

Implementasi Deep Learning Untuk Klasifikasi Produk Grocery dan Deteksi Tanggal Kedaluwarsa Menggunakan Resnet50 dan Easyocr

Faza Hanif Suwanda*, Ekky Novriza Alam, Riska Yanu Fa'rifah

Program Studi Sarjana Sistem Informasi, Fakultas Rekayasa Industri, Universitas Telkom, Bandung, Indonesia

*Correspondence: fazahanifs@gmail.com

Abstrak

Pengecekan kategori produk dan tanggal kedaluwarsa pada toko grocery masih banyak dilakukan secara manual, sehingga rentan terhadap kekeliruan dan memakan waktu, terutama pada kemasan dengan cetakan tanggal yang kecil atau format penulisan yang beragam. Penelitian ini bertujuan membangun pipeline dua tahap yang mengklasifikasikan kategori produk grocery sekaligus mendeteksi tanggal kedaluwarsa pada citra produk secara otomatis. Metode yang digunakan terdiri atas model klasifikasi citra berbasis transfer learning dengan arsitektur ResNet50 (backbone dibekukan) yang dilatih pada tiga kategori produk (Buah Buahan, Produk Dairy, dan Roti), serta modul deteksi tanggal kedaluwarsa yang memanfaatkan detektor teks CRAFT bawaan EasyOCR, dipadukan dengan pencocokan pola (regex) dan mekanisme fallback OCR bertingkat. Model klasifikasi dilatih menggunakan 398 citra data latih dan diuji pada 98 citra data validasi, menghasilkan akurasi validasi sebesar 83,67%, jauh di atas baseline tebakan acak 33,3% untuk tiga kelas, dengan F1-score tertinggi pada kategori Produk Dairy (0,91). Pengujian pipeline deteksi tanggal pada 63 citra uji menunjukkan detection precision 70,0% dan overall valid rate 44,4%, mengindikasikan bahwa pendekatan pragmatis berbasis detektor teks siap pakai dapat berfungsi tanpa perlu melatih model deteksi objek khusus, meskipun keandalannya masih perlu ditingkatkan pada tahap penyaringan kandidat tanggal palsu. Evaluasi sistem terintegrasi juga menemukan bahwa asumsi desain awal, yaitu OCR hanya dijalankan pada kategori berkemasan, tidak sepenuhnya tepat, karena kategori Buah Buahan justru menunjukkan success rate lebih tinggi (83,3%) dibandingkan kategori berkemasan (40,4%). Kontribusi utama penelitian ini adalah pendekatan pragmatis yang memanfaatkan detektor teks siap pakai untuk menemukan lokasi objek tanggal yang sangat kecil tanpa melatih model deteksi objek khusus, sehingga pipeline dapat diimplementasikan end-to-end dengan sumber daya data dan komputasi yang terbatas.

Kata kunci: klasifikasi citra; deep learning; ResNet50; transfer learning; deteksi tanggal kedaluwarsa; OCR; EasyOCR

Abstract

Checking product categories and expiry dates in grocery stores is still largely done manually, making the process error-prone and time-consuming, especially for packaging with small or inconsistently formatted date prints. This research builds a two-stage pipeline that automatically classifies grocery product categories and detects expiry dates from product images. The method consists of an image classification model based on transfer learning with a frozen ResNet50 backbone, trained on three product categories (Fruits, Dairy Products, and Bread), and an expiry-date detection module leveraging the CRAFT text detector built into EasyOCR, combined with regular-expression matching and a tiered OCR fallback mechanism. The classification model was trained on 398 training images and evaluated on 98 validation images, achieving a validation accuracy of 83.67%, well above the 33.3% random-guess baseline for three classes, with the highest F1-score on the Dairy Products category (0.91). Testing of the date-detection pipeline on 63 test images showed a detection precision of 70.0% and an overall valid-date rate of 44.4%, indicating that a pragmatic approach based on a ready-made text detector can function without training a dedicated object detector, although reliability still needs improvement in filtering false-positive date candidates. Evaluation of the integrated system further found that the initial design assumption, that OCR should only run on packaged categories, was not entirely accurate, since the Fruits category showed a higher success rate (83.3%) than the packaged category (40.4%). The main contribution of this research is a pragmatic approach that leverages a ready-made text detector to locate very small date objects without training a dedicated object detector from scratch, allowing the pipeline to be implemented end-to-end under limited data and computing resources.

Keywords: image classification; deep learning; ResNet50; transfer learning; expiry date detection; OCR; EasyOCR

PENDAHULUAN

Pengelolaan persediaan makanan di tingkat rumah tangga maupun ritel skala kecil masih menghadapi kendala dalam mengenali jenis produk dan memantau tanggal kedaluwarsa secara konsisten. Beragamnya jenis kemasan, perbedaan desain label, serta keterbatasan waktu pengguna menyebabkan sebagian produk terlupakan atau tidak terpantau hingga melewati tanggal kedaluwarsanya. Pemeriksaan manual satu per satu label kemasan rentan terhadap kesalahan, terutama ketika

tanggal kedaluwarsa dicetak dengan ukuran kecil, kontras rendah, atau format penulisan yang berbeda antarproduk.

