

Analisis Trade-Off Akurasi dan Efisiensi Algoritma Feature Matching Citra Rambu Lalu Lintas Beresolusi Rendah

Malfino Wildan Akhya¹, Burhanuddin Dhika², Albireo Musyaffa Finoo³, Muhammad Naufal^{4,*}, Ricardus Anggi Pramunendar⁵

Fakultas Ilmu Komputer, Program Studi Teknik Informatika, Universitas Dian Nuswantoro, Semarang, Indonesia
Email: ¹11202214688@mhs.dinus.ac.id, ²11202214679@mhs.dinus.ac.id, ³11202315418@mhs.dinus.ac.id, ^{4,*}m.naufal@dsn.dinus.ac.id, ⁵ricardus.anggi@dsn.dinus.ac.id
Email Penulis Korespondensi: m.naufal@dsn.dinus.ac.id

Abstrak—Permasalahan deteksi dan pencocokan fitur visual menjadi semakin penting dalam perkembangan Sistem Transportasi Cerdas (ITS), khususnya pada sistem bantuan pengemudi dan pengenalan rambu lalu lintas, yang dipengaruhi oleh variasi pencahayaan, rotasi, dan skala citra. Penelitian ini membandingkan performa tiga algoritma feature matching, yaitu Scale Invariant Feature Transform (SIFT), KAZE, dan Oriented FAST and Rotated BRIEF (ORB), menggunakan 52 pasangan citra rambu lalu lintas representatif yang dipilih dari setiap kelas dataset. Proses evaluasi dilakukan menggunakan pipeline pra-pemrosesan minimalis untuk mengamati karakteristik dasar masing-masing algoritma. Kinerja algoritma dievaluasi berdasarkan rasio inlier sebagai indikator akurasi pencocokan, total waktu eksekusi sebagai indikator efisiensi komputasi, serta rasio selisih keypoint untuk mengukur konsistensi jumlah fitur yang terdeteksi antar pasangan citra. Hasil eksperimen menunjukkan bahwa ORB memberikan trade-off terbaik antara akurasi dan efisiensi dengan waktu eksekusi tercepat sebesar 0.0056 detik dan rasio inlier tertinggi sebesar 0.6575. Sementara itu, KAZE menunjukkan konsistensi deteksi fitur yang lebih baik berdasarkan rasio selisih keypoint yang lebih rendah dibandingkan algoritma lainnya, meskipun membutuhkan waktu komputasi lebih tinggi. Temuan ini menunjukkan bahwa ORB lebih sesuai untuk implementasi real-time dengan keterbatasan komputasi, sedangkan KAZE berpotensi digunakan pada skenario yang membutuhkan stabilitas fitur lebih tinggi. Namun, penelitian ini masih terbatas pada jumlah pasangan citra yang relatif kecil dan belum mencakup evaluasi pada kondisi lingkungan yang lebih kompleks.

Kata Kunci: Pencocokan Fitur; Rambu Lalu Lintas; SIFT; KAZE; ORB

Abstract—The problem of visual feature detection and matching is becoming increasingly important in the development of Intelligent Transportation Systems (ITS), especially in driver assistance systems and traffic sign recognition, which are affected by variations in lighting, rotation and image scale. This research compares the performance of three feature matching algorithms, namely Scale Invariant Feature Transform (SIFT), KAZE, and Oriented FAST and Rotated BRIEF (ORB), using 52 representative traffic sign image pairs selected from each dataset class. The evaluation process is carried out using a minimalist pre-processing pipeline to observe the basic characteristics of each algorithm. The performance of the algorithm is evaluated based on the inlier ratio as an indicator of matching accuracy, total execution time as an indicator of computational efficiency, and the keypoint difference ratio to measure the consistency of the number of features detected between image pairs. Experimental results show that ORB provides the best trade-off between accuracy and efficiency with the fastest execution time of 0.0056 seconds and the highest inlier ratio of 0.6575. Meanwhile, KAZE shows better feature detection consistency based on a lower keypoint difference ratio compared to other algorithms, even though it requires higher computing time. These findings suggest that ORB is more suitable for real-time implementations with computational limitations, while KAZE can potentially be used in scenarios that require higher feature stability. However, this research is still limited to a relatively small number of image pairs and does not include evaluations in more complex environmental conditions.

