

# Eksperimen Pemodelan dan skenario Skenario Faster R-CNN untuk Penerapan Self Checkout Cashier

Manatap Dolok Lauro<sup>1</sup>, Lina<sup>2</sup>, Billy Marcelino<sup>3</sup>, Lorico Salim<sup>4</sup>,

<sup>1,2,3,4</sup>Teknik Informatika, Fakultas Teknologi Informasi, Universitas Tarumanagara

<sup>1</sup>manataps@ft.untar.ac.id, <sup>2</sup>lina@fti.untar.ac.id, <sup>3</sup>billy.535200009@stu.untar.ac.id, <sup>4</sup>lorico.535200015@stu.untar.ac.id

## Abstract

*This research focuses on developing an efficient and cost-effective self-checkout system for grocery stores by utilizing computer vision technology. The proposed system employs Faster R-CNN, a powerful deep learning algorithm, to detect and recognize products in real-time from images captured by a camera. This method eliminates the need for physical barcode/QR code scanning or the use of RFID tags, thereby significantly reducing operational costs. The study utilizes a dataset of 2,526 product images encompassing 10 distinct product classes. This dataset is divided into training data (2,026 images) and test data (500 images). The Faster R-CNN model is trained using the training data and then evaluated on the test data. Evaluation results demonstrate that the model achieves an accuracy of up to 84% when detecting a single object within a frame. However, the accuracy decreases to 44% for three objects and 12% for five objects within a frame. Despite the decrease in accuracy in scenarios with multiple objects, this research highlights the significant potential of computer vision technology in enhancing efficiency and the shopping experience in grocery stores. Further research is needed to improve the model's accuracy in detecting multiple objects simultaneously.*

*Keywords: self-checkout, computer vision, Faster R-CNN, product recognition, grocery stores*

## Abstrak

Penelitian ini bertujuan untuk mengembangkan sistem *self-checkout* yang efisien dan hemat biaya untuk toko kelontong dengan memanfaatkan teknologi *computer vision*. Sistem yang diusulkan menggunakan *Faster R-CNN*, sebuah algoritma *deep learning* untuk mendeteksi dan mengenali produk secara *real-time* dari gambar yang diambil oleh kamera. Metode ini menghilangkan kebutuhan akan pemindaian *barcode/QR code* atau penggunaan tag RFID, sehingga mengurangi biaya operasional secara signifikan. Penelitian ini menggunakan 2.526 foto produk yang terdiri dari 10 kelas produk yang berbeda. Data ini dibagi menjadi data latih (2.026 foto) dan data uji (500 foto). Model *Faster R-CNN* dilatih menggunakan data latih dan kemudian dievaluasi kinerjanya menggunakan data uji. Hasil evaluasi menunjukkan bahwa model mampu mencapai akurasi hingga 84% ketika mendeteksi satu objek dalam satu frame. Namun, akurasi menurun menjadi 44% untuk tiga objek dan 12% untuk lima objek dalam satu frame. Meskipun terdapat penurunan akurasi pada skenario dengan banyak objek, penelitian ini menunjukkan potensi besar dari teknologi *computer vision* dalam meningkatkan efisiensi dan pengalaman berbelanja di toko kelontong. Penelitian lebih lanjut diperlukan untuk meningkatkan akurasi model dalam mendeteksi banyak objek secara bersamaan.

Kata kunci: *self-checkout, computer vision, Faster R-CNN, pengenalan produk, toko kelontong*

©This work is licensed under a Creative Commons Attribution - ShareAlike 4.0 International.

## 1. Pendahuluan

Di Indonesia pengaplikasian teknologi barcode dan QR Code sering kita jumpai pada saat berbelanja di supermarket. Teknologi ini memiliki banyak kelebihan pada saat proses checkout barang di meja kasir jika dibandingkan dengan pencatatan manual. Namun, terdapat beberapa kekurangan yang ditemukan pada teknologi barcode seperti kapasitasnya yang terbatas untuk menyimpan data. Permasalahan seperti barcode yang sulit terbaca pada produk yang basah, dan adanya kemungkinan barcode mengalami kerusakan atau hilang sehingga tidak bisa dibaca scanner membuat antrean pada meja kasir menjadi tambah panjang, dan pembeli harus menunggu lebih lama lagi.

Toko kelontong yang mengadopsi teknologi ini dapat memberikan dampak positif; antara lain meningkatkan kepuasan pelanggan, meningkatkan efisiensi, memangkas biaya, dan pada akhirnya meningkatkan performa finansial [1]. Konsumen mengharapkan pengalaman berbelanja yang lancar, dan waktu yang

dihabiskan untuk menunggu di antrean kasir yang panjang dapat mengurangi pengalaman tersebut. Keterbatasan teknologi barcode dan QR Code [2] menghambat kemampuan toko untuk mengukur proses pembayaran secara efektif guna menangani peningkatan volume pelanggan.