Perkembangan deep learning membuka peluang untuk mengotomasi sebagian proses tersebut. Convolutional Neural Network (CNN) telah banyak digunakan untuk klasifikasi citra karena mampu mengekstraksi fitur visual secara hierarkis (Purwono et al., 2023; Bhat et al., 2023), sementara Optical Character Recognition (OCR) memungkinkan ekstraksi teks, termasuk tanggal, langsung dari citra kemasan. Pada

domain retail, kombinasi kedua teknologi ini relevan untuk mendukung otomatisasi inventori dan pemeriksaan produk (Alabdan et al., 2024; Alghamdi et al., 2024).

Pemilihan arsitektur ResNet50 pada penelitian ini didasarkan pada karakteristik tugas berupa klasifikasi citra satu produk (single-object classification), bukan deteksi banyak objek dalam satu citra sebagaimana pada skenario deteksi produk di rak (shelf detection) yang umumnya menggunakan model deteksi objek seperti YOLO (Selvam and Koilraj, 2022). ResNet50 dipilih karena konsisten dilaporkan memiliki performa kuat dan kompetitif pada berbagai tugas klasifikasi citra produk dan makanan melalui pendekatan transfer learning (Selvam and Koilraj, 2022; Pettersson et al., 2024), termasuk pada kondisi data latih yang terbatas. Untuk deteksi dan pembacaan tanggal kedaluwarsa, penelitian ini menggunakan EasyOCR karena bersifat open source, relatif ringan dibandingkan layanan OCR komersial, mendukung lebih dari 80 bahasa, telah dilengkapi modul deteksi teks CRAFT yang terbukti efektif menemukan lokasi teks pada latar kompleks (Baek et al., 2019), serta mudah diintegrasikan dalam ekosistem Python yang sama dengan TensorFlow/Keras.

Meskipun demikian, pembacaan tanggal kedaluwarsa secara otomatis tetap menjadi tantangan tersendiri karena kemasan produk memiliki pola visual yang beragam, karakter hasil cetak dapat miring,

berbentuk dot matrix, atau mengalami gangguan kualitas pencetakan (Zheng et al., 2023). Beberapa penelitian telah mengembangkan pipeline OCR khusus untuk expiry date dengan akurasi tinggi (Zheng et al., 2023; Peng et al., 2025), namun evaluasi khusus terhadap pustaka OCR siap pakai seperti EasyOCR pada tanggal kedaluwarsa dalam kondisi nyata masih terbatas (Pettersson et al., 2024; Bohlol et al., 2025). Di sisi lain, penelitian klasifikasi produk grocery dan penelitian deteksi tanggal kedaluwarsa umumnya masih dikembangkan secara terpisah (Alabdan et al., 2024; Selvam and Koilraj, 2022; Zheng et al., 2023), padahal penerapan praktis di toko grocery membutuhkan satu sistem yang dapat langsung mengenali jenis produk sekaligus memeriksa tanggal kedaluwarsanya dalam satu kali pemindaian.

Penelitian Terdahulu dan Posisi Penelitian

Literatur menunjukkan bahwa pengenalan produk grocery paling akurat bila menggabungkan deteksi objek, klasifikasi citra, dan pembacaan teks kemasan, dengan ResNet50 sering menjadi backbone yang kuat dan OCR membantu membedakan produk yang sangat mirip (Selvam and Koilraj, 2022; Selvam et al., 2024; Bohlol et al., 2025). Tabel 1 merangkum posisi penelitian ini terhadap delapan penelitian terdahulu yang relevan.

Tabel 1. Posisi Penelitian (State of the Art)

No	Penulis	Metode	Fokus	Performa
1	(Selvam and Koilraj, 2022)	YOLOv5 + ResNet50 + text detection	Deteksi & pengenalan produk retail + OCR kemasan	Tidak dilaporkan eksplisit
2	(Wiryana et al., 2023)	CNN sederhana	Klasifikasi produk toko, 35 label, 1.050 citra	Accuracy 91,37%
3	(Bu et al., 2024)	Transfer learning + ensemble	Klasifikasi citra makanan	Accuracy 96,88%
4	(Pettersson et al., 2024)	Multimodal fusion citra + OCR	Pengenalan produk grocery fine-grained	Multimodal > unimodal
5	(Selvam et al., 2024)	YOLOv5 + OD-Refiner + OCR	Pengenalan produk pada latar kompleks	F-score 88,97%
6	(Khandaker et al., 2024)	Ensemble CNN (MobileNet+ResNet50)	Visual search & rekomendasi produk	Accuracy 99,8%
7	(Zheng et al., 2023)	Improved DBNet + ResNet + CTC	OCR tanggal kedaluwarsa kemasan makanan	Deteksi 97,9%; Recognition 97,8%
8	(Peng et al., 2025)	CNN-based text detection & recognition	OCR expiry date untuk aplikasi mobile	F1 0,9303; Accuracy 97,06%
9	Penelitian ini	ResNet50 (transfer learning, frozen) + EasyOCR (CRAFT) + regex	Klasifikasi 3 kategori + ekstraksi tanggal kedaluwarsa end-to-end	Accuracy klasifikasi 83,67%; Detection precision 70,0%; Valid rate 44,4% (n=63)

