifikasi metode tunggal yang digunakan dalam penelitian gudang RFID sebelumnya (Bakar et al., 2020; Fuentes-Penna et al., 2022). Penggunaan MobileNetV2 sebagai backbone juga sejalan dengan temuan Haq et al. (2022) dan Setiawan et al. (2024) yang mengkonfirmasi efektivitas arsitektur deep learning ringan untuk klasifikasi produk dalam kondisi dataset terbatas di lingkungan gudang.

Perlu juga dicatat bahwa identifikasi yang didominasi OCR di mana kode SKU adalah fitur utama yang dapat dibaca cenderung terjadi pada produk yang desain kemasannya tidak menghadirkan tanda visual yang cukup khas pada resolusi dan jarak kamera yang digunakan di Box 1. Temuan ini selaras dengan rasionalitas desain awal untuk



menyertakan kedua metode: kedua teknik menangani jenis produk yang berbeda daripada bersaing untuk tugas yang sama, menjadikan integrasinya komplementer daripada redundan.

3.4 Justifikasi Arsitektur Dua Box

Pemisahan fisik Box 1 (identifikasi) dan Box 2 (penghitungan) dibenarkan atas dua dasar teknis. Pertama, sensor infrared E18-D80NK beroperasi pada panjang gelombang 940 nm. LED strip 5V yang dipasang di Box 1 untuk pencahayaan kamera memancarkan cahaya pada spektrum luas yang mencakup komponen near-infrared. Ketika kedua unit berada dalam satu penutup yang sama atau berdekatan tanpa pelindung, emisi infrared LED strip menjenuhkan atau mendestabilisasi fotodiode penerima E18-D80NK, menghasilkan hitungan yang keliru. Pemisahan fisik mengeliminasi interferensi ini tanpa memerlukan hardware pelindung tambahan.

Kedua, struktur dua box memungkinkan hitungan fisik dari sensor infrared Box 2 berfungsi sebagai verifikasi independen terhadap jumlah item yang tercatat RFID. Jika pemasok mengantarkan 10 unit tetapi hanya 8 yang dilabeli RFID, RFID saja hanya akan mencatat 8; sensor infrared di Box 2 akan menghitung 10, dan sistem akan menandai ketidaksesuaian tersebut. Fungsionalitas verifikasi silang ini merupakan mekanisme deteksi kecurangan pada level hardware yang sama sekali tidak ada pada sistem gudang RFID single-sensor (Memon et al., 2021; Zhou et al., 2020).

3.5 Perbandingan dengan Sistem Manual

Tabel 3 menyajikan perbandingan langsung antara sistem manual yang saat ini digunakan di Multimart Tomohon dengan sistem prototipe otomatis yang diusulkan pada enam dimensi operasional.

Tabel 3. Perbandingan: Sistem Manual vs. Sistem Otomatis yang Diusulkan

Aspect	Manual System	Proposed System
Recording Speed	Slow - manual data entry	Real-time (automatic)
Data Accuracy	Prone to human error	High (RFID + visual ID)
Count Verification	None / manual recount	Automatic (IR sensor)
History Tracing	Difficult - paper records	Easy - digital database
Fraud Detection	None	Automatic (RFID vs physical count)
Stock Update	Delayed	Real-time

Berdasarkan Tabel 3, sistem yang diusulkan memberikan perbaikan pada keenam dimensi operasional dibandingkan sistem manual yang saat ini berjalan di Multimart Tomohon. Dari sisi kecepatan pencatatan, sistem manual yang bergantung pada entri data manual digantikan oleh pencatatan otomatis berbasis RFID dan sensor infrared yang berjalan secara real-time tanpa penundaan. Dari sisi akurasi data, sistem manual rentan terhadap kesalahan tulis yang disebabkan kelelahan atau kelalaian staf, sedangkan sistem yang diusulkan mengandalkan identifikasi RFID dan visual CNN/OCR sehingga peluang kesalahan manusia berkurang secara signifikan. Pada dimensi verifikasi jumlah, sistem manual tidak memiliki mekanisme penghitungan ulang otomatis, sementara sistem yang diusulkan menggunakan sensor infrared E18-D80NK di Box 2 untuk menghitung jumlah fisik item secara independen tanpa campur tangan staf. Dari sisi penelusuran riwayat, catatan berbasis kertas sulit ditelusuri dan mudah hilang, sedangkan semua transaksi pada sistem yang diusulkan tersimpan secara terstruktur di database MySQL dengan jejak audit lengkap yang bisa diakses kapan saja. Dimensi deteksi kecurangan adalah yang paling kritis: sistem manual tidak memiliki mekanisme apapun untuk mendeteksi ketidaksesuaian antara jumlah yang diklaim pemasok dengan jumlah yang benar-benar diterima, sedangkan sistem yang diusulkan secara otomatis menandai setiap discrepancy antara hitungan RFID di Box 1 dan hitungan fisik infrared di Box 2 sebagai peringatan yang tersimpan di database. Terakhir, pembaruan stok yang sebelumnya selalu terlambat karena harus menunggu proses pencatatan manual kini terjadi secara langsung bersamaan dengan proses penerimaan barang.