Perkembangan teknologi terkini di sisi pengalaman berbelanja toko ritel yaitu dengan adanya adopsi *Self-Service Technology* (SST), yaitu suatu teknologi penghubung antara pembeli dan pihak penyedia barang/layanan tanpa adanya bantuan dari karyawan pihak tersebut [3]. SST bukanlah suatu sistem yang berdiri sendiri, sistem ini membutuhkan *servicescape*, yaitu suatu area yang mampu mempengaruhi intensi dan dorongan bagi pembeli untuk menggunakan SST tersebut [4]. Namun, faktor teknologi adalah suatu bagian yang tak terpisahkan dari SST. Teknologi ini telah merambah di berbagai bisnis dan telah menjadi suatu komponen yang krusial [5]. Tergantung dari jenis bisnisnya, beberapa metode SST yang dapat digunakan

antara lain penggunaan Barcode, QR Code, dan RFID [6], yang biasa diikuti dengan metode pembayaran yang bertujuan untuk memudahkan pembeli, seperti pembayaran menggunakan Debit/Credit Card, NFC, dan QRIS.

Meskipun beberapa toko kelontong modern telah bereksperimen dengan sistem pembayaran mandiri berbasis RFID, seperti yang terlihat pada sistem kotak yang diterapkan pada Uniqlo, Decathlon, dan Gramedia, masih terdapat kebutuhan yang terus-menerus akan sistem alternatif yang bertujuan untuk meningkatkan efisiensi. Berdasarkan penelitian yang telah dilakukan [7], [8], sistem self-checkout menggunakan RFID memberikan kemudahan dan kenyamanan dalam proses pembayaran. Namun kemudahan ini diikuti dengan besarnya biaya persiapan instalasi perangkat keras yang cukup tinggi, isu privasi yang melekat pada penggunaan RFID, serta biaya yang muncul akibat penggunaan tag RFID [9].

Selain penggunaan Barcode, QR Code, dan RFID, teknologi *computer vision* menghadirkan peluang untuk merevolusi pengalaman belanja dengan metode SST. Deteksi objek adalah salah satu tugas fundamental dalam Computer Vision, berfokus pada identifikasi dan lokalisasi objek semantik dalam gambar atau video [10]. Kemampuan ini mendasari berbagai macam aplikasi, antara lain kendaraan otonom [11], pengawasan [12], pencitraan medis [13], deteksi bahasa isyarat [14], dan identifikasi produk untuk proses *stock taking* [15].

Identifikasi produk melalui pengenalan obyek menawarkan metode tanpa kontak dan sangat mudah beradaptasi untuk menyederhanakan proses pembayaran [16]. Sistem seperti ini dapat secara drastis mengurangi waktu yang diperlukan untuk identifikasi produk, meminimalkan waktu antrian pembayaran, meningkatkan pengalaman berbelanja secara keseluruhan, serta dapat meminimalisir biaya infrastruktur di awal implementasi.

Penelitian ini memperkenalkan metode pembayaran otomatis tanpa kasir menggunakan computer vision untuk identifikasi produk. Pada kondisi yang sesungguhnya, pelanggan yang berbelanja di toko kelontong seringkali membeli lebih dari 1 produk. Berbeda dari penelitian sebelumnya yang hanya berfokus pada deteksi 1 obyek, penelitian ini difokuskan pada deteksi multi-obyek yang terekam dalam 1 foto. Tujuan utamanya adalah menciptakan solusi untuk meningkatkan pengalaman pembayaran di supermarket secara signifikan. Penerapan yang sukses tidak hanya akan meningkatkan kepuasan pelanggan tetapi juga dapat mengurangi biaya operasional toko dengan mengoptimalkan proses pembayaran.

Penelitian terdahulu yang menggunakan Faster R-CNN salah satunya mendeteksi gulma pada tanaman kedelai secara real-time [17]. Hasil penelitian ini menunjukkan akurasi yang mencapai 90.31% dengan waktu pendeteksian 0.59 detik. Implementasi yang dapat

dilakukan terhadap penelitian ini adalah pada robot pertanian otonom, dimana dalam kondisi ini, membutuhkan pendeteksian obyek yang bersifat real-time. Beberapa penelitian yang berfokus pada deteksi obyek yaitu menggunakan metode YOLOv5 [18], LeNet-5 [19], dan CNN [20] dalam mendeteksi produk kebutuhan sehari-hari. Secara berurutan, ketiga penelitian ini mendeteksi kebutuhan produk sehari-hari, kematangan buah apel, dan deteksi buah mangrove. Hasil ketiga penelitian menunjukkan bahwa penggunaan metode ini mampu mendeteksi obyek dengan baik.

