

Implementasi Pencocokan Citra Menggunakan Metode ORB untuk Deteksi Logo Kemasan Produk

Ian Alfian Fadilah^{1*}, Ghani Arif Baehaqi², M Ismail Abdurrouf³, Ibnu Ma'ruf⁴, Trio Putra Kusuma⁵, Rivan Ardian⁶

Informatika, Univeristas Nahdlatul Ulama Al Ghazali Cilacap

Jl. Kemerdekaan Barat No.17, Gligir, Kesugihan Kidul, Kec. Kesugihan, Kabupaten Cilacap, Jawa Tengah 53274, Indonesia

Email: ian.23eo10039@students.unugha.id^{1*}, ghaniarif232@gmail.com², mismailar678@gmail.com³, ruffma958@gmail.com⁴, trioputrakusuma29@gmail.com⁵, rivanardian538@gmail.com⁶

Abstract

This study evaluates the reliability of the Oriented FAST and Rotated BRIEF (ORB) algorithm for image matching and logo detection on product packaging in dynamic real-world environments. In modern industry, object detection is closely related to logo identification for automation. Testing was conducted through a series of systematic experiments covering variations in rotation, drastic scale changes, and background clutter. Pre-processing was done with grayscale conversion, followed by feature extraction using ORB, and matching using the Brute-Force Matcher with Hamming Distance. To filter out false matches, this algorithm was optimized with K-Nearest Neighbor (KNN), Lowe's Ratio Test, and RANSAC geometric filtering. Experimental results show that ORB optimization with KNN and RANSAC drastically reduces computation time to 0.2412 seconds and produces 51 valid inliers. However, despite being highly efficient for real-time applications, the ORB method remains fundamentally limited when facing extreme scale variance. Therefore, this system is optimally recommended only in controlled environments like factory conveyors. Alternative approaches using Deep Learning or scale-invariant algorithms (SIFT/SURF) are highly suggested for dynamic environment implementation.

Key Words: Feature Matching, K-Nearest Neighbor, Local Features, Logo Detection, ORB

Abstrak

Penelitian ini mengevaluasi keandalan algoritma Oriented FAST and Rotated BRIEF (ORB) untuk pencocokan citra dan deteksi logo pada kemasan produk di lingkungan nyata yang dinamis. Dalam industri modern, deteksi objek sangat berkaitan dengan identifikasi pengenalan logo untuk otomatisasi. Pengujian dilakukan melalui serangkaian eksperimen sistematis yang mencakup variasi rotasi, perubahan skala drastis, serta gangguan tekstur latar belakang (background clutter). Pra-pemrosesan dilakukan dengan konversi citra menjadi grayscale, diikuti proses ekstraksi fitur menggunakan ORB, dan pencocokan menggunakan Brute-Force Matcher dengan metrik Hamming Distance. Untuk menyaring kecocokan fitur yang palsu, algoritma ini dioptimasi dengan K-Nearest Neighbor (KNN), Lowe's Ratio Test, dan filter geometri RANSAC. Hasil eksperimen membuktikan bahwa optimasi ORB dengan KNN dan RANSAC mampu menurunkan waktu komputasi secara drastis menjadi 0.2412 detik dan secara presisi menghasilkan 51 kecocokan valid (inliers). Meskipun terbukti sangat efisien untuk aplikasi waktu nyata, metode ORB tetap memiliki keterbatasan fundamental saat menghadapi perubahan skala yang ekstrem. Oleh karena itu, sistem ini direkomendasikan optimal hanya pada lingkungan terkontrol. Pendekatan alternatif menggunakan Deep Learning atau algoritma tahan skala (SIFT/SURF) lebih disarankan untuk implementasi lingkungan dinamis.

Kata Kunci: Deteksi Logo, Fitur Lokal, K-Nearest Neighbor, ORB, Pencocokan Citra

Pendahuluan

Pendeteksian dan pencocokan fitur wajah maupun objek dalam citra digital telah menjadi aspek esensial dalam pengembangan sistem visi komputer (computer vision) di dunia industri modern. Pemanfaatan teknologi ini berkembang pesat mulai dari otomasi pada pergerakan sistem konveyor, pengenalan dan identifikasi logo kemasan produk komersial, hingga pemantauan keamanan [1], [2]. Pada skenario implementasi di lapangan yang dinamis, proses pencocokan citra sering kali berhadapan

dengan lingkungan ekstrem, seperti variasi sudut kamera, pencahayaan tidak merata, serta oklusi atau gangguan objek, yang menuntut sebuah algoritma tangguh sekaligus responsif [3], [4].