Sistem yang diusulkan mengatasi keenam defisiensi operasional yang diidentifikasi selama fase observasi awal. Peningkatan yang paling signifikan secara struktural adalah dimensi deteksi kecurangan, yang bertransisi dari tidak ada kemampuan pada sistem manual menjadi verifikasi silang otomatis fitur yang belum dilaporkan dalam penelitian gudang berbasis RFID sebelumnya yang secara khusus menargetkan sektor ritel kecil hingga menengah (Bakar et al., 2020; Memon et al., 2021). Hasil pengujian prototipe yang disajikan pada Bagian 3.1 hingga 3.3 memberikan dukungan empiris bagi klaim peningkatan akurasi, identifikasi, dan kecepatan dalam perbandingan ini.

3.6 Pembahasan

Temuan penelitian ini dapat dibandingkan dengan beberapa penelitian terdahulu yang relevan. Dari sisi kinerja RFID, Erlangga et al. (2022) mengembangkan sistem pemantauan inventaris real-time berbasis RFID di gudang dan melaporkan bahwa pembacaan tag berhasil dilakukan secara konsisten pada kondisi statis. Penelitian ini memperluas temuan tersebut dengan menguji pembacaan pada kondisi dinamis kartu bergerak dengan tiga level kecepatan berbeda dan menemukan bahwa kecepatan konveyor merupakan variabel kritis yang belum dibahas secara eksplisit dalam penelitian Erlangga et al. (2022). Fuentes-Penna et al. (2022) dalam tinjauan sistematis mereka terhadap sistem WMS berbasis RFID juga tidak membahas kendala jarak baca yang muncul dalam konteks konveyor otomatis, yang menjadi temuan penting dalam penelitian ini.



Dari sisi identifikasi visual berbasis CNN, Gulzar (2023) melatih MobileNetV2 untuk klasifikasi gambar buah dengan dataset 3.068 gambar dan mencapai akurasi 98,7%. Penelitian ini menggunakan dataset yang jauh lebih kecil (30 gambar per kelas) namun tetap mencapai akurasi validasi 100% dalam kondisi pencahayaan terkontrol, yang mengonfirmasi bahwa transfer learning dari ImageNet efektif bahkan pada dataset sangat terbatas sebagaimana disimpulkan oleh Velarati et al., (2024) dalam perbandingan CNN vs MobileNetV2 untuk klasifikasi rempah-rempah. Perbedaan mendasar antara penelitian ini dengan Gulzar (2023) dan Velarati et al., (2024) adalah konteks penggunaannya: penelitian-penelitian tersebut menguji klasifikasi pada gambar statis dengan latar belakang bersih, sedangkan penelitian ini mengintegrasikan CNN ke dalam pipeline real-time yang berjalan bersamaan dengan pemrosesan RFID pada server yang sama, membuktikan kelayakan implementasi multi-proses pada satu server tanpa GPU dedicated dengan throughput 66,7 FPS.

Dari sisi arsitektur sistem, (Tan & Sidhu, 2022) mengkaji integrasi RFID dan IoT dalam manajemen rantai pasok dan mengidentifikasi verifikasi data sebagai tantangan utama yang belum terpecahkan secara teknis. Penelitian ini menjawab tantangan tersebut secara konkret melalui mekanisme verifikasi silang antara hitungan RFID (Box 1) dan hitungan fisik sensor infrared (Box 2), sebuah pendekatan yang tidak ditemukan dalam penelitian Tan & Sidhu (2022) maupun dalam sistem RFID single-sensor yang ditinjau oleh Ali et al. (2024). Jarašūnienė et al. (2023) dalam studi dampak IoT terhadap manajemen gudang juga menyimpulkan bahwa akurasi penghitungan barang masih menjadi isu terbuka yang memerlukan solusi berbasis sensor tambahan, yang secara langsung mendukung justifikasi penggunaan sensor infrared E18-D80NK sebagai lapisan verifikasi independen dalam penelitian ini. Secara keseluruhan, penelitian ini berkontribusi dengan mengintegrasikan solusi dari berbagai penelitian terdahulu RFID untuk identifikasi, CNN/OCR untuk pengenalan visual, dan sensor infrared untuk verifikasi fisik dalam satu arsitektur terpadu yang belum dilaporkan sebelumnya dalam literatur yang ditinjau.