Berdasarkan Tabel 1, sebagian besar penelitian terdahulu hanya berfokus pada salah satu tugas, yaitu klasifikasi produk saja (Bu et al., 2024; Wiryana et al., 2023; Khandaker et al., 2024) atau deteksi/pengenalan tanggal kedaluwarsa saja (Zheng et al., 2023; Peng et al., 2025), sedangkan penelitian yang menggabungkan kedua tugas dalam satu pipeline (Selvam and Koilraj, 2022; Selvam et al., 2024; Bohlol et al., 2025), umumnya belum mengevaluasi kinerja pustaka OCR siap pakai seperti

EasyOCR secara spesifik pada tugas pembacaan tanggal kedaluwarsa. Kebaruan penelitian ini terletak pada empat aspek: (1) integrasi pipeline klasifikasi dan OCR dalam satu alur kerja terpadu, (2) penggunaan dataset produk grocery lokal yang dikumpulkan secara mandiri, (3) evaluasi khusus terhadap kinerja EasyOCR pada tugas pembacaan tanggal kedaluwarsa beserta interval kepercayaannya, dan (4) implementasi serta pengujian

sistem secara end-to-end, bukan hanya evaluasi tiap komponen secara terpisah.

METODE

Penelitian ini termasuk applied research dengan pendekatan kuantitatif, karena keberhasilan sistem diukur melalui metrik numerik (accuracy, precision, recall, F1-score). Metode yang digunakan adalah experimental research, yaitu merancang, mengimplementasikan, dan menguji pipeline computer vision secara bertahap, kemudian mengevaluasi hasilnya secara kuantitatif. Sebagai alternatif pada tahap deteksi tanggal kedaluwarsa, sempat dicoba pendekatan melatih model regresi bounding box khusus untuk memprediksi lokasi area tanggal. Pendekatan ini tidak digunakan pada

implementasi akhir karena area tanggal yang dicari berukuran sangat kecil ($\pm 0,6\%$ dari luas citra), sehingga satu head regresi tunggal kesulitan konvergen. Penelitian ini memilih memanfaatkan modul deteksi teks CRAFT yang sudah tersedia pada EasyOCR sebagai pendekatan yang lebih pragmatis dan sesuai dengan keterbatasan data.

Dataset

Dataset merupakan data primer yang dikumpulkan secara mandiri menggunakan kamera ponsel dan penelusuran citra daring, disusun ke dalam tiga kategori produk grocery: Buah Buahan, Produk Dairy, dan Roti. Tabel 2 merangkum spesifikasi akuisisi data, sedangkan Tabel 3 merangkum karakteristik umum dataset.

Tabel 2. Spesifikasi Akuisisi Data

Parameter	Keterangan
Perangkat	Kamera ponsel (smartphone)
Format citra	JPEG/JPG
Resolusi asli	Bervariasi sesuai perangkat pengambilan
Ukuran input model	224×224 piksel (setelah resize)
Latar (background)	Kondisi nyata (real-world), bukan studio foto
Pencahayaannya	Bervariasi (indoor dan cahaya alami)
Orientasi citra	Beragam, tidak difokuskan pada satu sudut tertentu

Tabel 3. Karakteristik Dataset

Karakteristik	Nilai
Jumlah kelas	3 (Buah Buahan, Produk Dairy, Roti)
Jumlah dataset klasifikasi	496 citra (398 data latih, 98 data validasi)
Format berkas	JPG/JPEG
Resolusi input model	224×224 piksel
Dataset OCR (pengujian pipeline)	63 citra uji, terpisah dari data latih/validasi klasifikasi
Jumlah citra mentah terkumpul	± 583 citra sebelum penyaringan

Pelabelan dataset dilakukan otomatis berdasarkan struktur folder melalui fungsi `flow from directory()` pada Keras Image Data Generator, sehingga tidak memerlukan anotasi manual satu per satu. Pembagian data latih dan validasi menggunakan skema 80:20 dengan random seed tetap (`seed = 42`), menghasilkan 398 citra data latih (80,24%) dan 98 citra data validasi (19,76%), tanpa independent test set terpisah mengingat keterbatasan jumlah data yang dikumpulkan secara mandiri.

Preprocessing

Seluruh citra diseragamkan menjadi 224×224 piksel sesuai kebutuhan input ResNet50. Normalisasi nilai piksel menggunakan fungsi `preprocess_input` bawaan ResNet50 (bukan `rescale 1/255`) agar skema normalisasi konsisten dengan skema saat ResNet50 dilatih pada ImageNet. Karena ukuran dataset relatif kecil, augmentasi citra diterapkan pada data latih (Tabel 4) untuk memperbanyak variasi data secara artifisial dan mengurangi risiko overfitting; data validasi hanya dinormalisasi tanpa augmentasi tambahan.

Tabel 4. Konfigurasi Data Augmentation pada Data Latih

Parameter	Nilai
Rotasi	hingga 40°
Pergeseran horizontal/vertikal	hingga 25%
Shear	0,2
Zoom	hingga 30%
Flip horizontal	Ya
Variasi kecerahan	0,6–1,4 kali
Pergeseran kanal warna	hingga 30

Arsitektur Model Klasifikasi

Model klasifikasi menggunakan ResNet50 pretrained ImageNet sebagai backbone dengan skema transfer learning backbone dibekukan (frozen), dilanjutkan dengan Global Average Pooling 2D, Batch Normalization, Dropout (0,5), Dense 128 neuron (aktivasi

ReLU, regularisasi L2), Dropout tambahan (0,5), dan lapisan output Dense 3 neuron dengan aktivasi Softmax (Tabel 5). Total parameter yang dapat dilatih (trainable) pada model ini adalah 266.755 parameter, jauh lebih sedikit dibandingkan total parameter ResNet50 ($\pm 23,5$ juta) karena seluruh lapisan backbone dibekukan.