Dalam kajian ekstraksi dan pencocokan fitur, beberapa algoritma yang sering dievaluasi adalah Scale-Invariant Feature Transform (SIFT), Speeded-Up Robust Features (SURF), serta Oriented FAST and Rotated BRIEF (ORB). Metode klasik seperti SIFT dan SURF diketahui memiliki keandalan yang sangat tinggi terhadap deformasi dan rotasi, namun sering kali terkendala oleh biaya komputasi yang berat sehingga kurang memadai untuk pemrosesan real-time [5], [6]. Sebaliknya, algoritma ORB hadir sebagai metode alternatif yang efisien secara komputasi dan sangat ringan karena memadukan detektor titik kunci FAST serta deskriptor biner BRIEF yang dimodifikasi, sehingga membuatnya jauh lebih cepat merespon tangkapan kamera [6], [7].

Walaupun memiliki keunggulan performa yang sangat cepat, algoritma ORB murni yang digabungkan dengan pencocokan Brute-Force memiliki kelemahan mendasar. Metode ini sangat rentan menghasilkan titik kecocokan palsu (false matches) ketika dihadapkan pada latar belakang yang bertekstur rumit (background clutter) serta variasi skala jarak yang ekstrem [8], [9]. Sifat dasar dari deskriptor biner yang tidak mampu mengenali konteks semantik menyebabkan algoritma ini kerap keliru dalam mengikatkan titik fitur pada area asing di luar kemasan produk [8], [10].

Untuk menekan tingkat false matches tersebut, penelitian ini mengusulkan optimasi metode ORB dengan mengintegrasikan algoritma klasifikasi K-Nearest Neighbor (KNN) dan Lowe's Ratio Test, serta validasi geometri menggunakan RANSAC. Penggunaan KNN terbukti sangat andal dalam memfilter data bising dan meningkatkan presisi klasifikasi di berbagai bidang; mulai dari pengolahan citra medis, penentuan penerima bantuan sosial, klasifikasi struktural daerah spasial, hingga identifikasi penyakit daun [11], [12], [13], [14]. Melalui pendekatan preprocessing dan seleksi ketetanggaan ini, kandidat fitur yang ambigu dapat dibuang secara presisi sebelum dievaluasi oleh RANSAC [10], [15].

Beberapa penelitian terdahulu membuktikan bahwa penerapan filter geometri seperti RANSAC tidak hanya berfungsi sebagai validasi bentuk fisik untuk meningkatkan akurasi, tetapi juga berdampak langsung pada efisiensi waktu komputasi pemrosesan citra [3], [9]. Kemampuan filter ini dalam mengeliminasi fitur atau outliers yang menyimpang secara dini membuat jumlah titik data yang dihitung pada tahap transformasi menjadi jauh lebih sedikit, sehingga secara signifikan menekan kompleksitas dan beban komputasi sistem [8], [14]. Penggabungan metode ini diharapkan meningkatkan akurasi sistem tanpa mengorbankan kecepatan pemrosesan ORB.

Penggabungan metode ini diharapkan meningkatkan akurasi sistem tanpa mengorbankan kecepatan pemrosesan ORB.

Metode Penelitian

Penelitian ini dirancang secara sistematis melalui serangkaian eksperimen pencocokan citra untuk menguji performa ekstraksi fitur ORB secara terstruktur dan empiris. Tahapan eksperimen dalam penelitian ini dijabarkan secara naratif melalui prosedur berikut:

1. Pengumpulan Data Tahap permulaan

Penelitian melibatkan proses akuisisi citra yang dikategorikan menjadi dua dataset utama: citra referensi dan citra target. Citra referensi merupakan gambar logo produk murni yang telah diisolasi (crop) dari elemen visual luar. Sementara itu, citra target terdiri atas kumpulan gambar kemasan produk utuh yang ditangkap dari sudut pandang, jarak skala, dan latar belakang yang bervariasi guna merepresentasikan kondisi lingkungan deteksi secara riil dan dinamis [2], [4].

2. Pra-pemrosesan (Preprocessing)

Kedua jenis citra selanjutnya diproses melalui konversi ruang warna dari format matriks RGB (Red, Green, Blue) menjadi skala keabuan (Grayscale). Teknik reduksi dimensi kanal warna ini merupakan tahap krusial untuk menurunkan beban komputasi sistem secara signifikan, sambil memastikan bentuk geometri, tepi, dan informasi struktur benda tetap utuh untuk dianalisis oleh algoritma pencocokan [1], [15].