Keywords: Feature Matching; Traffic Signs; SIFT; KAZE; ORB

1. PENDAHULUAN

Pendeteksian dan pencocokan fitur visual dalam citra digital merupakan aspek fundamental dalam pengembangan Sistem Transportasi Cerdas (ITS), khususnya pada kendaraan otonom dan Sistem Bantuan Pengemudi Tingkat Lanjut (ADAS) [1], [2]. Keandalan algoritma deteksi fitur sangat krusial dalam sistem ini untuk fungsi pengenalan rambu lalu lintas dari citra kamera [3]. Keandalan ini menjadi kunci dalam menjawab tantangan lingkungan nyata, seperti perubahan pencahayaan ekstrem, orientasi rambu yang bervariasi, serta perbedaan skala citra akibat jarak pandang [4]. Perkembangan teknologi *vision-based recognition* dan kebutuhan akan sistem navigasi yang cepat menjadikan penelitian pada bidang ini semakin penting [5].

Namun demikian, pencocokan fitur pada citra rambu lalu lintas menghadapi sejumlah tantangan yang signifikan, antara lain variasi bentuk dan warna antar rambu, perubahan pencahayaan dan cuaca, serta rotasi dan skala gambar [6]. Penerapan algoritma pendeteksi fitur lokal klasik seperti *Scale-Invariant Feature Transform* (SIFT) dan *Oriented FAST and Rotated BRIEF* (ORB), masih menghadapi keterbatasan performa yang signifikan dalam kondisi pencitraan rambu lalu lintas yang dinamis [7]. Berdasarkan studi-studi terdahulu, akurasi deteksi algoritma berbasis float descriptor seperti SIFT dapat menurun drastis pada resolusi rendah [8], sementara algoritma *binary descriptor* seperti ORB, meskipun unggul dalam kecepatan, sering menunjukkan penurunan rasio pencocokan pada perubahan rotasi sudut tajam [9]. Penurunan performa ini berdampak langsung terhadap meningkatnya *false reject rate* pada sistem *real time* kendaraan, yang dapat menghambat keputusan navigasi yang tepat [10]. Oleh karena itu, diperlukan perbandingan komprehensif untuk mengidentifikasi algoritma yang mampu menawarkan *trade-off* terbaik antara akurasi dan efisiensi komputasi, terutama pada perangkat terbatas sumber daya [11].

Sebagai solusi terhadap tantangan tersebut, penelitian ini mengusulkan studi komparatif mendalam yang melibatkan tiga algoritma fitur kunci: SIFT, ORB, dan KAZE [12]. Pemilihan KAZE di sini bertujuan untuk menguji apakah keunggulan teknisnya dalam mempertahankan detail tepi yang krusial pada rambu lalu lintas dapat memberikan stabilitas deteksi fitur yang superior [13]. Selain itu, perbandingan antara SIFT, KAZE, dan ORB akan mengevaluasi *trade-off* antara *float descriptor invarian* skala, *float descriptor* non-linear, dan *binary descriptor* cepat [14]. Strategi ini berangkat dari kebutuhan akan sistem pengenalan rambu yang tidak hanya akurat, namun juga responsif dan memiliki ketahanan fitur yang konsisten pada kondisi lingkungan yang menantang [15].