Tabel 5. Konfigurasi Arsitektur Model Klasifikasi

Tahapan	Konfigurasi	Output Shape
Input	224×224×3	224×224×3
ResNet50 Backbone	Pretrained ImageNet (frozen)	7×7×2048
Global Average Pooling	GAP2D	2048
Batch Normalization	Default	2048
Dropout	0,5	2048
Dense	128 neuron, ReLU, L2	128
Dropout	0,5	128
Output Dense	3, Softmax	3

Strategi backbone dibekukan penuh dipilih karena jumlah data latih relatif kecil (398 citra untuk tiga kategori). Pada percobaan awal, penerapan fine-tuning (membuka kembali sebagian lapisan ResNet50) pada dataset seukuran ini menurunkan akurasi validasi secara drastis dari sekitar 88% menjadi mendekati level tebakan acak ($\pm 33\%$), yang mengindikasikan model kehilangan kemampuan generalisasi (menghafal data latih). Berdasarkan temuan empiris tersebut, skema fine-tuning tidak digunakan pada pelatihan model final.

Pembobotan Kelas dan Konfigurasi Pelatihan

Jumlah citra data latih pada setiap kategori tidak seimbang (139 citra Buah Buahan, 115 citra Produk Dairy, 144 citra Roti). Untuk mengurangi potensi bias terhadap kelas mayoritas, diterapkan class weighting menggunakan fungsi `compute_class_weight` (scikit-learn, skema 'balanced'), menghasilkan bobot 0,954 untuk Buah Buahan, 1,154 untuk Produk Dairy, dan 0,921 untuk Roti. Konfigurasi pelatihan selengkapnya disajikan pada Tabel 6.

Tabel 6. Konfigurasi Pelatihan Model Klasifikasi

Parameter	Nilai
Optimizer	Adam
Learning rate	0,001, diturunkan otomatis via ReduceLROnPlateau (faktor 0,5, patience 4)
Batch size	16
Epoch (maksimum)	30, dengan EarlyStopping (patience 8, restore_best_weights)
Class weight	'balanced' (Buah Buahan 0,954; Produk Dairy 1,154; Roti 0,921)
Loss function	Categorical Crossentropy

Implementasi EasyOCR dan Ekstraksi Tanggal

Pipeline deteksi tanggal kedaluwarsa memanfaatkan modul CRAFT bawaan EasyOCR untuk mendeteksi seluruh bounding box area teks pada citra beserta skor keyakinannya; kotak dengan skor keyakinan minimal 0,1 dipertimbangkan sebagai kandidat area teks. Reader EasyOCR diinisialisasi dengan konfigurasi `easyocr.Reader(['en'], gpu=True)`. Setiap kotak teks hasil deteksi disaring menggunakan enam pola regular expression (regex) yang dirancang untuk mengenali berbagai format penulisan tanggal kedaluwarsa: format numerik lengkap (mis. 31-03-2022), format tahun-bulan-tanggal (mis. 2022-03-31), format tanggal dengan singkatan nama bulan (mis. 09 JUN 26), format tahun-bulan atau bulan-tahun saja, serta format berkata kunci EXP/BB/BBE/Best Before/Use By. Pola regex menggunakan negative lookbehind/lookahead (`(?!<!\d)` dan `(?!>\d)`) alih-alih penanda batas kata (`\b`), karena `\b` terbukti gagal pada kasus tanggal yang berdempetan

langsung dengan karakter non-Latin (mis. karakter Hangul).

Pipeline deteksi tanggal dirancang bertingkat dalam tiga tahap fallback: (1) box detection — area kandidat yang cocok pola tanggal di-crop, diperbesar (upscale 2×), dan dibaca ulang dengan allowlist digit; (2) fallback teks penuh — apabila tidak ada kotak yang cocok, sistem membaca ulang seluruh citra tanpa pembatasan karakter; dan (3) fallback digit — apabila tahap kedua belum berhasil, sistem membaca ulang seluruh citra dengan allowlist terbatas pada digit dan simbol tanggal. Sistem baru beralih ke tahap berikutnya apabila tahap sebelumnya gagal menghasilkan kandidat tanggal yang valid.

Integrasi Pipeline

Klasifikasi produk dan deteksi tanggal kedaluwarsa diintegrasikan menjadi satu alur kerja: citra input pertama diklasifikasikan untuk memperoleh

kategori dan skor keyakinan; apabila kategori termasuk produk berkemasan (Produk Dairy atau Roti), sistem melanjutkan ke tahap deteksi tanggal. Apabila kategori adalah Buah Buahan (produk segar), tahap OCR dilewati secara default kecuali pada mode pengujian paksa-OCR (`force_ocr = True`) yang digunakan khusus untuk keperluan evaluasi menyeluruh pada penelitian ini. Keluaran akhir sistem terdiri atas kategori produk, skor keyakinan klasifikasi, tanggal kedaluwarsa hasil ekstraksi, dan metode deteksi yang berhasil digunakan.