Menurut penelitian [21] yang dilakukan terhadap produk ritel, perbandingan antara algoritma Faster R-CNN [22] dan YOLO9000 [23] memberikan hasil bahwa algoritma Faster R-CNN dapat mendeteksi obyek dengan lebih akurat, yaitu dengan tingkat akurasi sebesar 67,1%. Namun apabila dibandingkan dengan YOLO9000, algoritma ini memiliki waktu deteksi yang lebih cepat yaitu 0,023 detik per-foto.

Berdasarkan penelitian tersebut, sistem yang diusulkan memanfaatkan Faster R-CNN untuk mengidentifikasi produk secara akurat dari gambar kamera secara real-time. Metode ini menghilangkan kebutuhan akan pemindaian barcode/kode QR fisik atau tag RFID. Sistem yang dirancang memiliki potensi untuk menciptakan pengalaman pembayaran yang efisien dan tanpa hambatan.

## 2. Metode Penelitian

Prosedur otomatisasi belanja tanpa kasir / *self-checkout*, yaitu salah satu implementasi dari SST, untuk layanan mandiri di pasar ritel telah ada sejak tahun 80-an. Salah satu solusi utama dalam layanan mandiri otomatis ini adalah dengan memberikan pembeli kemampuan untuk memindai barcode mereka sendiri saat proses pembayaran. *Self-checkout* adalah layanan yang memungkinkan pengguna untuk melakukan pembayaran dan mengemas barang belanjaan mereka sendiri tanpa perlu bantuan kasir. Fasilitas ini sangat *user friendly*, karena pengguna hanya perlu melakukan pemindaian barang belanjaan mereka, mengemasnya, dan melakukan pembayaran sendiri menggunakan mesin yang tersedia. Salah satu contoh peralatan teknologi belanja tanpa kasir di sebuah supermarket dapat dilihat pada Gambar 1.



Gambar 1. Self-Checkout Cashier  
Sumber: Qingdao CCL Technology  
<https://id.cclkiosk.com/self-checkout/supermarket-self-checkout-kiosk.html>.

Tahap awal perancangan sistem *self-checkout* ini adalah perencanaan. Sistem ini bertujuan untuk mendeteksi dan mengenali produk serta harga produk belanja dalam gambar menggunakan metode Faster R-CNN, dengan tujuan mengurangi kebutuhan tenaga manusia pada proses pembayaran. Sistem dilatih dan diuji menggunakan sekitar 2.500 gambar produk dua dimensi, yang dibagi menjadi data latih (80%) dan data uji (20%). Detail jumlah masing-masing data dapat dilihat di Tabel 1. Data latih digunakan untuk melatih model Faster R-CNN, sementara data uji digunakan untuk evaluasi model. Kedua jenis data terdiri dari 10 kelas produk, dengan 200 gambar per kelas, yang diambil secara manual. Selain itu, 500 gambar produk tambahan akan digunakan sebagai data uji untuk mengukur kinerja sistem, yang terdiri dari 50 gambar per-kelas. Data uji ini juga diambil secara manual dan setiap gambar dapat berisi maksimal 5 produk dalam 1 gambar. Perangkat keras yang digunakan adalah sebuah PC dengan processor AMD Ryzen 5 5400U, Radeon Graphics 2.4 GHz, dan memory RAM sebesar 8GB.

Tabel 1. Pembagian Kelas serta Jumlah Data latih dan Data Uji

Kelas	Data Latih	Data Uji
Kelas 1	200	50
Kelas 2	200	50
Kelas n..	200	50
Kelas 10	200	50
Total	2.000	500

Setelah tahap perancangan selesai, sistem self-checkout dengan metode Faster R-CNN mulai dibangun. Proses ini terdiri dari dua langkah utama: pengembangan fungsi deteksi dan pengenalan produk menggunakan Python, serta pembuatan antarmuka pengguna grafis (GUI) berbasis desktop dengan PyQt5.

Proses pembangunan sistem *self-checkout* dimulai dengan pengumpulan data foto produk yang akan digunakan sebagai bahan pembelajaran bagi model Faster R-CNN dengan arsitektur ResNet-101. Model ini kemudian dilatih menggunakan data tersebut, dan setelah proses pelatihan selesai, dilakukan evaluasi terhadap model menggunakan data validasi yang terpisah. Jika hasil evaluasi menunjukkan kinerja yang memuaskan, model dan bobot yang dihasilkan disimpan untuk digunakan dalam tahap pengenalan produk selanjutnya.

