

Prototype Conveyor Sederhana untuk Deteksi Objek Secara Real-time dengan Algoritma YOLOv4

Silvia Nur Anggraini¹, Kharis Hudaiby Hanif²

^{1,2} Universitas Borneo Tarakan, Tarakan, Kalimantan Utara, 77115, Indonesia

e-mail: ¹silviaanggrai58@gmail.com, ²hudaiby21@borneo.ac.id

Diterima
11-09-2025

Direvisi
25-09-2025

Disetujui
30-09-2025

Abstract: In the digitalization era, innovation in manufacturing inventory management is essential. Conventional infrared sensor-based systems face limitations, such as a maximum detection range of 15 cm and susceptibility to lighting interference. This study proposes an automated prototype system employing the YOLOv4 deep learning algorithm for real-time object detection and counting on a production line. The system aims to automate product counting, reduce manual errors, and enhance production efficiency. Experiments were conducted on a conveyor belt at two different speeds, detecting beverage cans and snack packages. A dataset of 5,706 images was collected using a 1080P webcam positioned above the conveyor. Performance was evaluated using F-measure, accuracy, precision, and recall derived from a confusion matrix. Results indicate optimal performance at 43 RPM, achieving an average F-measure of 81% and 70.6% accuracy. Precision reached 95.7% for cans and 97.8% for snacks, with recall of 66.6% and 73.1%, respectively. At 59 RPM, the F-measure declined to 77.7% with 65.8% accuracy. YOLOv4 consistently maintained precision above 93% across all configurations, demonstrating robustness in avoiding false positives, although recall variability (62.7%–73.1%) suggests further refinement is needed to minimize false negatives. This research contributes to manufacturing automation by advancing deep learning-based inventory management systems adaptive to diverse object characteristics and operational requirements.

Keywords: Manufacturing, prototype, conveyor Belt, YOLOv4, deep learning

Abstrak: Era digitalisasi menuntut inovasi dalam pengelolaan persediaan manufaktur. Sistem konvensional berbasis sensor infrared memiliki keterbatasan dengan jangkauan deteksi maksimal 15 cm dan rentan gangguan pencahayaan. Penelitian ini mengembangkan prototype sistem otomatis menggunakan algoritma *deep learning* YOLOv4 untuk mendeteksi dan menghitung objek secara *real-time* di jalur produksi. Sistem dirancang untuk mengotomatiskan penghitungan produk, mengurangi kesalahan manual, dan meningkatkan efisiensi produksi. Pengujian dilakukan pada *conveyor Belt* dengan dua kecepatan berbeda untuk mendeteksi kaleng minuman dan kemasan snack. Dataset terdiri dari 5.706 citra yang diambil melalui webcam 1080P yang dipasang di atas *conveyor Belt*. Evaluasi menggunakan metrik F-measure, akurasi, precision, dan *recall* berdasarkan confusion matrix. Hasil menunjukkan performa optimal pada kecepatan 43 RPM dengan F-measure rata-rata 81% dan akurasi 70,6%. Precision mencapai 95,7% untuk kaleng minuman dan 97,8% untuk kemasan snack, dengan *recall* masing-masing 66,6% dan 73,1%. Pada kecepatan 59 RPM, F-measure turun menjadi 77,7% dengan akurasi 65,8%. Model YOLOv4 menunjukkan konsistensi precision tinggi di atas 93% pada semua konfigurasi, mengindikasikan reliabilitas dalam menghindari false positive. Namun, variabilitas *recall* 62,7%-73,1% menunjukkan perlunya perbaikan untuk meminimalkan false negative. Penelitian ini berkontribusi pada pengembangan teknologi otomatisasi manufaktur, khususnya penerapan *deep learning* untuk pengelolaan inventaris yang adaptif terhadap karakteristik objek dan persyaratan operasional.

Kata kunci: Manufaktur, prototype, conveyor Belt, YOLOV4, deep learning

I. PENDAHULUAN

Begitu banyaknya penggunaan teknologi menunjukkan perkembangan era digitalisasi. Digitalisasi sendiri diartikan sebagai proses transformasi digital yang menggunakan teknologi berbasis komputerisasi untuk memudahkan pekerjaan manusia. Secara sederhana, teknologi ini didefinisikan sebagai kemampuan manusia untuk berinteraksi dengan dunia menggunakan sistem komputer (Salamah dkk., 2022). Kemajuan teknologi telah menghadirkan berbagai kesempatan sekaligus hambatan baru dalam aktivitas manufaktur dan manajemen stok barang. Pada era modern ini, kompetisi antar perusahaan tidak lagi terpusat pada strategi penetapan harga murah semata, tetapi lebih mengutamakan penciptaan nilai lebih yang dapat dirasakan konsumen. Demi mempertahankan eksistensi di tengah persaingan pasar, setiap perusahaan dituntut untuk membangun dan memelihara keunggulan daya saing yang berkelanjutan. Kendala yang kerap dihadapi sektor industri manufaktur, terutama bagi pelaku usaha kecil menengah (UKM), terletak pada aspek pengendalian inventaris yang efektif. Ketersediaan stok barang harus dijaga dalam kondisi optimal guna memastikan kelancaran alur produksi tanpa hambatan, sehingga perusahaan mampu merespons kebutuhan konsumen secara responsif di setiap waktu yang diperlukan (Soeltanong & Sasongko, 2021).

Dalam konteks industri manufaktur modern, sistem penghitungan objek otomatis berbasis Arduino dengan sensor infrared menghadapi sejumlah tantangan kritis yang membutuhkan solusi inovatif. Permasalahan utama meliputi efisiensi penghitungan barang dalam skala besar, yang secara tradisional dilakukan secara manual dan rentan terhadap kesalahan, serta kompleksitas menjaga akurasi penghitungan di tengah variabilitas ukuran, kecepatan, dan jarak barang yang bergerak di conveyor. Keterbatasan teknologi sensor infrared dengan jarak deteksi maksimal 15 cm menambah kompleksitas permasalahan, membatasi kemampuan sistem untuk mendeteksi barang dalam berbagai kondisi industri. Untuk mengoptimalkan sistem, diperlukan pendekatan komprehensif yang mampu mengatasi kelemahan deteksi sensor, meningkatkan adaptabilitas terhadap kondisi produksi yang beragam, dan merancang mekanisme penghitungan serta pendeteksi yang lebih dinamis dan berkelanjutan (Hidayat dkk., 2019). Di tengah perkembangan industrialisasi kontemporer, teknologi sabuk berjalan (*conveyor Belt*) telah berevolusi menjadi elemen krusial yang digunakan secara luas di berbagai bidang industri, mulai dari sektor manufaktur, distribusi, ekstraksi tambang, hingga agrikultur untuk mengalirkan produk atau bahan baku secara berkesinambungan. Akan tetapi, implementasi sistem sabuk berjalan tradisional yang masih bergantung pada intervensi manusia dalam aktivitas pemindahan material bukan hanya membutuhkan sumber daya manusia dalam jumlah besar, melainkan juga mengandung potensi bahaya yang signifikan bagi keselamatan operator serta mudah mengalami ketidaktepatan dalam proses kalkulasi volume barang. Namun dari penelitian terdahulu ini yang masih menggunakan sensor infrared memiliki keterbatasan dalam hal akurasi dan fleksibilitas, terutama ketika diterapkan dalam lingkungan produksi yang dinamis. Sensor fisik seperti ini sering kali mengalami masalah ketika ada gangguan eksternal, seperti perubahan kondisi pencahayaan atau posisi objek yang tidak teratur, sehingga mempengaruhi keandalan hasil deteksi.