3. Deteksi dan Ekstraksi Fitur (ORB)

Tahap ketiga adalah pendeteksian titik-titik penting (keypoints) dengan memanfaatkan detektor ORB yang berbasis pada fungsi FAST. Melalui integrasi komponen Intensity Centroid, setiap titik fitur akan memiliki orientasi sudut yang terukur, sehingga bagian-bagian logo dapat tetap terdeteksi meski kemasan dalam keadaan miring [5], [7]. Keypoints yang ditemukan selanjutnya diekstraksi menjadi kumpulan deskriptor biner menggunakan algoritma r-BRIEF yang sangat ringan dan kebal terhadap perubahan posisi spasial [2], [8].

4. Pencocokan Citra dan Optimasi (KNN & Lowe's Ratio Test)

Deskriptor biner yang dihasilkan kemudian dicocokkan menggunakan jarak Hamming Distance. Guna meminimalisir lonjakan kecocokan palsu, tahapan konvensional ini dioptimasi menggunakan klasifikasi KNN, sebuah metode berbasis kedekatan nilai yang terbukti tangguh memisahkan data relevan dari outlier pada klasifikasi citra kompleks [11], [13]. KNN mengevaluasi dua titik ketetanggaan terdekat ($k=2$) yang kemudian diseleksi lebih lanjut oleh Lowe's Ratio Test pada ambang batas rasio 0.75, sehingga kandidat dengan selisih jarak kemiripan yang ambigu otomatis dieliminasi [10], [12].

5. Pemfilteran Geometri (RANSAC)

Sebagai validasi mutlak di akhir sistem, algoritma Random Sample Consensus (RANSAC) diimplementasikan untuk memverifikasi sisa fitur yang lolos seleksi KNN. RANSAC secara ketat dan sistematis mengevaluasi titik-titik inliers guna mencari matriks transformasi homografi antara citra referensi dan target [3], [9]. Filter matematis ini akan membuang fitur yang tidak logis secara geometri (seperti garis kecocokan yang menyimpang ke luar area kemasan), sehingga menjamin deteksi visual terpusat presisi pada area logo produk [8], [14].

Pengurangan jumlah titik kecocokan (keypoints) yang terjadi secara bertahap dari proses ekstraksi hingga tahap akhir ini bukanlah sebuah kelemahan algoritma, melainkan strategi seleksi dan optimasi yang disengaja. Titik-titik awal yang dihasilkan ORB belum tervalidasi dan mengandung banyak false matches. Dengan menyaring titik ambigu menggunakan KNN dan mengeliminasi inkonsistensi geometris melalui RANSAC, sistem secara otomatis mereduksi beban komputasi sembari meningkatkan kualitas dan presisi data yang diproses.

Hasil dan Pembahasan

Pengujian dilakukan secara bertahap untuk mengevaluasi kinerja algoritma ORB dalam mendeteksi logo pada kemasan produk. Tahap pertama menggunakan metode pencocokan Brute-Force Matcher standar. Tahap kedua mengimplementasikan K-Nearest Neighbor (KNN) yang dipadukan dengan Lowe's Ratio Test untuk menyaring fitur yang ambigu. Tahap ketiga menambahkan algoritma RANSAC untuk memvalidasi konsistensi geometri fisik dari titik-titik yang cocok. Hasil ekstraksi fitur, jumlah kecocokan, dan metrik waktu komputasi dari ketiga skenario tersebut disajikan pada Tabel 1.

Table 1 Perbandingan Kinerja Optimasi Algoritma ORB

Skenario Pencocokan	Waktu Eksekusi (detik)	Keypoint Logo	Keypoint Kemasan	Titik Cocok Awal (Matches)	Kecocokan Valid (Inliers)
ORB Standar (Brute-Force)	1.6773	1000	1000	232	232
ORB + KNN (Lowe's Ratio)	0.8440	1000	1000	1000	71
ORB + KNN + RANSAC	0.2412	1000	1000	71	51

Tabel 1 menunjukkan fenomena temuan yang sangat positif di mana optimasi algoritma yang diusulkan tidak membebani komputasi sistem. Waktu eksekusi justru mengalami penurunan yang