Metode Evaluasi

Kinerja model klasifikasi dievaluasi menggunakan confusion matrix serta metrik accuracy, precision, recall, dan F1-score dengan pendekatan one-vs-rest untuk klasifikasi multi-kelas, dirangkum menjadi rata-rata makro dan rata-rata tertimbang. Evaluasi pipeline deteksi tanggal dilakukan pada 63 citra uji

dengan mengklasifikasikan setiap keluaran ke dalam tiga kondisi: tanggal ditemukan dan valid (true positive), tanggal ditemukan tetapi tidak valid (false positive), dan tanggal tidak ditemukan sama sekali (false negative). Berdasarkan ketiga kondisi tersebut dihitung detection precision, detection recall, dan overall valid rate, masing-masing disertai interval kepercayaan 95% menggunakan Wilson score interval mengingat keterbatasan ukuran sampel.

HASIL

Hasil Persiapan Dataset

Setelah proses pembersihan struktur folder, diperoleh total 496 citra yang siap digunakan pada proses pelabelan otomatis (Tabel 7). Distribusi kelas relatif seimbang antar kategori meskipun tidak identik, sehingga pembobotan kelas diterapkan pada tahap pelatihan.

Tabel 7. Jumlah Dataset Hasil Pengumpulan per Kategori

Kategori	Citra Latih	Citra Validasi	Total
Buah Buahan	139	34	173
Produk Dairy	115	28	143
Roti	144	36	180
Total	398	98	496

Hasil Pelatihan Model Klasifikasi

Pelatihan berjalan hingga maksimum 30 epoch dengan mekanisme EarlyStopping yang memantau

akurasi validasi. Tabel 8 menunjukkan cuplikan akurasi dan loss pada delapan epoch pertama.

Tabel 8. Cuplikan Akurasi dan Loss Pelatihan (Epoch 1–8)

Epoch	Train Acc.	Train Loss	Val. Acc.	Val. Loss
1	0,7186	33,302	0,6224	41,082
2	0,8970	26,584	0,6939	35,065
3	0,8920	24,929	0,7245	33,519
4	0,9171	24,089	0,7143	30,743
5	0,9447	21,472	0,7143	29,291
6	0,9422	20,097	0,7449	26,984
7	0,9472	19,574	0,7143	26,961
8	0,9573	18,071	0,6837	26,609

Train accuracy meningkat cukup cepat dan stabil di atas 0,90 sejak epoch ke-2, sedangkan akurasi validasi meningkat lebih lambat dan berfluktuasi pada beberapa epoch — indikasi overfitting ringan yang wajar terjadi pada dataset berukuran kecil, namun tidak parah karena akurasi validasi tetap jauh di atas baseline tebakan acak. Model terbaik (bobot pada epoch dengan akurasi validasi tertinggi, disimpan melalui `restore_best_weights`) dievaluasi ulang pada seluruh 98 citra data validasi,

menghasilkan validation loss 1,5255 dan validation accuracy 83,67%.

Evaluasi Model Klasifikasi

Confusion matrix pada data validasi menunjukkan prediksi benar sebanyak 26 dari 34 citra Buah Buahan, 24 dari 28 citra Produk Dairy, dan 32 dari 36 citra Roti. Tabel 9 merangkum precision, recall, dan F1-score per kategori.

Tabel 9. Precision, Recall, dan F1-Score Model Klasifikasi

Kelas	Precision	Recall	F1-Score	Support
Buah Buahan	0,84	0,76	0,80	34
Produk Dairy	0,96	0,86	0,91	28
Roti	0,76	0,89	0,82	36
Macro avg	0,85	0,84	0,84	98
Weighted avg	0,85	0,84	0,84	98

F1-score tertinggi diperoleh kategori Produk Dairy (0,91), diikuti Roti (0,82) dan Buah Buahan (0,80). Penelusuran silang antara nilai recall dan precision per kelas mengindikasikan bahwa sumber kesalahan paling dominan adalah citra Buah Buahan yang diprediksi sebagai Roti (diperkirakan mencakup 7–8 dari 8 total kesalahan pada kelas Buah Buahan), sedangkan kesalahan pada Produk Dairy relatif kecil dan tersebar tipis ke dua kelas lain. Class weighting terbukti efektif mencegah bias terhadap kelas mayoritas, ditunjukkan

oleh recall Roti (kelas dengan citra latih terbanyak, 0,89) yang tidak jauh berbeda dari recall Produk Dairy (kelas dengan citra latih paling sedikit, 0,86).

Evaluasi Pipeline Deteksi Tanggal Kedaluwarsa

Setiap keluaran pada 63 citra uji diperiksa dan diklasifikasikan ke dalam tiga kondisi sebagaimana dirangkum pada Tabel 10, yang berfungsi sebagai confusion sederhana untuk tahap deteksi tanggal.