Oleh karena itu, berdasarkan dari permasalahan tersebut penelitian ini mengusulkan prototype sistem otomatis berbasis computer vision untuk mendeteksi dan menghitung objek secara *real-time* di industri manufaktur. Sistem ini menggunakan *deep learning* dengan algoritma YOLOv4 (You Only Look Once) untuk mendeteksi objek pada gambar yang diambil oleh kamera. Sistem ini akan membantu mengotomatiskan tugas-tugas yang berulang, seperti menghitung jumlah produk yang dihasilkan di jalur produksi, sehingga mengurangi kesalahan manusia dan meningkatkan efisiensi produksi (UTOMO, 2023). Algoritma YOLO adalah metodologi pembelajaran mendalam yang dikhususkan untuk melakukan deteksi objek dengan kecepatan tinggi. Sebagai bagian integral dari teknologi *deep learning*, algoritma YOLO memiliki mekanisme pembelajaran mesin yang meniru struktur dan fungsi jaringan neural manusia. Teknologi ini mampu mengatasi kompleksitas data melalui proses analisis pola, segmentasi kelompok, dan kategorisasi informasi. Algoritma ini memiliki arsitektur berlapis dan jaringan yang kompleks dalam proses pelatihan, memungkinkan pembelajaran yang komprehensif dan dapat dijadikan acuan untuk menyelesaikan berbagai

permasalahan teknis. Implementasi algoritma YOLO memanfaatkan *Convolutional Neural Network* (CNN) untuk melakukan identifikasi objek secara *real-time*. Keunikan pendekatan ini terletak pada penggunaan metodologi yang berbeda dari algoritma konvensional lainnya, yaitu dengan menerapkan satu kesatuan jaringan neural untuk mengidentifikasi seluruh objek yang terdapat dalam citra. Dalam proses prediksi, jaringan tersebut memanfaatkan keseluruhan karakteristik visual dari gambar untuk menentukan dan memperkirakan *bounding box* yang paling optimal (Yasen et al., 2023). *Bounding box* merupakan kotak imajiner tidak nyata yang mengelilingi objek yang teridentifikasi. *Bounding box* sendiri berbentuk kotak yang sama besarnya dengan objek yang teridentifikasi. Koordinat piksel objek *upper-left*(UL), *upper-right*(UR), *lower-left*(LL), dan *lower-right*(LR) diperlukan untuk membuat *bounding box* (Putra dkk., 2023).

YOLOv4 dipilih karena memiliki kecepatan pemrosesan yang baik dengan tetap mempertahankan akurasi yang cukup tinggi. YOLOv4 juga dapat dijalankan dengan perangkat keras yang lebih terjangkau, seperti Graphics Processing Unit GPU biasa (contoh: NVIDIA GeForce GTX 1080 Ti), tanpa memerlukan biaya komputasi yang tinggi seperti pada versi yang lebih baru. Versi ini juga sudah cukup memadai untuk tugas pendeteksian pada produk di industri manufaktur, sesuai dengan kebutuhan dari penelitian ini (UTOMO, 2023). Tidak hanya YOLOv4 penelitian ini juga menggunakan algoritma DeepSORT (*Deep Simple Online and Realtime Tracking*), DeepSORT merupakan salah satu algoritma tracking objek terdepan yang dikembangkan sebagai evolusi dari metode *Simple Online and Realtime Tracking* (SORT) yang sebelumnya telah dikenal dalam komunitas computer vision. DeepSORT sendiri mencoba untuk meningkatkan efisiensi pergantian ID pada metode SORT sebelumnya. Untuk memperbaiki pergantian ID tersebut, DeepSORT diterapkan pada algoritma *Convolutional Neural Network* (CNN) pada pemberian ID dengan menggunakan informasi pergerakan dan penampilan suatu objek. SORT menunjukkan performa yang baik dalam hal kecepatan komputasi, metode ini juga memiliki kelebihan dalam hal konsistensi pemberian identitas (ID) objek, khususnya ketika objek mengalami perubahan pose atau keluar masuk dari frame kamera (Tawakkal, 2024).