Meskipun pendekatan berbasis Deep Learning saat ini mendominasi berbagai tugas computer vision pada Intelligent Transportation Systems (ITS), algoritma feature matching klasik seperti SIFT, ORB, dan KAZE masih relevan untuk diteliti, terutama pada perangkat dengan keterbatasan sumber daya komputasi, memori, dan konsumsi daya. Algoritma klasik memiliki keunggulan berupa kompleksitas model yang lebih ringan, tidak memerlukan proses pelatihan dataset berskala besar, serta lebih mudah diimplementasikan pada sistem embedded dan aplikasi real-time dengan latency rendah. Selain itu, evaluasi terhadap algoritma klasik masih penting sebagai baseline untuk memahami *trade-off* antara akurasi, stabilitas fitur, dan efisiensi komputasi sebelum menerapkan pendekatan deep learning yang lebih kompleks. Pada beberapa skenario ITS berbasis edge computing, penggunaan metode klasik masih dipertimbangkan karena mampu memberikan waktu inferensi yang lebih cepat dan kebutuhan perangkat keras yang lebih rendah dibandingkan model deep learning modern. Tujuan dari penelitian ini adalah mengidentifikasi dan membandingkan performa tiga algoritma *feature matching* (SIFT, KAZE, dan ORB) berdasarkan parameter objektif seperti jumlah *keypoint*, rasio inlier, dan waktu eksekusi, menganalisis *trade-off* antara akurasi dan efisiensi di antara ketiga algoritma tersebut terhadap dataset serta menentukan algoritma paling optimal yang dapat memberikan rekomendasi praktis untuk diterapkan pada sistem pengenalan rambu otomatis [14]. Penelitian ini diharapkan dapat memberikan kontribusi terhadap pengembangan algoritma deteksi fitur untuk ITS yang tangguh dan efisien, sekaligus menawarkan panduan praktis bagi pengembang sistem ADAS dalam memilih algoritma yang sesuai dengan kebutuhan spesifik [16]. Penelitian ini dibatasi pada penggunaan citra resolusi rendah 128×128 piksel dengan jumlah pasangan citra pengujian yang terbatas serta tanpa penerapan teknik image enhancement atau preprocessing lanjutan. Selain itu, pengujian belum mencakup kondisi lingkungan nyata seperti blur, noise, dan variasi cuaca ekstrem yang mana dapat berpengaruh terhadap hasil [17].

2. METODOLOGI PENELITIAN

Metodologi penelitian berperan sebagai pedoman sistematis dalam pelaksanaan studi, memastikan setiap tahapan penelitian berjalan terarah dan selaras dengan tujuan yang ingin dicapai. Secara garis besar, penelitian ini diawali dengan pengumpulan set data rambu lalu lintas sebanyak 208 pasangan citra (*image pairs*). Data citra kemudian menjalani tahap Pra-pemrosesan minimalis sebelum masuk ke proses perbandingan. Selanjutnya, tiga algoritma *feature matching* (SIFT, KAZE, dan ORB) diterapkan untuk ekstraksi fitur, diikuti dengan pencocokan fitur menggunakan *Brute-Force Matcher* dan validasi geometris dengan metode RANSAC untuk menghitung rasio inlier (akurasi). Tahap akhir meliputi evaluasi performa algoritma berdasarkan tiga metrik objektif (akurasi, efisiensi, dan stabilitas), serta analisis *trade-off* untuk menentukan algoritma optimal.

Implementasi dan pemrosesan data keseluruhan dilakukan menggunakan bahasa pemrograman *python*, didukung oleh pustaka *computer vision OpenCV* (untuk ekstraksi fitur dan validasi geometris). Seluruh eksperimen komputasi dilaksanakan pada perangkat keras dengan spesifikasi: Laptop ACER SWIFT 3 SF314-512-56YV yang ditenagai oleh prosesor INTEL EVO i5-1240P dan RAM 16GB, untuk menjamin presisi pengukuran waktu eksekusi mili detik yang akurat sesuai dengan kebutuhan studi komparatif *real-time*.

Metodologi penelitian ini dirancang untuk mengevaluasi *trade-off* antara akurasi, efisiensi komputasi, dan stabilitas feature matching pada citra rambu lalu lintas. Seluruh citra menggunakan resolusi 128×128 piksel untuk mensimulasikan skenario komputasi ringan pada sistem embedded dan real-time ITS. Pembentukan pasangan citra dilakukan dengan mempertimbangkan variasi kondisi visual seperti rotasi, pencahayaan, dan skala objek. Tahap pra-pemrosesan minimalis diterapkan secara sengaja untuk meminimalkan pengaruh manipulasi citra tambahan sehingga performa yang diperoleh lebih merepresentasikan karakteristik dasar masing-masing algoritma feature matching.



Gambar 1. Alur Penelitian

2.1 Pengumpulan Dataset

Penelitian ini menggunakan pendekatan kuantitatif komparatif yang didasarkan pada Traffic Sign Dataset yang bersumber dari platform *kaggle* [18], dipilih karena mengandung citra-citra rambu lalu lintas dengan beragam variasi kondisi. *Dataset* ini, yang mencakup total ±3.900 citra, terbagi ke dalam 58 kelas rambu lalu lintas yang berbeda, menjadikannya representatif untuk skenario pengenalan rambu pada sistem transportasi cerdas di dunia nyata. Secara struktural, setiap folder utama mewakili satu jenis rambu lalu lintas, dengan setiap kelas memiliki 70-100 citra yang menampilkan variasi posisi, orientasi, dan pencahayaan. Karakteristik citra yang beragam, termasuk format RGB dan resolusi yang variatif (50

$\times 50$ hingga 128×128 piksel), sangat ideal untuk menguji ketahanan (*robustness*) algoritma terhadap tantangan lingkungan nyata.