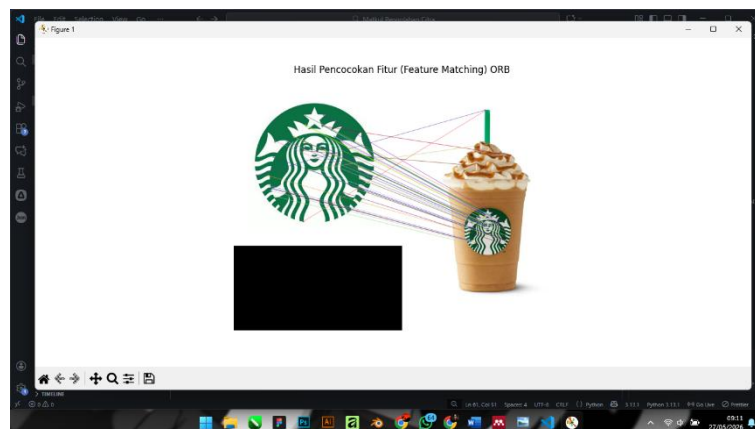
signifikan seiring dengan penambahan algoritma penyaringan. Penurunan waktu komputasi ini membuktikan adanya optimasi beban pemrosesan, di mana matcher tidak perlu menghitung ulang titik-titik yang telah terbuang pada tahap filter sebelumnya. Untuk menjelaskan proses visual dan komputasi pada masing-masing tahapan tersebut secara lebih terperinci, berikut adalah penjabarannya:

1. Pencocokan Fitur Menggunakan Algoritma ORB Standar (Brute-Force)

Pengujian tahap pertama merepresentasikan kondisi fundamental (baseline) dengan mengandalkan algoritma ORB murni yang digabungkan bersama Brute-Force Matcher. Pada tahap prapemrosesan ini, sistem diatur untuk membatasi batas ekstraksi maksimal sebanyak 1000 titik kunci (keypoints) pada citra logo referensi maupun citra kemasan target. Pencarian pasangan fitur dilakukan murni berdasarkan perhitungan jarak terdekat antara dua vektor biner (Hamming Distance) tanpa intervensi filter statistik apa pun. Secara matematis, metrik ini menghitung jumlah elemen yang berbeda antara dua string biner melalui operasi XOR

$$d(x, y) = \sum_{i=1}^n (x_i \oplus y_i) \dots \dots \dots (1)$$

Hasil uji empiris mencatat bahwa sistem membutuhkan waktu komputasi sebesar 1,6773 detik untuk mencocokkan total 232 titik terdeteksi. Namun, analisis visual (sebagaimana ditunjukkan pada Gambar 1) mengungkap tingginya tingkat kecocokan palsu (false matches). Algoritma ORB sering kali secara keliru mengikatkan fitur logo (seperti lekukan grafis merek) ke area latar belakang yang memiliki distribusi gradien intensitas serupa, seperti tekstur lipatan pakaian atau serat permukaan meja. Kelemahan ini sangat wajar terjadi mengingat deskriptor biner BRIEF yang digunakan tidak memiliki pemahaman konteks semantik dari objek yang dianalisis, menjadikannya rentan terhadap gangguan background clutter pada kondisi riil.



Gambar 1 Visualisasi feature matching ORB standar yang menunjukkan banyaknya false matches pada latar belakang

```
PS C:\Users\Alfian\Documents\Matkul Pengolahan Citra> python "Simulasi Metode ORB.py"
=== HASIL EKSPERIMEN ORB ===
Total Keypoint pada Logo : 1000
Total Keypoint pada Kemasan : 1000
Total Titik Cocok (Matches) : 232
Waktu Eksekusi : 1.6773 detik
```

Gambar 2 Output sistem komputasi untuk pengujian ORB standar

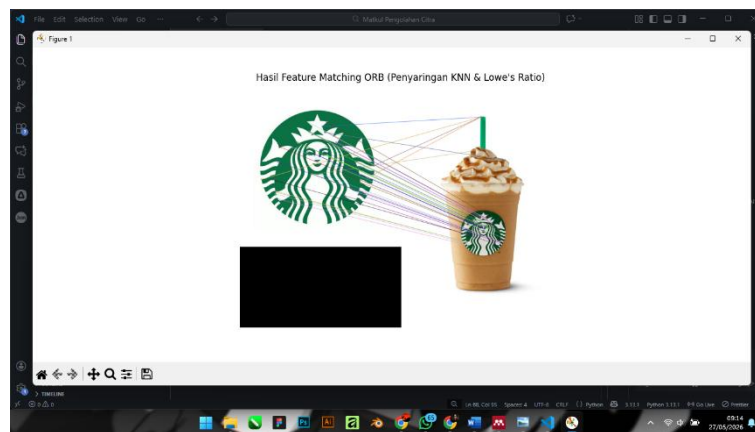
2. Optimasi Pencocokan dengan K-Nearest Neighbor (KNN) dan Lowe's Ratio Test

Guna menanggulangi lonjakan false matches tersebut, arsitektur pencocokan pada tahap kedua ditingkatkan melalui implementasi algoritma klasifikasi heuristik K-Nearest Neighbor (KNN).