II. METODE PENELITIAN

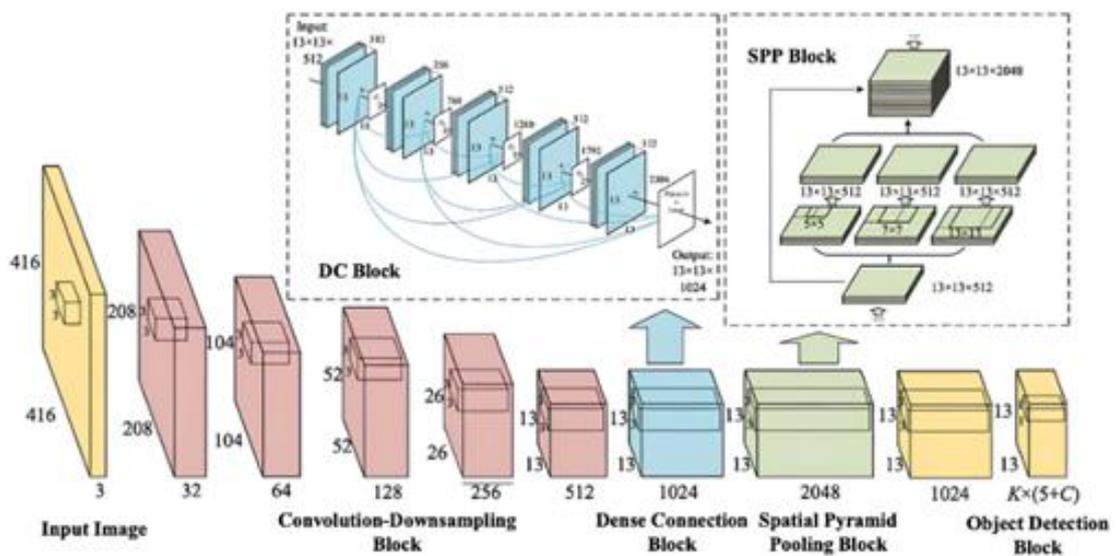
1. Studi Literatur

Mukhlison, Sri Widoretno, dan Ava Muhamad Alsa Fahri Mahardika (2024) dalam penelitiannya yang berjudul "*Conveyor Belt dan Alat Penghitung Otomatis Berbasis Arduino Nano Menggunakan Sensor Inframerah Pada Produksi Roti Tawar*" telah berhasil mengembangkan sistem otomatis untuk proses produksi roti tawar dengan mengintegrasikan *conveyor Belt* dan teknologi penghitungan berbasis Arduino Nano serta sensor inframerah. Sistem yang dikembangkan mampu melakukan penghitungan dan pemisahan produk secara otomatis berdasarkan kriteria yang telah ditetapkan, sehingga berkontribusi dalam meningkatkan efisiensi operasional proses produksi. Namun, penelitian tersebut mengidentifikasi bahwa tingkat akurasi sistem sangat dipengaruhi oleh sensitivitas sensor inframerah yang digunakan. Selain itu, terdapat keterbatasan signifikan terkait ukuran objek yang dapat terdeteksi oleh sistem, yang berpotensi mempengaruhi kualitas hasil akhir deteksi. Keterbatasan yang ditemukan dalam penelitian Mukhlison dkk. (2024) menjadi landasan untuk pengembangan sistem deteksi yang lebih canggih menggunakan pendekatan computer vision dengan algoritma YOLOv4, yang diharapkan dapat mengatasi masalah keterbatasan ukuran objek dan meningkatkan akurasi deteksi secara keseluruhan (Widoretno & Mahardika, 2024).

2. Konsep dasar teori

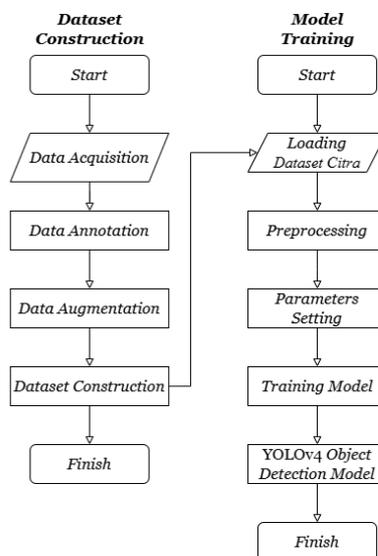
Arsitektur YOLO terdiri dari 24 lapisan konvolusional (*convolutional layer*) dengan 4 lapisan penggabungan maksimum, diikuti oleh 2 lapisan lagi yang terhubung penuh (*fully connected layer*). Untuk mengurangi kedalaman *feature maps*, beberapa lapisan konvolusi menggunakan lapisan reduksi 1×1 sebagai alternatif (Hutauruk dkk., 2020). YOLO memprediksi beberapa kotak pembatas untuk setiap sel kisi. Selama pelatihan, hanya ingin satu prediktor kotak pembatas yang bertanggung jawab untuk setiap objek. YOLO menugaskan satu prediktor untuk "bertanggung jawab" memprediksi apa yang akan terjadi berdasarkan prediksi mana yang memiliki Intersection of Union

(IoU) dengan kebenaran dasar tertinggi. Ini menghasilkan spesialisasi dalam prediktor kotak pembatas. Setiap prediktor menjadi lebih baik dalam meramalkan ukuran, rasio, atau kelas objek tertentu, yang menghasilkan skor *recall* yang lebih baik secara keseluruhan (Yanto, 2023). *Non-maximum suppression system* (NMS) merupakan teknik utama yang digunakan dalam model YOLO. NMS adalah fasilitas pasca-pemrosesan yang digunakan untuk meningkatkan akurasi dan efektivitas deteksi objek. Dalam deteksi objek, biasanya ada beberapa kotak pembatas untuk satu objek dalam sebuah gambar. Kotak pembatas ini mungkin berdekatan atau berada di tempat yang tumpang tindih, tetapi semuanya menunjukkan objek yang sama. Maka NMS digunakan untuk menemukan dan mengeluarkan satu kotak pembatas untuk setiap objek dalam gambar serta menghapus kotak pembatas yang berlebihan atau salah.



Gambar 1. Arsitektur YOLO

3. Alur Penelitian

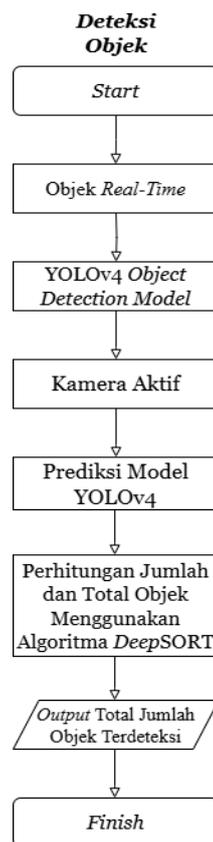


Gambar 2. Alur diagram sistem

Diagram alir pada Gambar 2 menggambarkan dua proses utama dalam pengembangan model deteksi objek YOLOv4 yang terbagi menjadi bagian kiri untuk persiapan dataset dan bagian kanan

untuk implementasi model. Proses pengembangan sistem deteksi objek ini dimulai dengan tahap dataset construction yang diawali dengan fase Start. Langkah pertama adalah melakukan data acquisition untuk mengumpulkan data citra yang diperlukan sebagai bahan dasar pelatihan model. Data yang telah terkumpul kemudian melalui proses data annotation untuk memberikan label dan penandaan pada objek-objek yang akan dideteksi. Selanjutnya, dilakukan data augmentation untuk memperbanyak variasi data dan meningkatkan kualitas dataset. Setelah dataset siap, proses berlanjut ke tahap dataset construction untuk membangun struktur dataset yang terorganisir.

Tahap selanjutnya adalah model training yang dimulai dengan loading training data untuk memuat dataset yang telah dipersiapkan ke dalam sistem. Kemudian dilakukan *preprocessing* untuk memproses dan menyiapkan data sebelum pelatihan. Proses parameter setting dilakukan untuk mengatur konfigurasi parameter model yang optimal. Setelah itu, dilaksanakan training model untuk melatih algoritma menggunakan dataset yang telah disiapkan. Hasil pelatihan menghasilkan YOLOv4 object detection model yang siap digunakan. Seluruh proses ini berakhir pada tahap finish ketika model telah berhasil dilatih dan siap untuk diimplementasikan dalam sistem deteksi objek secara *real-time*.