Tabel 10. Confusion Sederhana Hasil Deteksi Tanggal pada 63 Citra Uji

Kondisi	Jumlah Citra	Persentase (dari 63)
Tanggal ditemukan dan valid (TP)	28	44,4%
Tanggal ditemukan tetapi tidak valid (FP)	12	19,0%
Tanggal tidak ditemukan sama sekali (FN)	23	36,5%

Berdasarkan Tabel 10, diperoleh Detection Precision = $28/(28+12) = 70,0\%$ dengan interval kepercayaan 95% Wilson [54,6%–81,9%] ($n = 40$ kandidat yang ditemukan); Detection Recall = $28/(28+23) = 54,9\%$ dengan interval kepercayaan 95% [41,4%–67,7%] ($n = 51$); dan Overall Valid Rate = $28/63 = 44,4\%$ dengan interval kepercayaan 95% [32,8%–56,7%] ($n = 63$). Perlu dicatat bahwa perhitungan recall tetap mengasumsikan seluruh 63 citra uji memang memuat tanggal kedaluwarsa yang terbaca, karena penelitian ini tidak menyertakan label ground truth manual untuk citra uji; Detection Precision tidak bergantung pada asumsi tersebut sehingga lebih dapat dipertanggungjawabkan sebagai metrik utama.

Dari 40 kandidat tanggal yang ditemukan, 12 di antaranya (30,0%) merupakan false positive, didominasi oleh format numerik pendek yang mudah cocok dengan rangkaian angka hasil salah baca OCR pada kode produk, berat kemasan, atau kode toko (mis. “86.9465”, “4-6200”, “30.16.500” dengan bulan 16 yang tidak valid), maupun kombinasi hari/bulan di luar rentang wajar (mis. “35-7-98” dengan hari 35). Temuan ini menegaskan bahwa validasi rentang hari (1–31), bulan (1–12), dan tahun yang masuk akal belum diterapkan pada tahap ekstraksi regex saat ini, dan menjadi penyebab utama seluruh kasus false positive yang teramati.

Tabel 11. Distribusi Metode Deteksi Tanggal pada 63 Citra Uji

Metode Deteksi	Jumlah Citra	Persentase
Box detection (kotak teks langsung cocok pola tanggal)	19	30,2%
Fallback teks penuh (OCR seluruh citra tanpa batasan karakter)	14	22,2%
Fallback digit (OCR seluruh citra, hanya digit)	30	47,6%

Mayoritas deteksi (69,8%) tetap bergantung pada kedua mekanisme fallback yang bekerja pada seluruh citra, sehingga fallback berperan sebagai jalur utama, bukan sekadar mekanisme cadangan sebagaimana dirancang semula. Pemeriksaan terhadap teks mentah hasil OCR mengungkap beberapa pola kesalahan baca yang berulang: (1) tanggal yang berdempetan langsung dengan kode produk atau harga terbaca sebagai satu rangkaian digit panjang tanpa pemisah; (2) karakter tanggal berformat dot-matrix menghasilkan pembacaan tidak konsisten; (3) beberapa kasus salah baca mengubah nilai hari/bulan menjadi di luar rentang wajar; dan (4) pada kemasan Roti bermerek, OCR mampu membaca frasa kunci seperti “Best Before” dengan cukup baik meskipun tanggal yang mengikutinya tidak selalu terekstraksi secara utuh.

Evaluasi Sistem Terintegrasi

Pengujian end-to-end pada seluruh 63 citra uji dengan mode paksa-OCR menghasilkan success rate pada kategori berkemasan sesuai desain default (Produk Dairy dan Roti, 57 citra) sebesar $23/57 = 40,4\%$ (interval kepercayaan 95% [28,6%–53,3%]), dan success rate pada kategori Buah Buahan yang diuji lewat mode paksa-OCR (6 citra) sebesar $5/6 = 83,3\%$ (interval kepercayaan 95% [43,6%–97,0%]). Pipeline accuracy keseluruhan (proporsi seluruh 63 citra uji yang menghasilkan tanggal valid, terlepas dari kategori) adalah $28/63 = 44,4\%$, konsisten dengan Overall Valid Rate pada subbab 3.4.

Temuan bahwa Success Rate kategori Buah Buahan (83,3%) jauh lebih tinggi dibandingkan kategori berkemasan sesuai desain default (40,4%) secara konsisten muncul pada dua pengujian independen yang dilakukan pada tahap pengembangan ($n = 20$ dan $n = 63$), mempertanyakan asumsi desain awal pipeline bahwa OCR hanya perlu dijalankan pada kategori berkemasan.

Meskipun jumlah citra Buah Buahan pada pengujian masih kecil sehingga interval kepercayaannya melebar, konsistensi arah temuan pada dua pengujian independen memperkuat perlunya peninjauan ulang terhadap logika penentuan kategori “berkemasan” pada tahap integrasi.