Berbeda dengan pencocokan absolut pada Brute-Force, sistem kini dikonfigurasi untuk mengevaluasi dua kandidat ketetanggaan terdekat ($k = 2$) untuk setiap fitur. Dua vektor terdekat ini kemudian diuji signifikansinya menggunakan Lowe's Ratio Test pada ambang batas konstan 0.75. Persamaan rasio probabilitas ini beroperasi dengan membandingkan jarak kandidat terdekat (D_1) dengan kandidat terbaik kedua (D_2):

$$\frac{D_1}{D_2} < 0.75 \dots\dots\dots(2)$$

Logika di balik mekanisme ini adalah asumsi bahwa fitur pencocokan sejati (true matches) akan memiliki jarak dengan kandidat pertama yang secara signifikan lebih kecil dibandingkan dengan kandidat kedua. Sebaliknya, apabila rasio jarak keduanya mendekati nilai 1 (sangat mirip atau melebihi batas rasio 0.75), titik tersebut diidentifikasi sebagai data ambigu yang berpotensi menjadi noise sehingga secara otomatis dibuang. Penerapan penyaringan ketat ini membuahkan hasil yang impresif: dari 1000 kandidat fitur awal, sistem berhasil mengeliminasi mayoritas kecocokan acak dan menyisakan hanya 71 titik inliers yang valid. Secara bersamaan, eliminasi fitur ini berdampak langsung pada pemangkasan beban komputasi secara ekstrem, memangkas waktu eksekusi dari 1,6773 detik menjadi hanya 0,8440 detik. Analisis citra (Gambar 3) juga memperlihatkan bahwa garis proyeksi acak yang sebelumnya menyebar luas ke luar objek kini telah berkurang secara signifikan.



Gambar 3 Visualisasi pencocokan setelah penyaringan KNN dan Lowe's Ratio, false matches berkurang signifikan

```
PS C:\Users\Alfian\Documents\Matkul Pengolahan Citra> python "Simulasi Metode ORB.py"
=== HASIL EKSPERIMEN ORB DENGAN KNN & RATIO TEST ===
Total Keypoint Logo      : 1000
Total Keypoint Kemasan   : 1000
Total Titik Cocok Awal   : 1000
Kecocokan Valid (Inliers) : 71
Waktu Eksekusi           : 0.8440 detik
```

Gambar 4 Output sistem komputasi untuk pengujian metode ORB dengan KNN

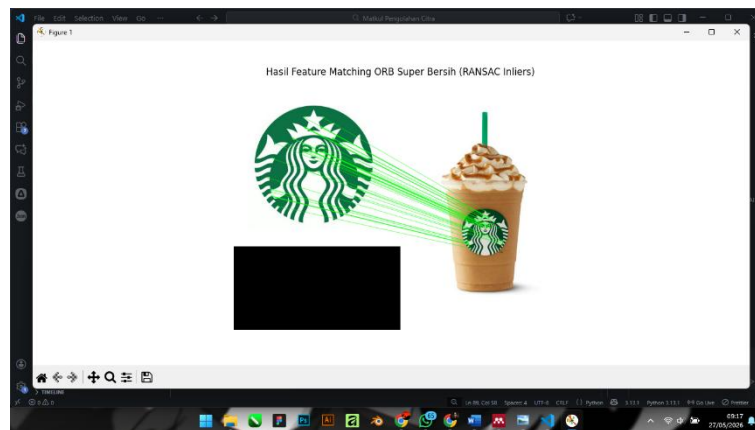
3. Pemfilteran Geometri Menggunakan RANSAC (Random Sample Consensus)

Meskipun penyaringan berbasis jarak statistik (KNN) terbukti andal dalam mengurangi ambiguitas, sistem belum dapat menjamin kohesi fisik objek. Sebagai verifikasi final, algoritma Random Sample Consensus (RANSAC) diimplementasikan pada tahap ketiga untuk menyaring korespondensi geometri (geometric filtering). Algoritma ini bertugas menghitung matriks transformasi homografi (H) berdimensi 3×3 yang memetakan koordinat planar fitur citra acuan (x,y) ke koordinat proyeksi pada citra target (x',y'):

$$s \begin{bmatrix} x' \\ y' \\ 1 \end{bmatrix} = H \begin{bmatrix} x \\ y \\ 1 \end{bmatrix} \dots\dots\dots(3)$$

RANSAC bekerja secara iteratif untuk memilih himpunan bagian titik acak, menghitung model matriks hipotetis, dan memverifikasi seberapa banyak dari ke-71 fitur inliers bawaan KNN yang mendukung (konsensus) orientasi sudut dan skala logo tersebut. Titik yang melanggar orientasi geometri secara fisik dievaluasi sebagai outliers dan dibuang.