4. KESIMPULAN

Penelitian ini menghasilkan rancangan dan pengujian awal sistem pencatatan barang masuk gudang berbasis Internet of Things yang memadukan identifikasi frekuensi radio, sensor infrared, OCR, dan CNN dalam arsitektur dua box terhubung belt conveyor. Modul RFID RC522 terbukti andal hanya pada jarak 1-4 cm dengan kecepatan belt lambat hingga sedang, sebuah keterbatasan fisik yang mengharuskan kalibrasi presisi antena dan kecepatan belt pada implementasi skala penuh dan menjadi justifikasi nyata mengapa fallback visual kondisional merupakan bagian yang tidak bisa diabaikan dari sistem ini. Model CNN MobileNetV2 yang dilatih dengan 30 gambar per kelas mencapai akurasi validasi 100% dalam kondisi dataset kecil dan terkontrol; angka ini tidak dapat langsung digeneralisasikan ke variasi pencahayaan atau kemasan yang berbeda, dan kebutuhan pelatihan ulang penuh setiap kali produk baru ditambahkan harus diatasi melalui penjadwalan pelatihan berkala yang terstruktur. Pengujian identifikasi real-time mengonfirmasi CNN efektif untuk kemasan tidak terhalang dengan kepercayaan 94%, sementara OCR menjadi jalur fallback yang esensial ketika kemasan tertutupi label, memvalidasi logika pipeline kondisional yang dirancang. Arsitektur dua box secara empiris mengeliminasi interferensi optis antara LED strip dan sensor infrared, sekaligus menghadirkan mekanisme deteksi kecurangan otomatis melalui verifikasi silang hitungan RFID dengan hitungan fisik infrared kemampuan yang tidak ditemukan pada sistem gudang RFID single-sensor yang ditinjau dalam literatur. Kontribusi penelitian ini adalah rancangan arsitektur dua box dengan mekanisme verifikasi silang RFID-infrared sebagai deteksi kecurangan level hardware, pipeline kondisional OCR/CNN yang menangani seluruh variasi produk terlepas dari ketersediaan kode SKU, serta data pengujian empiris yang memvalidasi kelayakan teknis dan skalabilitas sistem ke konteks gudang ritel serupa. Penelitian lanjutan perlu berfokus pada integrasi prototipe fisik penuh, perluasan dataset CNN dengan variasi pencahayaan yang lebih beragam, pengembangan mekanisme fine-tuning yang efisien untuk mengurangi kebutuhan pelatihan ulang penuh, serta benchmarking kuantitatif performa sistem dibandingkan proses penerimaan manual di gudang Multimart Tomohon.

REFERENCES

- Alajami, A. A., & Pous, R. (2025). The design of a vision-assisted dynamic antenna positioning radio frequency identification-based inventory robot utilizing a 3-degree-of-freedom manipulator. *Sensors*, 25(8), 2418. <https://doi.org/10.3390/s25082418>
- Ali, A. A., Rashid, R. A., Abdikadir, N. M., Mohamed, A. A., & Ahmed, M. M. (2024). IoT based warehouse management system leveraging on RFID and cloud platform technologies. In *2024 IEEE International Conference on Advanced Telecommunication and Networking Technologies (ATNT)* (pp. 1-4). IEEE. <https://doi.org/10.1109/ATNT61688.2024.10719252>
- Atzori, L., Iera, A., & Morabito, G. (2010). The Internet of Things: A survey. *Computer Networks*, 54(15), 2787-2805. <https://doi.org/10.1016/j.comnet.2010.05.010>
- B H, S., Kumar M T, A., D V, H., Siddesh, A. K., & Guruswamy, Y. (2023). Automatic inspection conveyor using IR sensors. *International Journal of Engineering Research & Technology (IJERT)*, 11(05), 1-5. <https://www.ijert.org/automatic-inspection-conveyor-using-ir-sensors>