Perbandingan dengan Penelitian Terdahulu

Tabel 12. Perbandingan Hasil Penelitian dengan Penelitian Terdahulu

Penelitian	Model/Metode	Fokus	Accuracy/F1
(Wiryana et al., 2023)	CNN sederhana	Klasifikasi produk toko (35 label)	Accuracy 91,37%
(Bu et al., 2024)	Transfer learning + ensemble	Klasifikasi citra makanan	Accuracy 96,88%
(Khandaker et al., 2024)	Ensemble CNN (MobileNet+ResNet50)	Visual search produk grocery	Accuracy 99,8%
(Selvam et al., 2024)	YOLOv5 + OD-Refiner + OCR	Pengenalan produk latar kompleks	F-score 88,97%
(Zheng et al., 2023)	Improved DBNet + CTC	OCR tanggal kedaluwarsa	Deteksi 97,9%; Recognition 97,8%
(Peng et al., 2025)	CNN-based text detection	OCR expiry date mobile	F1 0,9303; Accuracy 97,06%
Penelitian ini	ResNet50 (frozen) + EasyOCR + regex	Klasifikasi 3 kategori + deteksi tanggal end-to-end	Accuracy klasifikasi 83,67%; Detection precision 70,0%; Valid rate 44,4%

Akurasi klasifikasi maupun keberhasilan deteksi tanggal pada penelitian ini berada di bawah sebagian besar penelitian pembanding. Selisih performa tersebut dapat ditelusuri pada beberapa faktor penyebab: (1) ukuran dataset penelitian ini (398 citra latih) jauh lebih kecil dibandingkan penelitian pembanding klasifikasi yang menggunakan ribuan hingga puluhan ribu citra (Bu et al., 2024; Wiryana et al., 2023; Khandaker et al., 2024); (2) strategi transfer learning frozen dipilih sebagai konsekuensi langsung dari keterbatasan data tersebut, karena percobaan fine-tuning pada dataset ini justru menjatuhkan akurasi validasi mendekati tebakan acak; (3) penelitian ini secara sengaja tidak melatih detektor teks khusus (seperti improved DBNet pada (Zheng et al., 2023) atau CNN kustom pada (Peng et al., 2025)) dan memanfaatkan CRAFT bawaan EasyOCR yang bersifat generik, sehingga wajar bila precision deteksi tanggal berada di bawah penelitian yang menggunakan detektor khusus; dan (4) penelitian ini tidak menyertakan tahap deteksi objek berbasis YOLO sebagaimana pada (Selvam and Koilraj, 2022; Selvam et al., 2024), karena setiap citra input diasumsikan berisi satu produk yang difoto secara close-up, bukan citra rak dengan banyak produk, sehingga perbandingan langsung terhadap F-score pada (Selvam et al., 2024) tidak sepenuhnya setara. Selisih performa ini karenanya bukan semata-mata kelemahan metodologis, melainkan konsekuensi logis dari keputusan desain yang diambil untuk mengakomodasi keterbatasan sumber daya data dan komputasi. Kontribusi utama penelitian ini karenanya bukan pada pencapaian akurasi tertinggi, melainkan pada pembuktian bahwa integrasi end-to-end klasifikasi dan OCR tetap dapat diimplementasikan secara fungsional pada kondisi keterbatasan tersebut.

Keterbatasan Penelitian

- Jumlah dataset klasifikasi masih terbatas (496 citra untuk tiga kelas), sehingga akurasi klasifikasi (83,67%) masih di bawah penelitian pembanding yang menggunakan dataset lebih besar.
- Pembagian dataset klasifikasi hanya menggunakan skema latih:validasi (80:20) tanpa independent test set.
- Penelitian ini tidak menyertakan anotasi ground truth manual untuk citra uji, sehingga Detection Recall dan Overall Valid Rate masih bergantung pada asumsi bahwa setiap citra uji memang memuat tanggal yang seharusnya dapat dibaca.
- Precision deteksi tanggal baru mencapai 70,0%, menunjukkan pola regex saat ini masih perlu diperketat, terutama pada validasi rentang hari/bulan/tahun yang masuk akal.
- Asumsi desain bahwa OCR hanya perlu dijalankan pada kategori berkemasan terbukti tidak sepenuhnya tepat, karena Success Rate kategori Buah Buahan tetap lebih tinggi dibandingkan kategori berkemasan pada dua pengujian independen.
- Waktu inferensi sistem belum diukur secara sistematis, sehingga kelayakan penggunaan sistem pada kondisi operasional real-time belum dapat dinilai.
- Sampel Buah Buahan pada pengujian deteksi tanggal masih sangat kecil (6 dari 63 citra) sehingga belum representatif untuk kategori tersebut.

SIMPULAN

Model klasifikasi ResNet50 dengan skema transfer learning frozen backbone berhasil mengklasifikasikan tiga kategori produk grocery dengan akurasi validasi 83,67%, jauh di atas baseline tebakan acak (33,3%), dengan F1-score tertinggi pada kategori

Produk Dairy (0,91). Pipeline deteksi tanggal berbasis EasyOCR yang dipadukan dengan regex dan fallback bertingkat menghasilkan detection precision 70,0% dan overall valid rate 44,4% pada pengujian 63 citra uji, menunjukkan bahwa pipeline mampu berfungsi tanpa perlu melatih model deteksi objek khusus, namun masih perlu ditingkatkan terutama pada aspek penyaringan kandidat tanggal palsu. Integrasi kedua komponen ke dalam satu pipeline berhasil menghasilkan keluaran gabungan berupa kategori produk, skor keyakinan, tanggal kedaluwarsa, dan metode deteksi dalam satu alur kerja tunggal; namun evaluasi integrasi secara konsisten menemukan bahwa asumsi desain awal (OCR hanya dijalankan pada kategori berkemasan) tidak sepenuhnya tepat, sehingga aspek ini masih memerlukan penyempurnaan sebelum dapat diterapkan secara penuh tanpa mode paksa-OCR.