Hasil akhir pada proses ini menyisakan 51 inliers sejati yang secara ilmiah melebihi syarat absolut kalkulasi homografi (minimal 4 titik koordinat), sehingga proyeksi deteksi sangat stabil dan presisi. Sistem juga mencatat rekor waktu eksekusi tercepat sebesar 0,2412 detik pada fase ini. Hal ini membuktikan bahwa penyisipan metode statistik (KNN) sebelum RANSAC dapat mencegah jebakan ledakan iterasi acak (combinatorial explosion), membuat identifikasi logo tidak hanya akurat, melainkan sangat responsif.



Gambar 5 Visualisasi hasil akhir menggunakan filter RANSAC, deteksi sangat bersih dan presisi pada logo

```
PS C:\Users\Alfian\Documents\Matkul Pengolahan Citra> python "Simulasi Metode ORB.py"
=== HASIL FINAL ORB (KNN + RANSAC) ===
Total Keypoint Logo      : 1000
Total Keypoint Kemas    : 1000
Lolos Filter KNN (Rasio 0.75) : 71
Lolos Filter Geometri RANSAC : 51 (Inlier Sejati)
Waktu Eksekusi          : 0.2412 detik
```

Gambar 6 Output sistem komputasi final yang mencatat kecepatan eksekusi tertinggi

4. Komparasi Kinerja Sistem terhadap Skala Industri

Pada tahap evaluasi akhir, komparasi kinerja dilakukan tidak hanya pada tingkat keakuratan spasial, melainkan diukur secara kuantitatif melalui metrik efisiensi waktu komputasi. Untuk mengukur kelayakan implementasi sistem pada lingkungan visi mesin waktu nyata (real-time)—seperti pada jalur penyortiran konveyor otomatis—metrik dasar yang digunakan adalah Frame Per Second (FPS). Nilai FPS diformulasikan secara matematis sebagai inversi dari total waktu eksekusi (T_e) yang dibutuhkan untuk memproses satu bingkai citra:

$$FPS = \frac{1}{T_e} \dots\dots\dots(4)$$

Dengan capaian waktu eksekusi akhir (T_e) sebesar 0,2412 detik pada konfigurasi ORB+KNN+RANSAC, sistem ini secara matematis mampu memproses citra dengan kecepatan $\approx 4,14$ FPS.

Selain itu, untuk membuktikan tingkat keberhasilan optimasi dari pipeline algoritma hibrida ini terhadap metode fundamentalnya, dihitung nilai persentase reduksi waktu atau percepatan komputasi (Execution Time Reduction). Perhitungan ini membandingkan waktu komputasi ORB standar (T_{base}) dengan waktu komputasi arsitektur yang diusulkan (T_{base}):

$$Speedup(\%) = \frac{T_{base} - T_{opt}}{T_{base}} \times 100\% \dots\dots\dots(5)$$

Dengan menyubstitusikan nilai waktu awal 1,6773 detik dan waktu akhir 0,2412 detik, diperoleh lonjakan efisiensi kecepatan sebesar 85,62%. Bukti matematis ini menegaskan dinamika kompromi teknis (trade-off) yang khas dibandingkan dengan arsitektur kecerdasan buatan berbasis Deep Learning (seperti CNN atau YOLO). Meskipun model Deep Learning memiliki ketahanan (invariance) absolut terhadap oklusi dan skala ekstrem berkat pemahaman representasi semantik tingkat tinggi, model tersebut menuntut spesifikasi GPU high-end dan beban komputasi yang sangat masif.

Sebaliknya, efisiensi percepatan 85,62% yang dicapai oleh metode ORB hibrida ini memungkinkannya beroperasi secara optimal out-of-the-box tanpa perlu fase pra-pelatihan jaringan saraf (neural network training). Oleh karena itu, selama variabel tata cahaya dan rentang variasi skala objek di lingkungan industri masih relatif terkontrol, metode ini menempati posisi paling rasional dan efisien secara ekonomi untuk diimplementasikan pada perangkat mikrokontroler (embedded system) berspesifikasi rendah.