Tahap berikutnya adalah pengembangan antarmuka pengguna grafis (GUI) berbasis desktop menggunakan library PyQt5. GUI ini dirancang untuk memberikan pengalaman pengguna yang intuitif dan mudah digunakan, dengan beberapa modul utama yang meliputi Modul Home sebagai tampilan utama yang menyediakan akses ke modul-modul lain; Modul Cart

yang menampilkan daftar produk yang berhasil dideteksi beserta jumlah, harga, dan total; Modul About yang berisi informasi mengenai aplikasi dan pengembangnya; serta Modul Help yang memberikan panduan penggunaan aplikasi.

Setelah seluruh komponen sistem selesai dibangun dan terintegrasi, pengujian menyeluruh dilakukan untuk memastikan bahwa sistem berjalan sesuai dengan yang tujuan diharapkan. Pengujian tampilan dilakukan dengan metode *black box testing*, di mana fokusnya adalah pada interaksi pengguna dengan antarmuka tanpa melihat kode internal sistem. Sementara itu, pengujian fungsionalitas sistem dilakukan dengan menjalankan berbagai skenario penggunaan dan mengumpulkan data hasil pengujian untuk dianalisis dan dilaporkan.

### 3. Hasil dan Pembahasan

#### 3.1. Dataset

Dataset yang digunakan dalam penelitian ini terdiri dari 2.526 foto produk, dengan 2.026 foto digunakan sebagai data latih dan 500 foto sebagai data uji. Proses pengumpulan data dilakukan secara manual dengan mengambil foto produk dari berbagai sudut pandang. Untuk memastikan konsistensi dan kualitas data, foto diambil dari atas produk dengan pencahayaan yang memadai. Setiap produk diberikan kesempatan untuk difoto dari beberapa sudut. Beberapa foto diambil dengan fokus pada satu produk dalam satu frame, sementara beberapa foto lainnya diambil dengan menampilkan hingga maksimal 5 produk dalam satu frame. Hal ini dilakukan untuk melatih model agar dapat mengenali produk baik secara individu maupun dalam kelompok.

Total terdapat 10 jenis produk yang diuji dalam penelitian ini. Setiap produk memiliki jumlah foto yang seimbang, baik dalam data latih maupun data uji, untuk memastikan bahwa model tidak bias terhadap produk tertentu. Dengan demikian, diharapkan model dapat mempelajari ciri-ciri khas dari setiap produk secara merata dan menghasilkan kinerja yang optimal dalam tugas deteksi dan pengenalan produk.

Tabel 2 menyajikan distribusi data latih dan data uji yang digunakan dalam pengembangan sistem self-checkout. Terdapat 10 jenis produk yang menjadi target deteksi dan pengenalan, yaitu Biskuit Selamat, Chitato Lite, Chitato Sapi, Fitbar, Nissin Cracker, Pocari, Pop Mie, Roma Kelapa, Teh Botol, dan Chiki Twist. Setiap jenis produk memiliki 250 gambar yang diambil secara manual, dengan 200 gambar dialokasikan sebagai data latih dan 50 gambar sebagai data uji. Data latih digunakan untuk melatih model Faster R-CNN agar dapat mengenali ciri-ciri khas dari setiap produk, sedangkan data uji digunakan untuk mengukur kinerja model setelah proses pelatihan selesai. Secara keseluruhan, terdapat 2026 gambar yang digunakan sebagai data latih dan 500 gambar sebagai data uji.

Distribusi data yang seimbang ini diharapkan dapat membantu model dalam mempelajari karakteristik setiap produk secara efektif dan menghasilkan kinerja yang baik dalam mendeteksi dan mengenali produk pada saat self-checkout.

Tabel 2. Detail Data Latih dan Data Uji

Kelas	Nama Produk	Data Latih	Data Uji
1	Roma Kelapa	203	50
2	Chitato Lite	202	50
3	Pop Mie	201	50
4	Teh Botol	205	50
5	Chitato Sapi	202	50
6	Fitbar	202	50
7	Nissin Cracker	203	50
8	Pocari	204	50
9	Chiki Twist	200	50
10	Biskuit Selamat	204	50
Total		2026	500

Tabel 3 di bawah ini menggambarkan contoh dataset yang digunakan dalam pengembangan sistem self-checkout. Dataset ini terdiri dari 10 kelas produk, dengan setiap kelas memiliki 200 gambar. Setiap baris pada tabel mewakili satu kelas produk, sedangkan kolom-kolomnya menunjukkan beberapa contoh gambar dari produk tersebut. Gambar-gambar produk dalam dataset ini diambil dari berbagai sudut pandang untuk melatih model agar mampu mengenali produk dengan baik, bahkan ketika produk tersebut berada dalam posisi atau orientasi yang berbeda. Dataset ini akan digunakan untuk melatih model Faster R-CNN agar dapat mendeteksi dan mengenali produk-produk ini secara akurat pada saat self-checkout.