Penelitian lanjutan disarankan untuk: (1) menyusun anotasi ground truth manual pada citra uji agar Detection Recall dapat dihitung secara akurat; (2) menambah jumlah dan variasi dataset klasifikasi, khususnya kategori Produk Dairy; (3) menyediakan independent test set yang benar-benar terpisah dari proses pengembangan model; (4) memperketat pola regex atau menambahkan validasi semantik rentang hari/bulan/tahun; (5) meninjau ulang logika penentuan kategori “berkemasan” pada tahap integrasi; (6) memperbesar jumlah sampel uji khusus kategori Buah-Buahan; (7) mengukur waktu inferensi setiap tahap pipeline secara sistematis; (8) mempertimbangkan model deteksi teks atau objek khusus (mis. DBNet, YOLO) apabila dataset area tanggal kedaluwarsa di masa depan sudah cukup besar untuk dilatih; dan (9) mengembangkan kemampuan sistem untuk pemrosesan video atau aliran citra real-time sebagai langkah menuju penerapan praktis di lingkungan operasional toko grocery.

DAFTAR PUSTAKA

- H. Peng, J. Bayón, J. Recas, and M. Guijarro, “Efficient expiration date recognition in food packages for mobile applications,” *Algorithms*, vol. 18, no. 5, p. 286, 2025, doi: 10.3390/a18050286.
- I. M. Wiryana, S. Harmanto, A. Fauzi, I. B. Qisthi, and Z. N. Utami, “Store product classification using convolutional neural network,” *IAES Int. J. Artif. Intell.*, vol. 12, no. 3, pp. 1439–1447, 2023, doi: 10.11591/ijai.v12.i3.pp1439-1447.
- J. Zheng, J. Li, Z. Ding, L. Kong, and Q. Chen, “Recognition of expiry data on food packages based on improved DBNet,” *Connect. Sci.*, vol. 35, no. 1, pp. 1–16, 2023, doi: 10.1080/09540091.2023.2202363.
- L. Bu, C. Hu, and X. Zhang, “Recognition of food images based on transfer learning and ensemble learning,” *PLOS ONE*, vol. 19, 2024, doi: 10.1371/journal.pone.0296789.
- M. Alghamdi, H. Mengash, M. Aljebreen, M. Maray, A. A. Darem, and A. S. Salama, “Empowering retail through advanced consumer product recognition using Aquila optimization algorithm with deep learning,” *IEEE Access*, vol. 12, pp. 71055–71065, 2024, doi: 10.1109/access.2024.3399480.
- M. Purwono, A. Ma'arif, W. Rahmانيar, H. Fathurrahman, A. Frisky, and Q. Haq, “Understanding of convolutional neural network (CNN): A review,” *Int. J. Robot. Control Syst.*, vol. 2, no. 4, pp. 613–627, 2023, doi: 10.31763/ijrcs.v2i4.888.
- N. A. Khandaker, A. Rahman, A. A. Pinky, and T. Anannya, “A deep convolutional neural network-based approach for visual search & recommendation of grocery products,” *Ann. Data Sci.*, vol. 12, pp. 877–897, 2024, doi: 10.1007/s40745-024-00540-5.
- P. Bohlol, S. Hosseinpour, and M. S. Firouz, “Improved food recognition using a refined ResNet50 architecture with improved fully connected layers,” *Curr. Res. Food Sci.*, vol. 10, 2025, doi: 10.1016/j.crfs.2025.101005.
- 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, 2022, doi: 10.1007/s12161-022-02384-2.
- P. Selvam, M. Faheem, V. Dakshinamurthi, A. Nevgi, R. Bhuvaneshwari, K. Deepak, and J. A. Sundar, “Batch normalization free rigorous feature flow neural network for grocery product recognition,” *IEEE Access*, vol. 12, pp. 68364–68381, 2024, doi: 10.1109/access.2024.3400844.
- R. Alabdian, H. Alkahtani, K. M. Othman, R. Alroobaea, S. Algarni, A. A. K. Alharbi, and K. Shankar, “Advanced imaging technologies with ensemble learning for consumer products identification and classification,” *IEEE Trans. Consum. Electron.*, vol. 70, pp. 7174–7182, 2024, doi: 10.1109/tce.2024.3393991.
- S. S. Bhat, A. Ananth, and V. P. S., “Design and evolution of deep convolutional neural networks in image classification – A review,” *Int. J. Integr. Eng.*, vol. 15, no. 1, 2023, doi: 10.30880/ijie.2023.15.01.019.
- T. Pettersson, M. Riveiro, and T. Löfström, “Multimodal fine-grained grocery product recognition using image and OCR text,” *Mach. Vis. Appl.*, vol. 35, 2024, doi: 10.1007/s00138-024-01549-9.
- Y. Baek, B. Lee, D. Han, S. Yun, and H. Lee, “Character region awareness for text detection,” in *Proc. IEEE/CVF Conf. Comput. Vis. Pattern Recognit. (CVPR)*, 2019, pp. 9365–9374, doi: 10.1109/cvpr.2019.00959.