Gambar 3. Flowchart pemodelan data testing

Sistem deteksi objek dimulai dengan tahap start untuk inialisasi perangkat keras (webcam, *Conveyor Belt*) dan perangkat lunak yang diperlukan. Pada tahap objek *real-time*, webcam yang ditempatkan pada ketinggian 65 cm menangkap video stream secara *real-time* dari objek (kaleng minuman dan kemasan snack) yang bergerak di atas *conveyor Belt* dengan kecepatan 43-59 RPM. YOLOv4 object detection model kemudian menganalisis setiap frame untuk mengidentifikasi region of interest (ROI) dan mengenali karakteristik visual objek target. Sistem melakukan verifikasi kamera aktif untuk memastikan webcam berfungsi optimal dengan resolusi 1080P. Pada tahap prediksi model YOLOv4, model melakukan forward propagation untuk menghasilkan bounding box, class probability, dan confidence score setiap objek yang terdeteksi.

Hasil deteksi diproses pada tahap perhitungan jumlah dan total objek menggunakan algoritma *DeepSORT* untuk melacak objek antar frame dan memberikan ID unik, memastikan perhitungan

akurat meski objek bergerak atau tumpang tindih. Sistem menyajikan hasil pada tahap output total jumlah objek terdeteksi berupa informasi jumlah kaleng minuman, kemasan snack, dan total keseluruhan yang ditampilkan di layar dan disimpan untuk analisis. Proses diakhiri dengan tahap finish dimana seluruh operasi deteksi diselesaikan, memastikan setiap tahapan berjalan optimal untuk deteksi objek.

Diagram alir pada Gambar 2 dan flowchart pada Gambar 3 ini menggambarkan langkah-langkah yang jelas untuk menyiapkan data dan melatih model YOLOv4, dimulai dari pengumpulan data, anotasi, augmentasi, hingga pelatihan model dan implementasinya. Setiap tahapan sangat penting untuk memastikan bahwa model dapat mendeteksi objek dengan akurat di gambar atau video.

4. Alat dan Bahan

Tabel 1. Spesifikasi Alat dan Bahan

Alat dan Bahan	Spesifikasi
Laptop	Windows 11 64-bit, Processor 12th Gen Intel(R) Core i5, Memory 8192MB RAM
Python	Python 3.12.4
Webcam	Resolusi 1920x1080, sudut lebar 120°, panjang kabel 1,5 m, dan ukurannya 71.5 x 30 x 50 mm
Mini Conveyor	Panjang 60 cm, lebar 20 cm, dan tinggi 20 cm dengan berbahan aluminium Measuring Range: 2.5 RPM - 99,999 RPM Resolution: 0.1 RPM (from 2.5 to 999.9 RPM) 1 RPM (over 1,000 RPM) Accuracy: (0.05%+1 digit) Display: Large 5 digit, 18mm LCD Measuring Distance: 50-100mm Time Base: 6MHz Quartz Crystal Oscillator
Tachometer	Memory: Last Value. Max Value. Min RPM Sampling Time: 0.8s (over 60RPM) Power Supply: 1 x 9V 6F22 Battery Power Consumption: 30mA Working Temperature: 0-50 Size: 130 x 68 x 26mm Weight: 160g
Baterai	9 Volt
Tripod	Mount Holder 65-100mm, Foled Length 336mm, Extended Length 1530mm, Product Size 336x75x37.5mm, Product Weight 426g
Kaleng Minuman	Berbahan aluminium
Kemasan Snack	Berbahan kertas

5. Dataset

Basis Penelitian ini mengembangkan sistem pendeteksi dan penghitung otomatis makanan dan minuman di industri manufaktur menggunakan algoritma YOLOv4. Pada tahap ini dataset yang dikumpulkan terdapat dua pengambilan sumber yaitu dari dataset sekunder dan dataset primer. Dataset sekunder di ambil dari sumber pustaka www.kaggle.com dan [universe.Roboflow.com](http://universe.roboflow.com) masing-masing dataset yang di ambil dari setiap platform sebanyak 300 citra. Sedangkan dataset primer merupakan dataset yang dikumpulkan individu secara langsung di ambil sebanyak 300 citra. Total dataset yang digunakan dalam penelitian ini terdiri dari 900 sampel data yang telah dikumpulkan secara sistematis. Dataset berupa citra kaleng minuman dan kemasan snack kertas dikumpulkan dari platform Kaggle dan Roboflow, kemudian dibagi menjadi data training (60%), validation (20%), dan testing (20%). Pembagian ini memberikan keseimbangan optimal antara pembelajaran pola kompleks, evaluasi kinerja model, dan pengujian generalisasi model tanpa overfitting. Dengan menggunakan 20% dari total data, hasil yang diperoleh sebagai ukuran kemampuan generalisasi model dalam kondisi nyata, termasuk saat dipakai dalam keadaan *real-time*. Pembagian 60%, 20%, dan 20% dipilih karena memberikan keseimbangan yang baik antara jumlah data yang dibutuhkan untuk melatih model, memvalidasi kinerja selama pelatihan, dan menguji model pada data yang belum pernah dilihat untuk mengevaluasi kinerja secara menyeluruh(Hayat & Morgado-Dias, 2022).

Pengumpulan data sampel dilakukan dengan 2 kecepatan conveyor berbeda yaitu 43 RPM (Revolutions Per Minutes) dan 59 RPM, masing-masing dengan 5 kali pengambilan data, menghasilkan total 5.706 citra dari deteksi *real-time*. Untuk mengatasi false positive, sistem dapat ditingkatkan dengan memperbanyak dataset dan *epoch* pelatihan. Evaluasi kinerja sistem menggunakan metrik *precision*, *recall*, *F-measure*, dan akurasi beserta rata-rata keseluruhan dari ketiga pengujian terhadap seluruh data hasil uji sistem peroleh pada saat analisis pengetahuan.

6. Analisis Data

Pengujian penelitian akan dihitung berdasarkan nilai, adapun rumus yang digunakan dapat dilihat pada persamaan 1 rumus *precision*, persamaan 2 *recall*, persamaan 3 *f-measure*, persamaan 4 akurasi.

sebagai metode untuk menafsirkan dan mengetahui apakah hasil prediksi sistem benar dengan saran ini. Nilai-nilai ini didasarkan pada hasil identifikasi dari:

Precision dapat didefinisikan sebagai kecocokan atau kesesuaian (antara permintaan informasi dan tanggapan) adalah definisi precision. Sebenarnya, keakuratan ini relevan jika seseorang mencari informasi di sistem dan dokumentasi tersedia. Dengan kata lain, relevansi dokumen dengan pencari informasi menentukan seberapa akurat atau tepat dokumen tersebut untuk memenuhi kebutuhan pencari informasi (Hudha, 2022). Dapat dilihat pada persamaan (1) yang digunakan untuk menghitung nilai *precision*.