Tabel 3. Contoh Data latih Yang terbagi Dalam 10 Kelas



### 3.2. Dataset Training

Penelitian ini dilaksanakan dengan menggunakan empat model berbeda dengan tujuan menemukan konfigurasi optimal untuk menghasilkan hasil deteksi obyek terbaik. Variasi difokuskan pada konfigurasi

*batch size* dan jumlah *epoch*, hal ini dilakukan untuk mengevaluasi pengaruhnya terhadap kemampuan model dalam uji akurasi dan *loss*.

Model 1 dan 2 diimplementasikan dengan *batch size* kecil, masing-masing 8 dan 16. Hasil analisis menunjukkan bahwa kedua model tersebut menunjukkan hasil yang baik, ditunjukkan dengan akurasi validasi yang tinggi (>99%) dan *loss* yang rendah. Hal ini mengindikasikan bahwa *batch size* kecil berkontribusi pada pemahaman model yang lebih mendalam terhadap pola data.

Model 3 menerapkan *batch size* yang lebih besar, yaitu 64. Meskipun akurasi pada data latih sedikit menurun (96%), performa pada data validasi tetap sangat baik (99,62%). Temuan ini menunjukkan bahwa peningkatan *batch size* tidak selalu berdampak signifikan pada kemampuan uji model.

Model 4 dilatih dengan *batch size* 64 dan jumlah *epoch* yang lebih banyak (900) dengan tujuan untuk memaksimalkan akurasi pada data latih. Meskipun berhasil mencapai akurasi 98% pada data latih, model ini menunjukkan akurasi validasi lebih rendah (81,32%) dibandingkan ke-3 model lainnya. Fenomena ini mengindikasikan terjadinya *overfitting*, di mana model terlalu teroptimasi pada data latih sehingga gagal mendemonstrasikan kemampuan generalisasi yang memadai pada data baru.

*Overfitting* yang terjadi pada model 4 dapat terjadi karena model dilatih dengan 900 *epoch*, lebih banyak dari model lainnya. Pelatihan berlebihan dapat menyebabkan model hanya dapat mengenali fitur yang ada di data latih, sehingga saat dilakukan pengujian, model memberikan hasil yang lebih rendah dibandingkan saat melakukan akurasi latih.

Berdasarkan analisis performa, Model 1 dan 2 menunjukkan performa terbaik secara keseluruhan, mencapai keseimbangan antara akurasi dan validasi. Model 3 juga menunjukkan performa yang memuaskan, sementara pada Model 4, hasil menunjukkan terdapat indikasi *overfitting* dan memerlukan optimasi lebih lanjut.

Tabel 4. Hasil Pelatihan Data

Model	Batch Size	Epoch	Akurasi Latih	Loss Latih	Akurasi Validasi	Loss Validasi
Model 1	8	800	97%	0,027	99,76%	0,231
Model 2	16	800	97%	0,196	99,64%	0,222
Model 3	64	800	96%	0,191	99,62%	0,173
Model 4	64	900	98%	0,029	81,32%	0,024

### 3.3. Test

Data uji yang digunakan untuk pengujian terdiri dari beberapa set gambar produk yang berbeda, dengan variasi jumlah produk dalam setiap set. Terdapat dua

macam set gambar, yaitu 3 produk dan 5 produk. Dalam setiap gambar, terdapat berbagai jenis produk makanan ringan dan minuman, seperti Chitato, Chiki, Pocari Sweat, dan mie instan, yaitu kombinasi dari ke-10 kelas produk yang sudah diambil sebelumnya. Produk-produk ini disusun secara acak dalam setiap gambar, dengan orientasi dan posisi yang berbeda-beda. Penempatan seperti ini bertujuan untuk menguji kemampuan model Faster R-CNN dalam mendeteksi dan mengenali objek secara akurat dalam berbagai kondisi. Data uji ini digunakan untuk mengevaluasi kinerja sistem self-checkout yang menggunakan Faster R-CNN. Dengan menguji model pada berbagai kombinasi produk dan tata letak, diharapkan sistem dapat mengenali produk dengan baik dalam situasi nyata di kasir swalayan. Contoh data uji dapat dilihat di Tabel 5.