- Erlangga, S., Yunita, A., & Satriana, S. R. (2022). Development of automatic real time inventory monitoring system using RFID technology in warehouse. *JOIV: International Journal on Informatics Visualization*, 6(3), 636-642. <https://doi.org/10.30630/joiv.6.3.1231>
- Fatima, Z., Tanveer, M. H., Waseemullah, Zardari, S., Naz, L. F., Khadim, H., & Tahir, M. (2022). Production plant and warehouse automation with IoT and Industry 5.0. *Applied Sciences*, 12(4), 2053. <https://doi.org/10.3390/app12042053>
- Finkenzeller, K. (2010). *RFID Handbook: Fundamentals and Applications in Contactless Smart Cards, Near Field Communication and Smart Labels* (3rd ed.). John Wiley & Sons.
- Fuentes-Penna, A., Hernandez-Gress, E. S., & Laredo-Espinoza, J. (2022). RFID-enabled warehouse management systems: Architecture, benefits, and implementation challenges. *Journal of Industrial Information Integration*, 28, 100352. <https://doi.org/10.1016/j.jii.2022.100352>
- Gulzar, Y. (2023). Fruit image classification model based on MobileNetV2 with deep transfer learning technique. *Sustainability*, 15(3), 1906. <https://doi.org/10.3390/su15031906>
- Haq, I. U., Iqbal, M. W., & Khan, S. A. (2022). Deep learning-based real-time product classification system for retail industry. *Multimedia Tools and Applications*, 81(10), 14185-14202. <https://doi.org/10.1007/s11042-022-12425-x>
- Hercog, D., Lerher, T., Truntiĉ, M., & Težak, O. (2023). Design and implementation of ESP32-based IoT devices. *Sensors*, 23(15), 6739. <https://doi.org/10.3390/s23156739>
- Howard, A., Sandler, M., Chu, G., Chen, L.-C., Chen, B., Tan, M., Wang, W., Zhu, Y., Pang, R., Vasudevan, V., Le, Q. V., & Adam, H. (2019). Searching for MobileNetV3. *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)*, 1314-1324. <https://doi.org/10.1109/ICCV.2019.00140>
- Jarašūnienė, A., Čižiūnienė, K., & Čereška, A. (2023). Research on impact of IoT on warehouse management. *Sensors*, 23(4), 2213. <https://doi.org/10.3390/s23042213>
- Madhuri, G., Kaur, P., & Sethi, A. (2022). Smart markets integrated with RFID, computer vision, sensor data fusion. *International Journal for Research in Applied Science and Engineering Technology (IJRASET)*, 10(7), 1074-1079. <https://doi.org/10.22214/ijraset.2022.46022>
- Musthofa, K. N., & Haryono, W. (2023). Implementation of system development life cycle (SDLC) on IoT-based lending locker application. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 7(4), 982-987. <https://doi.org/10.29207/resti.v7i4.5047>
- Prasetyo, R. A., & Wibowo, A. (2022). Analisis permasalahan pencatatan manual pada gudang ritel. *Jurnal Sistem Informasi*, 10(1), 45-52. <https://doi.org/10.26595/jsi.2022.10.1.45>
- Pressman, R. S., & Maxim, B. R. (2015). *Software Engineering: A Practitioner's Approach* (8th ed.). McGraw-Hill Education.
- Pricillia, T., & Zulfachmi. (2024). Implementasi SDLC model prototype pada sistem informasi company profile berbasis website. *PETIK: Jurnal Pendidikan Teknologi Informasi dan Komunikasi*, 10(1), 85-97. <https://doi.org/10.31980/petik.v10i1.1030>
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L.-C. (2018). MobileNetV2: Inverted residuals and linear bottlenecks. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 4510-4520. <https://doi.org/10.1109/CVPR.2018.00474>
- Seitaj, H., & Elangovan, V. (2024). Information extraction from product labels: A machine vision approach. *International Journal of Artificial Intelligence and Applications (IJAIA)*, 15(2), 57-76. <https://doi.org/10.5121/ijaia.2024.15204>
- Smith, R. (2007). An overview of the Tesseract OCR engine. *Proceedings of the Ninth International Conference on Document Analysis and Recognition (ICDAR 2007)*, 629-633. <https://doi.org/10.1109/ICDAR.2007.4376991>
- Sporici, D., Cușnir, E., & Boianġiu, C.-A. (2020). Improving the accuracy of Tesseract 4.0 OCR engine using convolution-based preprocessing. *Symmetry*, 12(5), 715. <https://doi.org/10.3390/sym12050715>
- Tan, W. C., & Sidhu, M. S. (2022). Review of RFID and IoT integration in supply chain management. *Operations Research Perspectives*, 9, 100229. <https://doi.org/10.1016/J.ORM.2022.100229>
- Velarati, K., Sari, C. A., & Rachmawanto, E. H. (2024). A Comparison of Convolutional Neural Network (CNN) and Transfer Learning MobileNetV2 Performance on Spices Images Classification. *Journal of Applied Informatics and Computing*, 8(2), 413-420. <https://doi.org/10.30871/jaic.v8i2.8622>
- Zhong, R. Y., Xu, X., Klotz, E., & Newman, S. T. (2017). *Intelligent Manufacturing in the Context of Industry 4.0: A Review*. 3, 616-630. <https://doi.org/http://dx.doi.org/10.1016/J.ENG.2017.05.015>