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

Recall adalah metode pengujian yang membandingkan jumlah informasi relevan yang diterima sistem dengan jumlah total informasi relevan yang dikumpulkan selama proses pengumpulan informasi (terlepas dari apakah sistem telah menangkapnya atau belum) (Rahma, 2021). Dapat dilihat pada persamaan (2) yang digunakan untuk menghitung nilai *recall*.

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

F-measure adalah nilai dari antara *recall* dan *precision* yang menunjukkan hasil akurasi sistem. Pada kondisi tertentu, nilai *recall* dan *precision* dapat bervariasi dalam bobotnya. *F-measure* merupakan bobot harmonic mean dari *recall* dan *precision*, menunjukkan hubungan timbal balik antara *recall* dan *precision*. Untuk rumus dari *f-measure* dapat di lihat pada persamaan (3) (Nurdiansyah, 2020).

$$F\text{-measure} = \frac{2 \times precision \times recall}{precision + recall} \quad (3)$$

Akurasi adalah rasio prediksi benar (positif dan negatif) dengan keseluruhan data. Ini menunjukkan berapa persen kelas objek yang diprediksi benar dan tidak benar dari keseluruhan objek. Untuk rumus dari akurasi dapat di lihat pada persamaan (4) (Rofii, 2021).

$$Akurasi = \frac{\text{Hasil Deteksi}}{\text{Fakta Jumlah}} \times 100\% \quad (4)$$

- a. TP (True Positif), yaitu jumlah objek asli yang terdeteksi sistem.
- b. TN (True Negative), yang berarti ketika model memprediksi negatif, dan hasil sebenarnya memang negatif.
- c. FP (False Positif), yang berarti jumlah objek noise yang terdeteksi secara akurat oleh sistem.
- d. FN (False Negative), yang berarti jumlah objek sebenarnya yang tidak ditemukan secara akurat oleh sistem.

III. HASIL DAN PEMBAHASAN

1. Pengambilan data uji

Untuk mengevaluasi kinerja model deteksi kaleng minuman dan *snack* makanan dalam skenario nyata, peneliti melakukan data uji secara komprehensif. Data uji ini terdiri dari 5 pengambilan data dengan 2 kecepatan *conveyor* yang berbeda dengan total citra dari 10 pengambilan data ini yaitu sebanyak 5.706 citra yang diambil dari hasil deteksi *real-time*. *Dataset* pengujian ini secara sengaja mencakup berbagai variasi kondisi yang menantang untuk menguji ketahanan model.

Sistem *conveyor Belt* yang dikembangkan dalam penelitian ini merupakan sebuah sistem transportasi otomatis yang dirancang untuk mengangkut produk dengan dilengkapi teknologi *monitoring* visual berbasis *computer vision*. Dalam proses pengambilan data pengujian, terdapat beberapa variabel dan kondisi yang menjadi tantangan utama dalam implementasi sistem deteksi, di antaranya adalah variasi dalam jumlah objek yang terdeteksi dalam satu *frame*, pencahayaan yang bersifat random dan tidak konsisten, serta pengaturan jarak pengambilan gambar yang ditetapkan konsisten dengan posisi *webcam* dan *conveyor* sejajar dimana *webcam* mengarah langsung ke *belt* hitam pada *conveyor*. Kombinasi faktor-faktor ini menciptakan kondisi pengujian yang merepresentasikan tantangan deteksi objektif dalam implementasi sistem nyata, sehingga hasil evaluasi dapat memberikan gambaran performa yang baik untuk aplikasi industri sesungguhnya. Seluruh proses pengambilan data uji tersebut terdokumentasi secara menyeluruh dalam Gambar 4.



Gambar 4. Proses pengambilan data uji

Sistem penggerak *conveyor Belt* menggunakan motor DC yang mendapatkan suplai daya dari baterai 9 volt yang ditempatkan strategis di bagian kaki *conveyor Belt*. Pemilihan motor DC dengan sumber daya baterai 9 volt memberikan beberapa keunggulan, antara lain portabilitas sistem yang tinggi, kemudahan kontrol kecepatan, dan efisiensi energi yang baik. Untuk memudahkan operasional sistem, telah dipasang *switch on/off* yang berfungsi sebagai pengendali utama untuk mengaktifkan atau menonaktifkan seluruh perangkat *conveyor Belt*. *Switch* ini memungkinkan operator untuk mengontrol sistem secara manual sesuai dengan kebutuhan operasional dapat dilihat pada Gambar 5. Bagian akhir *conveyor Belt* terdapat wadah penampung produk yang dirancang dengan presisi tinggi. Wadah penampung ini memiliki dimensi panjang 20 cm, lebar 10 cm, dan tinggi 20 cm, dengan karakteristik khusus bahwa tinggi dan lebar wadah penampung sama persis dengan *conveyor Belt* sehingga membentuk permukaan yang rata dan saling terhubung. Desain ini memastikan bahwa produk dapat berpindah dengan mulus dari *conveyor Belt* ke wadah penampung tanpa mengalami gangguan atau terjatuh. Wadah penampung berfungsi sebagai tempat pengumpulan akhir setelah produk menyelesaikan perjalanannya melalui jalur *conveyor*, memungkinkan sistem untuk mengorganisir produk secara otomatis dan terstruktur.



Gambar 5. Prototype Conveyor

2. Sampel data uji

Berdasarkan Tabel 2, model YOLOv4 telah berhasil melakukan deteksi terhadap dua kelas yang diuji dalam sistem. Pada Tabel 2 menunjukkan kemampuan hasil deteksi model dalam mengidentifikasi dan mengklasifikasikan objek-objek target sesuai dengan kategori yang telah ditentukan. Proses deteksi tersebut memperlihatkan efektivitas implementasi sistem dalam mengenali objek-objek dari kedua kelas yang menjadi fokus pengujian. Keberhasilan deteksi ini menjadi indikator positif terhadap performa model YOLOv4 yang diimplementasikan dalam sistem tersebut.

Tabel 2. Hasil deteksi minuman kaleng dan kemasan snack

Class	Hasil Deteksi Sistem
Kaleng_Minuman	
Kemasan_Snack	

Sistem berhasil mendeteksi kuantitas secara akurat pada 94,3% dari total data uji, yang menunjukkan bahwa pendekatan *rule-based* yang dikembangkan cukup andal dalam mengidentifikasi kuantitas eksplisit dalam teks, sebagaimana ditunjukkan pada contoh “Tampilkan 5 produk terlaris bulan April 2025” yang menghasilkan keluaran ['5 produk', 'april 2025'] dengan nilai terdeteksi ['5', 'april 2025'], serta “List produk yang terjual antara 20 sampai 50 unit per hari” yang menghasilkan ['20', '50 unit'] dengan nilai terdeteksi ['20', '50'].