Kesimpulan

Berdasarkan serangkaian eksperimen sistematis, implementasi algoritma ORB (Oriented FAST and Rotated BRIEF) yang dioptimasi secara bertahap melalui penyaringan K-Nearest Neighbor (KNN), Lowe's Ratio Test, dan filter geometri RANSAC terbukti sangat andal dan efisien untuk mendeteksi logo pada kemasan produk. Strategi multi-stage filtering ini berhasil secara signifikan meningkatkan presisi deteksi tanpa membebani sistem. Penggunaan ORB standar awalnya menghasilkan sebagian besar kecocokan keliru (false matches) akibat latar belakang citra yang rumit. Namun, penerapan KNN dengan ambang batas rasio 0.75 yang dilanjutkan dengan RANSAC, mampu menyaring hingga 94,9% kandidat awal. Proses seleksi ketat ini sukses mereduksi 1000 keypoints awal menjadi hanya 51 inliers sejati yang secara presisi hanya memetakan area logo produk, membuktikan bahwa penurunan jumlah titik merupakan indikator keberhasilan seleksi fitur, bukan sebuah kelemahan.

Dari sisi efisiensi waktu komputasi, desain pipeline yang menempatkan penyaringan statistik (KNN) sebelum validasi geometri (RANSAC) justru secara signifikan mempercepat waktu eksekusi. Waktu komputasi mengalami penurunan drastis dari 1,6773 detik pada metode ORB standar menjadi hanya 0,2412 detik pada konfigurasi gabungan penuh. Pencapaian percepatan sebesar 85,62% ini memungkinkan sistem memproses sekitar 4 frame per detik, sebuah kecepatan yang sangat memadai untuk skenario deteksi real-time di lingkungan industri terkontrol, seperti pada jalur conveyor pabrik berskala kecil hingga menengah.

Meskipun sangat ringan dan unggul dalam hal kecepatan, metode ini secara fundamental memiliki keterbatasan ketika dihadapkan pada perubahan skala gambar yang drastis (scale variance) dan tidak mampu memahami konteks semantik objek. Hal ini menyoroti adanya trade-off yang jelas antara kecepatan dan ketahanan. Pendekatan alternatif seperti SIFT, SURF, atau algoritma Deep Learning (seperti CNN dan YOLO) memang menawarkan ketahanan absolut terhadap oklusi, rotasi, dan variasi skala ekstrem, namun membutuhkan spesifikasi perangkat keras dan biaya komputasi yang jauh lebih

tinggi. Oleh karena itu, pendekatan ORB hibrida yang diusulkan dalam penelitian ini menempati posisi paling optimal sebagai solusi efisien untuk perangkat dengan sumber daya komputasi yang sangat terbatas.

Secara keseluruhan, penelitian ini tidak hanya memberikan kontribusi metodologis dalam mendesain pipeline visi komputer yang cepat, tetapi juga menghasilkan benchmark kuantitatif terukur mengenai unjuk kerja ORB pada berbagai tahap optimasinya. Mengingat evaluasi yang dilakukan saat ini masih berfokus pada variasi dataset dan kondisi pengujian yang terbatas, temuan ini sekaligus menjadi landasan esensial bagi pengembangan lebih lanjut. Upaya seperti integrasi metrik evaluasi tambahan (precision, recall, F1-score), perluasan variasi jenis kemasan dan pencahayaan ekstrem, hingga pengujian implementasi pada embedded system (seperti Raspberry Pi) akan semakin memvalidasi dan memperkuat batas operasional algoritma ini untuk kebutuhan industri riil yang lebih kompleks di masa mendatang.