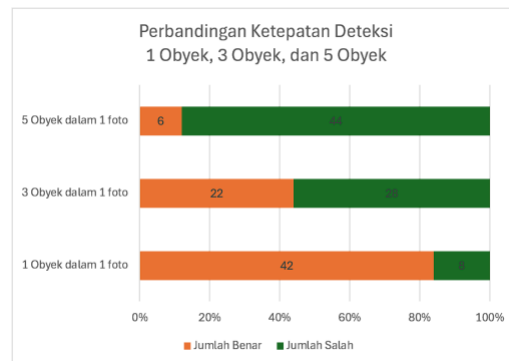
Tabel 6 menunjukkan hasil pengujian akurasi suatu sistem self-checkout. Terdapat tiga set skenario pengujian, yaitu satu objek dalam satu foto, tiga objek dalam satu foto, dan lima objek dalam satu foto.

Tabel 5. Contoh Data Uji Dengan Kombinasi 3 Produk dan 5 Produk

	Image 1	Image 2	Image 3	Image 4	Image 5
3 Produk Set 1					
3 Produk Set 2					
5 Produk Set 1					
5 Produk Set 2					

Pada skenario pertama, dengan satu objek dalam satu frame, sistem menunjukkan performa yang baik dengan tingkat akurasi sebesar 84%. Artinya, dari 50 data yang diuji, sistem mampu mendeteksi objek dengan benar sebanyak 42 kali. Namun, pada skenario kedua dan ketiga, akurasi sistem menurun secara signifikan. Ketika terdapat tiga objek dalam satu frame, akurasi sistem turun menjadi 44%, dengan hanya 22 deteksi benar dari 50 data uji. Penurunan akurasi yang lebih drastis terjadi pada skenario ketiga, di mana terdapat lima objek dalam satu frame. Dalam skenario ini, akurasi sistem hanya mencapai 12%, dengan hanya 6 deteksi benar dari 50 data uji.

Hasil pengujian ini menunjukkan bahwa sistem memiliki performa yang baik dalam mendeteksi objek tunggal dalam satu frame. Namun, kinerjanya menurun seiring dengan bertambahnya jumlah objek dalam satu frame. Hal ini mengindikasikan bahwa sistem mungkin mengalami kesulitan dalam membedakan dan mengenali objek dengan benar ketika terdapat banyak objek dalam satu frame.



Gambar 4. Hasil Pengujian Metode

### 3.4. Pembahasan

Pengujian model Faster R-CNN dengan arsitektur ResNet-101 pada sistem self-checkout menunjukkan hasil yang beragam dan memberikan wawasan berharga tentang kinerja model dalam skenario dunia nyata. Ketika hanya ada satu objek dalam frame gambar, model menunjukkan performa yang sangat baik dengan akurasi mencapai 84%. Ini berarti model mampu mengidentifikasi dan melokalisasi satu produk dengan tingkat kepercayaan yang tinggi. Misalnya, jika hanya ada satu botol minuman di keranjang belanja, sistem dapat dengan mudah mengenali dan mencatatnya.

Namun, tantangan muncul ketika jumlah objek dalam frame meningkat. Pada skenario tiga objek, akurasi turun menjadi 44%, menunjukkan bahwa model mulai mengalami kesulitan dalam memisahkan dan mengidentifikasi objek secara individual. Tumpang tindih antar objek atau kemiripan bentuk dan warna produk bisa menjadi faktor penyebab penurunan ini.

Penurunan akurasi semakin signifikan pada skenario lima objek, dimana akurasi hanya mencapai 12%. Dalam situasi ini, kompleksitas gambar meningkat secara drastis, dengan banyak objek saling bertumpuk dan memiliki berbagai orientasi. Misalnya, jika keranjang belanja berisi berbagai macam produk seperti minuman, makanan ringan, buah-buahan, dan sayuran, model mungkin kesulitan mengidentifikasi setiap item dengan benar.

Hasil pengujian ini menyoroti bahwa meskipun model Faster R-CNN dengan arsitektur ResNet-101 memiliki potensi yang baik dalam pengenalan objek tunggal, masih diperlukan peningkatan lebih lanjut untuk mencapai kinerja yang optimal dalam skenario multi-objek.

## 4. Kesimpulan

Penelitian ini berfokus pada pengembangan sistem self-checkout menggunakan metode Faster R-CNN dengan arsitektur ResNet-101. Dataset yang digunakan terdiri dari 2.526 foto produk, mencakup 10 jenis produk yang berbeda. Data latih terdiri dari 2.026 foto, sedangkan data uji terdiri dari 500 foto. Pengambilan

foto dilakukan secara manual dengan variasi jumlah produk dalam satu frame (1, 3, dan 5 produk) untuk melatih model mengenali objek baik secara individu maupun dalam kelompok.