3. Analisis sampel data uji

Evaluasi kinerja dilakukan menggunakan metrik klasifikasi seperti *Precision*, *Recall*, *F1-Score*, dan Akurasi, yang dihitung berdasarkan perbandingan prediksi sistem terhadap label *ground truth*.

Tabel 3. Perhitungan True Positif, False Positif, Dan False Negative Dengan Kecepatan Conveyor 43 Rpm

No Frame	Jumlah Objek	Actual	Predicted	Kaleng Minuman			Kemasan Snack		
				TP	FP	FN	TP	FP	FN
1	69	Kaleng_Minuman=33 Kemasan_Snack=36	Kaleng_Minuman=24 Kemasan_Snack=27	23	1	9	26	1	9
2	57	Kaleng_Minuman=27 Kemasan_Snack=30	Kaleng_Minuman=23 Kemasan_Snack=20	23	0	4	20	0	10
3	40	Kaleng_Minuman=24 Kemasan_Snack=16	Kaleng_Minuman=13 Kemasan_Snack=15	13	0	11	14	1	1
4	40	Kaleng_Minuman=25 Kemasan_Snack=15	Kaleng_Minuman=11 Kemasan_Snack=10	11	0	14	10	0	5
5	58	Kaleng_Minuman=30 Kemasan_Snack=28	Kaleng_Minuman=23 Kemasan_Snack=20	20	3	7	20	0	8
Overall		Kaleng_Minuman=139 Kemasan_Snack=125	Kaleng_Minuman=94 Kemasan_Snack=92	90	4	45	90	2	33

Tabel 4. Perhitungan True Positif, False Positif, Dan False Negative Dengan Kecepatan Conveyor 59 Rpm

No Frame	Jumlah Objek	Jumlah Kelas	Actual	Predicted	Kaleng Minuman			Kemasan Snack		
					TP	FP	FN	TP	FP	FN
1	43	2	Kaleng_Minuman=23 Kemasan_Snack=20	Kaleng_Minuman=12 Kemasan_Snack=15	12	0	11	14	1	5
2	66	2	Kaleng_Minuman=32 Kemasan_Snack=34	Kaleng_Minuman=20 Kemasan_Snack=21	20	0	12	21	0	13
3	53	2	Kaleng_Minuman=24 Kemasan_Snack=29	Kaleng_Minuman=19 Kemasan_Snack=15	19	0	5	12	3	14
4	61	2	Kaleng_Minuman=29 Kemasan_Snack=32	Kaleng_Minuman=23 Kemasan_Snack=21	23	0	6	20	1	11
5	61	2	Kaleng_Minuman=33 Kemasan_Snack=28	Kaleng_Minuman=21 Kemasan_Snack=20	21	0	12	19	1	8
Overall			Kaleng_Minuman=141 Kemasan_Snack=143	Kaleng_Minuman=95 Kemasan_Snack=92	95	0	46	86	6	51

Tabel 5. Hasil Perhitungan Data Evaluasi Kecepatan Conveyor 43 Rpm

Class	TP	FP	FN	Precision	Recall	F-measure	Akurasi
Kaleng_Minuman	90	4	45	0,957	0,666	0,784	0,676
Kemasan_Snack	90	2	33	0,978	0,731	0,836	0,736
Average Value				0,967	0,698	0,810	0,706

Tabel 6. Hasil Perhitungan Data Evaluasi Kecepatan Conveyor 59 Rpm

Class	TP	FP	FN	Precision	Recall	F-measure	Akurasi
Kaleng_Minuman	95	0	46	1,000	0,673	0,804	0,673
Kemasan_Snack	86	6	51	0,934	0,627	0,750	0,643
Average Value				0,967	0,65	0,777	0,658

Berdasarkan hasil evaluasi kedua model deteksi objek dengan model kecepatan conveyor Belt 43 RPM dan 59 RPM, terlihat perbedaan performa yang signifikan antara keduanya. Hasil evaluasi dengan kecepatan conveyor Belt 43 RPM menunjukkan karakteristik yang lebih seimbang dalam mendeteksi kedua jenis objek, dengan precision yang sangat tinggi untuk kaleng minuman 0,957 dan kemasan snack 0,978, serta recall yang relatif lebih baik yaitu 0,666 untuk kaleng minuman dan 0,731 untuk kemasan snack. Hal ini menghasilkan F-measure yang stabil pada 0,784 dan 0,836 masing-masing untuk kedua kelas objek.

Sebaliknya, pada kecepatan *conveyor Belt* 59 RPM memperlihatkan trade-off yang berbeda dalam performanya. Meskipun model ini mencapai precision sempurna 1,000 untuk deteksi kaleng minuman yang menunjukkan tidak adanya kesalahan prediksi positif, namun *recall*-nya justru sedikit lebih rendah 0,673 dibandingkan hasil evaluasi sistem dengan kecepatan *conveyor Belt* 43 RPM. Untuk kemasan snack, kecepatan *conveyor Belt* 59 RPM mengalami penurunan performa yang lebih signifikan dengan precision turun menjadi 0,934 dan *recall* yang menurun drastis menjadi 0,627, menghasilkan F-measure yang lebih rendah yaitu 0,750.

a. Kaleng_Minuman

Perbandingan performa untuk kelas kaleng minuman menunjukkan karakteristik yang menarik antara kedua model. Model 43 RPM dengan 90 true positive, 4 false positive, dan 45 false negative menghasilkan precision 0,957 yang sangat baik, namun *recall* 0,666 yang menunjukkan sekitar sepertiga kaleng minuman masih luput dari deteksi. F-measure 0,784 dan akurasi 0,676 menggambarkan performa yang stabil namun masih ada ruang perbaikan. Di sisi lain, model 59 RPM menunjukkan karakteristik yang lebih konservatif dengan 95 true positive, 0 false positive, dan 46 false negative. Precision sempurna 1,000 menunjukkan bahwa setiap prediksi kaleng minuman pasti benar, namun *recall* 0,673 yang sedikit lebih baik dari model 43 RPM tetap menunjukkan masalah dalam mendeteksi semua kaleng minuman yang ada. F-measure 0,804 yang lebih tinggi dan akurasi 0,673 menunjukkan bahwa meskipun akurasi sedikit lebih rendah, keseimbangan precision-*recall* lebih baik.

b. Kemasan_snack

Untuk kelas kemasan snack, perbedaan performa antara kedua model menjadi lebih jelas dan signifikan. Model 43 RPM dengan 90 true positive, 2 false positive, dan 33 false negative menunjukkan performa yang sangat baik dengan precision 0,978, *recall* 0,731, F-measure 0,836, dan akurasi 0,736. Performa ini menunjukkan bahwa model mampu mendeteksi hampir tiga perempat kemasan snack dengan tingkat kesalahan prediksi yang sangat rendah. Sebaliknya, model 59 RPM mengalami degradasi performa yang terlihat jelas dengan 86 true positive, 6 false positive, dan 51 false negative yang tinggi. Hal ini menghasilkan precision 0,934 yang masih baik namun turun dari model sebelumnya, *recall* 0,627 yang menunjukkan hanya sekitar 60% kemasan snack terdeteksi, F-measure 0,750, dan akurasi 0,643. Peningkatan false negative yang drastis dari 33 menjadi 51 menunjukkan bahwa model 59 RPM mengalami kesulitan dalam mengenali kemasan snack, kemungkinan dikarenakan cepatnya kemasan snack melewati area deteksi pada sistem sehingga banyaknya kemasan snack tidak terdeteksi dengan baik.