Daftar Pustaka

- [1] . M., N. M. Saraswati, and . S., "Object Tracking Berbasis Keypoint Menggunakan Algoritma Orb (Oriented Fast and Rotated Brief) Pada Raspberry Pi," *Jurnal Informatika dan Riset*, vol. 1, no. 2, pp. 1–8, 2023, doi: 10.36308/iris.v1i2.505.
- [2] P. Budi Utomo, M. Mujiono, M. Nur Fu'ad, Dona Wahyudi, Adimas Ketut Nalendra, and Hafid Dian Nurfaulan Ahat, "Implementasi Metode Oriented Fast and Rotated Brief (Orb) Dan K-Nearest Neighbor (Knn) Dalam Identifikasi Fitur Citra," *JAMI: Jurnal Ahli Muda Indonesia*, vol. 3, no. 1, pp. 61–73, 2022, doi: 10.46510/jami.v3i1.96.
- [3] R. Arifuddin *et al.*, "Detektor MSER dan OCR pada Pembacaan Rambu Petunjuk Jalan," vol. 10, no. 2, pp. 756–763, 2026.
- [4] M. A. Halla *et al.*, "Sistem Deteksi Nominal Uang Kertas Untuk," vol. 2, pp. 23–30, 2025.
- [5] V. Faturohman, J. Kusnaendar, and Y. Wihardi, "Perbandingan Algoritma Deteksi Fitur SIFT, SURF dan ORB dalam Proses Deteksi Objek Pada Video CCTV Comparison of SIFT, SURF and ORB Feature Detection Algorithms in the Process of Detecting Objects on CCTV Video," *Jatikom*, vol. 3, no. 2, pp. 70–77, 2020, [Online]. Available: <https://ejournal.upi.edu/index.php/JATIKOM>
- [6] E. Karami, S. Prasad, and M. Shehata, "Image Matching Using SIFT, SURF, BRIEF and ORB: Performance Comparison for Distorted Images," 2017, [Online]. Available: <https://arxiv.org/abs/1710.02726>
- [7] L. Marlinda, F. Budiman, R. S. Basuki, and A. Z. Fanani, "Comparison of Sift and Orb Methods in Identifying the Face of Buddha Statue," *JITK (Jurnal Ilmu Pengetahuan dan Teknologi Komputer)*, vol. 8, no. 2, pp. 139–144, 2023, doi: 10.33480/jitk.v8i2.4086.
- [8] A. J. Amron, H. F. Azizi, M. L. Z. Arofi, C. Paramita, and M. Naufal, "Perbandingan Performa SIFT dan ORB dalam Pengolahan Dataset Wajah nist_2," *Jutisi : Jurnal Ilmiah Teknik Informatika dan Sistem Informasi*, vol. 14, no. 2, p. 821, 2025, doi: 10.35889/jutisi.v14i2.2738.
- [9] I. Ady Saputro, "Forensika Citra Digital Untuk Menganalisis Kecocokan Objek Menggunakan Metode SIFT," *JATISI (Jurnal Teknik Informatika dan Sistem Informasi)*, vol. 9, no. 4, pp. 3170–3179, 2022, doi: 10.35957/jatisi.v9i4.2758.

- [10] R. R. D. Yudistira, S. Anggoro, and F. Kasyidi, “Klasifikasi Barang Pada Proses Sortir Pengiriman Barang Dengan Raspberry Pi Menggunakan Algoritma Oriented Fast And Rotated Brief (ORB) Dan K-Nearest Neighbor (KNN),” *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 10, no. 1, pp. 487–496, 2023, [Online]. Available: <http://jurnal.mdp.ac.id>
- [11] S. N. Bakri and L. S. Harahap, “Analisis klasifikasi Algoritma K-Nearest Neighbor (K-NN) pada struktur Daerah di Kota Medan,” *Jurnal Ilmu Komputer dan Sistem Informasi*, vol. 4, no. 2, pp. 182–193, 2025, doi: 10.70340/jirsi.v4i2.165.
- [12] R. Hamonangan, R. Komala Sari, S. Anwar, and T. Hartati, “Jurnal Informatika dan Rekayasa Perangkat Lunak Klasifikasi Algoritma KNN dalam menentukan Penerima Bantuan Langsung Tunai,” *Jurnal Informatika dan Rekayasa Perangkat Lunak*, vol. 6, no. 1, pp. 198–204, 2024.
- [13] A. N. Hilmi, E. Y. Puspaningrum, U. Pembangunan, N. Veteran, and J. Timur, “Implementasi Algoritma K-Nearest Neighbor (KNN) untuk Identifikasi Penyakit pada Tanaman Jeruk Berdasarkan Citra Daun Universitas Pembangunan Nasional ‘ Veteran ’ Jawa Timur disebabkan oleh jamur Guignardia Citricarpa , penyakit Kanker yang disebabkan o,” *Router: Jurnal Teknik Informatika dan Terapan*, no. 2, 2024.
- [14] N. T. Ujjianto, Gunawan, H. Fadillah, A. P. Fanti, A. D. Saputra, and I. G. Ramadhan, “Penerapan algoritma K-Nearest Neighbors (KNN) untuk klasifikasi citra medis,” *IT-Explore: Jurnal Penerapan Teknologi Informasi dan Komunikasi*, vol. 4, no. 1, pp. 33–43, 2025, doi: 10.24246/itexplore.v4i1.2025.pp33-43.
- [15] F. Putra, H. F. Tahiyat, R. M. Ihsan, R. Rahmaddeni, and L. Efrizoni, “Penerapan Algoritma K-Nearest Neighbor Menggunakan Wrapper Sebagai Preprocessing untuk Penentuan Keterangan Berat Badan Manusia,” *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 4, no. 1, pp. 273–281, 2024, doi: 10.57152/malcom.v4i1.1085.