Hasil pelatihan menunjukkan bahwa Model 1 dan Model 2 dijalankan dalam 800 epoch, yang memiliki performa terbaik dengan akurasi validasi yang tinggi (>99%) dan loss yang rendah. Model 3 juga dijalankan dalam 800 epoch, dan menunjukkan performa yang baik, sedangkan Model 4 mengalami overfitting.

Pengujian sistem pada data uji menunjukkan akurasi yang bervariasi. Sistem mencapai akurasi 84% untuk deteksi satu objek, 44% untuk tiga objek, dan 12% untuk lima objek dalam satu frame. Hasil ini menunjukkan bahwa model Faster R-CNN dengan arsitektur ResNet-101 memiliki potensi yang baik dalam pengenalan objek tunggal, namun perlu ditingkatkan lebih lanjut untuk mencapai kinerja optimal dalam skenario multi-objek.

Beberapa strategi peningkatan yang dapat dipertimbangkan termasuk augmentasi data, penyesuaian arsitektur model, penggunaan teknik ensemble, dan optimasi hyperparameter. Dengan melakukan langkah-langkah ini, diharapkan sistem self-checkout dapat menjadi lebih akurat dan efisien.

#### Ucapan Terimakasih

Penulis ingin menyampaikan terima kasih sebanyak-banyaknya kepada para pihak yang mendukung penyelesaian penelitian ini, yaitu: Lembaga Penelitian dan Pengabdian kepada Masyarakat (LPPM) Universitas Tarumanagara sebagai pemberi dana.

#### Daftar Rujukan

- [1] C. Y. T. Chan and D. Petrikat, "Self-Service Technology: Benefits and Challenges," *Journal of Computer Science and Technology Studies*, vol. 4, no. 2, pp. 118–127, Nov. 2022, doi: 10.32996/jcsts.2022.4.2.14.
- [2] H. Alamoudi, "Examining Retailing Sustainability in the QR Code-Enabled Mobile Payments Context During the COVID-19 Pandemic," *International Journal of Customer Relationship Marketing and Management*, vol. 13, no. 1, pp. 1–22, Oct. 2021, doi: 10.4018/IJCRMM.289210.
- [3] M. L. Meuter, M. J. Bitner, A. L. Ostrom, and S. W. Brown, "Choosing among Alternative Service Delivery Modes: An Investigation of Customer Trial of Self-Service Technologies," *J Mark*, vol. 69, no. 2, pp. 61–83, Apr. 2005, doi: 10.1509/jmkg.69.2.61.60759.
- [4] X. Guan, L. Xie, W.-G. Shen, and T.-C. Huan, "Are you a tech-savvy person? Exploring factors influencing customers using self-service technology," *Technol Soc*, vol. 65, p. 101564, May 2021, doi: 10.1016/j.techsoc.2021.101564.
- [5] N. Jalani, A. Azit, W. K. A. Wan Abd Manan, and M. Mokhtar, "THE INFLUENCE OF SELF-SERVICE EXPERIENCES ON CUSTOMER SATISFACTION," *International Journal of Industrial Management*, vol. 17, no. 4, pp. 186–194, Dec. 2023, doi: 10.15282/ijim.17.4.2023.10023.
- [6] P. A, V. A, N. K. C, S. R, and K. K, "Automatic Billing Trolley for an Enhanced Supermarket using RFID," in *2023 7th International Conference on Computing Methodologies and Communication (ICCMC)*, IEEE, Feb. 2023, pp. 840–844. doi: 10.1109/ICCMC56507.2023.10083555.
- [7] M. I. Ali, K. Ghazali, and A. S. Indrawanti, "Otomatisasi Sistem Keranjang Belanja pada Supermarket (Marketplace) Guna Meningkatkan Aspek Efisiensi Alur Perbelanjaan Menggunakan Sensor UHF RFID," *Jurnal Teknik ITS*, vol. 12, no. 1, May 2023, doi: 10.12962/J23373539.V12I1.104286.
- [8] T. Mannapur, P. Palange, A. Bhavsar, and S. D. Mali, "RFID Technology in Retail: A Study on IoT-Based Shopping Cart System," *International Journal of Advanced Research in Science, Communication and Technology*, pp. 265–272, May 2023, doi: 10.48175/IJARSCT-9748.
- [9] M. R. Krishna, M. Alifa Firdhos Farheen, and H. Killamsetti, "RFID-Powered Intelligent Shopping Cart: Streamlined Checkout and Automated Billing," in *2024 IEEE International Conference for Women in Innovation, Technology & Entrepreneurship (ICWITE)*, IEEE, Feb. 2024, pp. 345–348. doi: 10.1109/ICWITE59797.2024.10503373.
- [10] Z.-Q. Zhao, P. Zheng, S.-T. Xu, and X. Wu, "Object Detection With Deep Learning: A Review," *IEEE Trans Neural Netw Learn Syst*, vol. 30, no. 11, pp. 3212–3232, Nov. 2019, doi: 10.1109/TNNLS.2018.2876865.
- [11] O. BOURJA, H. DERROUZ, H. A. ABDELALI, A. MAACH, R. O. H. THAMI, and F. BOURZEIX, "Real Time Vehicle Detection, Tracking, and Inter-vehicle