Analisis confusion matrix mengungkapkan bahwa model 43 RPM memiliki distribusi error yang lebih seimbang dengan false positive yang rendah untuk kedua kelas, sementara model 59 RPM menunjukkan karakteristik yang sangat konservatif untuk kaleng minuman namun mengalami penurunan performa signifikan untuk kemasan snack. Dari perspektif praktis, model 43 RPM memberikan solusi yang lebih optimal untuk implementasi sistem deteksi objek karena menawarkan keseimbangan yang baik antara akurasi deteksi dan kemampuan menangkap objek target pada kedua kelas, meskipun model 59 RPM unggul dalam precision kaleng minuman namun kemampuan deteksi keseluruhan yang lebih rendah membuatnya kurang ideal untuk sistem yang memerlukan cakupan deteksi yang menyeluruh.

4. Kinerja menyeluruh model YOLOv4

Evaluasi kinerja menyeluruh model YOLOv4 dalam sistem deteksi objek kaleng minuman dan kemasan snack menunjukkan karakteristik performa yang bervariasi tergantung pada konfigurasi kecepatan *conveyor Belt*. Secara akumulasi, model YOLOv4 dengan kecepatan *conveyor Belt* 43 RPM mendemonstrasikan performa yang lebih konsisten dan seimbang dengan rata-rata precision 0,967, *recall* 0,698, F-measure 0,810, dan akurasi keseluruhan 0,706. Sementara itu, model YOLOv4 dengan kecepatan *conveyor Belt* 59 RPM menunjukkan rata-rata precision 0,967, *recall* 0,650, F-measure 0,777, dan akurasi keseluruhan 0,658. Data ini mengindikasikan bahwa peningkatan kecepatan operasional dari 43 RPM ke 59 RPM berdampak pada penurunan kemampuan deteksi keseluruhan, terutama dalam aspek *recall* dan akurasi.

Dari perspektif stabilitas, model YOLOv4 menunjukkan performa yang stabil dengan precision yang konsisten tinggi di atas 0,93 untuk semua konfigurasi dan kelas objek, menunjukkan reliabilitas yang baik dalam menghindari false positive. Namun, variabilitas *recall* yang cukup signifikan antara 0,627 hingga 0,731 mengindikasikan bahwa model masih menghadapi tantangan dalam mendeteksi semua objek target, dengan tingkat false negative yang perlu mendapat perhatian lebih lanjut. Khususnya, perbedaan performa antara kedua kelas objek menunjukkan bahwa model YOLOv4 lebih efektif dalam mendeteksi kemasan snack dibandingkan kaleng minuman pada konfigurasi 43 RPM, namun mengalami penurunan performa yang lebih drastis untuk kemasan snack ketika kecepatan ditingkatkan ke 59 RPM.

Aspek efisiensi komputasi model YOLOv4 terlihat dari trade-off antara kecepatan operasional dan akurasi deteksi. Model dengan konfigurasi 59 RPM menunjukkan karakteristik yang lebih konservatif dengan precision yang sangat tinggi untuk kaleng minuman 1,000 namun dengan cost berupa penurunan *recall* dan peningkatan false negative yang signifikan. Hal ini menunjukkan bahwa peningkatan throughput processing berdampak pada kemampuan model dalam melakukan deteksi objek secara sangat detail dan spesifik, terutama untuk objek dengan karakteristik visual yang lebih kompleks seperti kemasan snack yang memiliki variasi bentuk, ukuran, dan pattern yang lebih beragam dibandingkan kaleng minuman yang relatif uniform. Secara keseluruhan, implementasi YOLOv4 dalam aplikasi ini menunjukkan performa yang dapat diterima untuk sistem *real-time* deteksi dengan F-measure rata-rata di atas 0,777 untuk kedua konfigurasi. Namun, masih terdapat ruang yang berpengaruh untuk optimisasi, terutama dalam meningkatkan *recall* rate untuk mengurangi missed detection yang dapat berdampak pada aplikasi praktis.

Hasil akhir penelitian menunjukkan bahwa sistem mampu mendeteksi kaleng minuman dan kemasan snack yang bergerak di atas *conveyor Belt* secara real time berbasis computer vision dengan model YOLOv4. Evaluasi menunjukkan kinerja sistem yang baik dalam mendeteksi dan menghitung total objek dengan dua kelas berbeda secara real time, dengan performa optimal pada kecepatan *conveyor Belt* 43 RPM yang menghasilkan F-measure rata-rata 0,810. Nilai precision yang konsisten tinggi di atas 0,93 untuk semua konfigurasi menunjukkan bahwa sebagian besar deteksi yang dilakukan oleh sistem adalah akurat, meminimalkan kemungkinan terjadinya false positive (mendeteksi objek yang sebenarnya tidak ada). Nilai *recall* yang bervariasi antara 0,627 hingga 0,731 mengindikasikan bahwa sistem mampu mendeteksi sebagian besar objek yang ada dalam frame, meskipun masih terdapat ruang perbaikan untuk meminimalkan kemungkinan terjadinya false negative (gagal mendeteksi objek yang sebenarnya ada). F-measure sebagai nilai harmonic mean antara precision dan *recall* menunjukkan keseimbangan yang cukup baik antara kedua metrik tersebut, dengan kinerja terbaik dicapai pada konfigurasi kecepatan *conveyor Belt* 43 RPM untuk kemasan snack 0,836 dan konfigurasi kecepatan *conveyor Belt* 59 RPM untuk kaleng minuman 0,804, mengindikasikan bahwa sistem dapat diadaptasi sesuai dengan karakteristik objek target dan persyaratan kecepatan operasional untuk mencapai performa optimal secara keseluruhan.