- Distance Estimation based on Stereovision and Deep Learning using YOLOv3,” *International Journal of Advanced Computer Science and Applications*, vol. 12, no. 8, 2021, doi: 10.14569/IJACSA.2021.01208101.
- [12] R. Muwardi, J. M. R. Permana, H. Gao, and M. Yunita, “Human Object Detection for Real-Time Camera using Mobilenet-SSD,” *Journal of Integrated and Advanced Engineering (JIAE)*, vol. 3, no. 2, pp. 141–150, Sep. 2023, doi: 10.51662/jiae.v3i2.108.
- [13] J. Sobek *et al.*, “MedYOLO: A Medical Image Object Detection Framework,” *Journal of Imaging Informatics in Medicine*, Jun. 2024, doi: 10.1007/s10278-024-01138-2.
- [14] K. Aryasa and A. Rusydi, “Design and Build a Sign Language Detection Application with Tensorflow Object Detection and SSD Mobilenet V2,” in *2023 5th International Conference on Cybernetics and Intelligent System (ICORIS)*, IEEE, Oct. 2023, pp. 1–5. doi: 10.1109/ICORIS60118.2023.10352247.
- [15] M. N. Ardiansyah, P. S. Muttaqin, M. D. Prasetyo, and N. Novitasari, “Identifikasi Objek/Produk untuk Proses Stock Taking Barang menggunakan Konsep Object Recognition,” *Jurnal Rekayasa Sistem & Industri (JRSI)*, vol. 8, no. 01, p. 28, Jun. 2021, doi: 10.25124/jrsi.v8i1.455.
- [16] J.-Y. Jeon, S.-W. Kang, H.-J. Lee, and J.-S. Kim, “A Retail Object Classification Method Using Multiple Cameras for Vision-Based Unmanned Kiosks,” *IEEE Sens J*, vol. 22, no. 22, pp. 22200–22209, Nov. 2022, doi: 10.1109/JSEN.2022.3210699.
- [17] X. Zhang *et al.*, “Weed Identification in Soybean Seedling Stage Based on Optimized Faster R-CNN Algorithm,” *Agriculture*, vol. 13, no. 1, p. 175, Jan. 2023, doi: 10.3390/agriculture13010175.
- [18] P. Selvam and J. A. S. Koilraj, “A Deep Learning Framework for Grocery Product Detection and Recognition,” *Food Anal Methods*, vol. 15, no. 12, pp. 3498–3522, Dec. 2022, doi: 10.1007/s12161-022-02384-2.
- [19] D. C. Agustin, M. A. Rosid, and N. Ariyanti, “IMPLEMENTASI CONVOLUTIONAL NEURAL NETWORK UNTUK DETEKSI KESEGARAN PADA APEL,” *JURNAL FASILKOM*, vol. 13, no. 02, pp. 145–150, Aug. 2023, doi: 10.37859/jf.v13i02.5175.
- [20] H. Mukhtar, F. Alfamico, H. Fu’adah Amran, F. Handayani, and R. Medikawati Taufiq, “Deep Learning Untuk Klasifikasi Kematangan Buah Mangrove Berdasarkan Warna,” *JURNAL FASILKOM*, vol. 13, no. 3, pp. 563–569, Dec. 2023, doi: 10.37859/jf.v13i3.6292.
- [21] M. Ariyanto and P. D. Purnamasari, “Object Detection System for Self-Checkout Cashier System Based on Faster Region-Based Convolution Neural Network and YOLO9000,” in *2021 17th International Conference on Quality in Research (QIR): International Symposium on Electrical and Computer Engineering*, IEEE, Oct. 2021, pp. 153–157. doi: 10.1109/QIR54354.2021.9716200.
- [22] S. Ren, K. He, R. Girshick, and J. Sun, “Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks,” *IEEE Trans Pattern Anal Mach Intell*, vol. 39, no. 6, pp. 1137–1149, Jun. 2017, doi: 10.1109/TPAMI.2016.2577031.
- [23] J. Redmon and A. Farhadi, “YOLO9000: Better, Faster, Stronger,” in *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, IEEE, Jul. 2017, pp. 6517–6525. doi: 10.1109/CVPR.2017.690.