IV.SIMPULAN

Berdasarkan Penelitian ini berhasil mengembangkan sistem deteksi objek kaleng minuman dan kemasan snack yang bergerak di atas *conveyor Belt* secara *real-time* menggunakan model YOLOv4 berbasis computer vision. Hasil evaluasi menunjukkan bahwa sistem mampu bekerja dengan baik dalam kondisi pengujian nyata dengan berbagai tantangan seperti variasi pencahayaan, kecepatan *conveyor Belt*, dan jumlah objek yang bervariasi dalam setiap frame. Kinerja optimal sistem dicapai pada kecepatan *conveyor Belt* 43 RPM dengan nilai F-measure rata-rata 0,810 dan akurasi keseluruhan 0,706, dibandingkan dengan kecepatan 59 RPM yang menghasilkan F-measure rata-rata 0,777 dan akurasi 0,658.

Model YOLOv4 menunjukkan konsistensi yang baik dalam aspek precision dengan nilai di atas 0,93 untuk semua konfigurasi, mengindikasikan kemampuan sistem dalam meminimalkan false positive detection. Namun, variabilitas *recall* yang berkisar antara 0,627 hingga 0,731 menunjukkan bahwa sistem masih menghadapi tantangan dalam mendeteksi seluruh objek target, terutama pada kecepatan conveyor yang lebih tinggi. Performa deteksi kemasan snack pada kecepatan 43 RPM

menunjukkan hasil terbaik dengan F-measure 0,836, sementara deteksi kaleng minuman optimal pada kecepatan 59 RPM dengan F-measure 0,804. Peningkatan kecepatan conveyor dari 43 RPM ke 59 RPM berdampak pada penurunan kemampuan deteksi keseluruhan, terutama untuk kemasan snack yang mengalami peningkatan false negative secara signifikan dari 33 menjadi 51.

Secara keseluruhan, penelitian ini berhasil mengembangkan sistem deteksi objek *real-time* dengan tingkat precision rata-rata 0,967 yang sangat tinggi dan nilai *recall* rata-rata 0,698 yang baik pada kecepatan optimal 43 RPM, mendemonstrasikan keefektifan arsitektur YOLOv4 dalam aplikasi deteksi dan menghitung objek pada *conveyor Belt*. Meskipun kinerja model telah menunjukkan hasil yang memuaskan dengan F-measure terbaik mencapai 0,836 untuk kemasan snack, masih terdapat ruang untuk peningkatan terutama dalam meningkatkan nilai *recall* yang bervariasi antara 0,627-0,731 untuk mengurangi jumlah false negative yang berkisar 33-51 objek. Hasil penelitian ini membuktikan bahwa pendekatan *deep learning* dengan model YOLOv4 dapat diimplementasikan dengan sukses untuk sistem deteksi dan klasifikasi objek bergerak secara *real-time* dalam lingkungan industri, dengan kinerja optimal pada kecepatan conveyor 43 RPM yang menghasilkan keseimbangan terbaik antara akurasi dan throughput, sehingga memiliki potensi aplikasi yang luas dalam otomatisasi proses produksi, quality control, dan sistem pengawasan produk yang berarti hipotesis yang dibuat pada awal penelitian dapat diterima.

REFERENSI

- Hayat, A., & Morgado-Dias, F. (2022). *Deep learning* -based automatic safety helmet detection system for construction safety. *Applied Sciences*, 12(16), 8268.
- Hidayat, M. S., Pagiling, L., & Nur, M. N. A. (2019). Perancangan sistem pengepakan otomatis berbasis arduino uno menggunakan sensor jarak infra red. *J. Fokus Elektroda Energi List. Telekomun. Komputer, Elektron. Dan Kendali*, 4(1), 1–8.
- Hudha, M., Supriyati, E., & Listyorini, T. (2022). Analisis Sentimen Pengguna Youtube Terhadap Tayangan# Matanajwamenantiterawan Dengan Metode Naïve Bayes Classifier. *JIKO (Jurnal Inform. Dan Komputer)*, 5(1), 1–6.
- Hutauruk, J. S. W., Matulatan, T., & Hayaty, N. (2020). Deteksi kendaraan secara real time menggunakan metode YOLO berbasis android. *Jurnal Sustainable: Jurnal Hasil Penelitian Dan Industri Terapan*, 9(1), 8–14.
- Nurdiansyah, A. (2020). *Peringkasan Teks Dokumen Menggunakan Metode Simple Additive Weighting (Saw)*. Universitas Komputer Indonesia.
- Putra, P. Y., Arifianto, A. S., Fitri, Z. E., & Puspitasari, T. D. (2023). Deteksi Kendaraan Truk pada Video Menggunakan Metode Tiny-YOLO v4. *Jurnal Informatika Polinema*, 9(2), 215–222.
- Rahma, L., Syaputra, H., Mirza, A. H., & Purnamasari, S. D. (2021). Objek Deteksi Makanan Khas Palembang Menggunakan Algoritma YOLO (You Only Look Once). *Jurnal Nasional Ilmu Komputer*, 2(3), 213–232.
- Rofii, F., Priyandoko, G., Fanani, M. I., & Suraji, A. (2021). Vehicle Counting Accuracy Improvement By Identity Sequences Detection Based on Yolov4 Deep Neural Networks. *Teknik*, 42(2), 169–177.
- Salamah, I., Said, M. R. A., & Soim, S. (2022). Perancangan Alat Identifikasi Wajah Dengan Algoritma You Only Look Once (YOLO) Untuk Presensi Mahasiswa. *J. Media Inform. Budidarma*, 6(3), 1492.
- Soeltanong, M. B., & Sasongko, C. (2021). Perencanaan produksi dan pengendalian persediaan pada perusahaan manufaktur. *JRAP (Jurnal Riset Akuntansi Dan Perpajakan)*, 8(1), 14–27.
- Tawakkal, M. A. (2024). *Rancang Bangun Aplikasi Penghitungan Okupansi Manusia Dengan CCTV Menggunakan Object Detection Model YOLOv8*. Universitas Hasanuddin Makassar.
- UTOMO, M. S. (2023). *Deteksi Jumlah Manusia Menggunakan Metode YOLOv4 Dalam Suatu Gedung (Studi Kasus: Lab Elektro Unissula)*. Universitas Islam Sultan Agung.
- Widoretno, S., & Mahardika, A. M. A. F. (2024). Conveyor Belt dan Alat Penghitung Otomatis Berbasis Arduino Nano Menggunakan Sensor Inframerah pada Produksi Roti Tawar. *Jurnal Qua Teknika*, 14(1), 87–99.

- Yanto, Y., Aziz, F., & Irmawati, I. (2023). YOLO-V8 peningkatan algoritma untuk deteksi pemakaian masker wajah. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 7(3), 1437–1444.
- Yasen, N. M., Rifka, S., Vitria, R., & Yulindon, Y. (2023). Pemanfaatan YOLO untuk deteksi hama dan penyakit pada daun cabai menggunakan metode *deep learning* . *Elektron: Jurnal Ilmiah*, 63–71.