Seluruh citra dalam *dataset* telah melalui proses kurasi awal untuk memastikan kesesuaian format dan kualitas visual. Untuk kebutuhan eksperimen, citra digunakan secara keseluruhan sebagai sumber untuk membuat set pengujian pasangan citra (*testing image pairs*). Proses pembentukan pasangan dilakukan dengan membuat maksimal 5 pasangan citra secara acak dari setiap kelas rambu. Setiap pasangan citra bertujuan untuk mengukur tingkat kemiripan fitur antar dua gambar dalam kelas yang sama (rambu yang identik) yang memiliki variasi kondisi (seperti perbedaan skala, rotasi, atau pencahayaan). Proses ini menghasilkan total 52 pasangan citra uji yang digunakan secara seragam oleh algoritma SIFT, KAZE, dan ORB untuk evaluasi kinerja

2.2 Pra-pemrosesan Data

Tahap pra-pemrosesan data bertujuan untuk mempersiapkan citra agar berada dalam kondisi optimal, seragam, dan efisien untuk tahap ekstraksi fitur oleh algoritma SIFT, KAZE, dan ORB. Penelitian ini menggunakan *base pipeline* yang menekankan pada pra-pemrosesan minimalis untuk mendapatkan kinerja murni dari algoritma fitur tanpa modifikasi kontras ekstensif. Tahapan pra-pemrosesan dilaksanakan secara berurutan sebagai berikut:

a. Konversi ke Grayscale

Citra RGB terlebih dahulu dikonversi ke dalam format *grayscale* menggunakan fungsi pembacaan citra yang sesuai. Konversi ini bertujuan untuk mereduksi kompleksitas komputasi dengan menghilangkan kanal warna, sambil tetap mempertahankan informasi struktur dan tekstur gambar yang krusial untuk deteksi fitur.

b. Normalisasi Ukuran (Resizing)

Citra kemudian diubah secara seragam menjadi ukuran 128×128 piksel menggunakan interpolasi area. Normalisasi ukuran ini bertujuan untuk menjamin konsistensi pemrosesan dan efisiensi waktu komputasi untuk semua algoritma.

a. Normalisasi Intensitas

Setelah *resize*, citra menjalani normalisasi intensitas dengan rentang 0-255. Proses ini esensial untuk menyeimbangkan intensitas global dan mereduksi bias pencahayaan antar citra.

2.3 Ekstraksi Fitur

Ekstraksi fitur adalah tahap di mana *keypoint* dan *descriptor* unik dihitung dari citra yang telah dipra-proses, dan penelitian ini menguji tiga algoritma utama yang merepresentasikan kategori *descriptor* yang berbeda. Ekstraksi fitur dilakukan menggunakan tiga pendekatan utama sebagai berikut:

a. Scale-Invariant Feature Transform (SIFT)

SIFT merupakan algoritma *float descriptor* berdimensi 128 yang didasarkan pada deteksi *keypoint* melalui Difference of Gaussians (DoG). Algoritma ini secara spesifik dirancang untuk mendeteksi titik kunci yang kuat (*robust*) dan menghasilkan *descriptor* yang bersifat invarian terhadap rotasi, skala, dan perubahan pencahayaan [14]. SIFT berfungsi sebagai tolak ukur klasik dalam studi perbandingan fitur. Untuk parameter yang digunakan adalah $nfeatures=0$, $nOctaveLayers=3$, $contrastThreshold=0.04$, $edgeThreshold=10$, dan $sigma=1.6$. Untuk pencocokan *descriptor* yang dihasilkan, digunakan perhitungan jarak *euclidean distance* ($L_2 - Norm$), sesuai persamaan (1) di bawah ini:

$$d_{L_2}(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (1)$$

Dimana:

$d_{L_2}(x, y)$: jarak euclidean ($L_2 - Norm$) antara dua *descriptor* fitur (x dan y).

(x_i, y_i) : dimensi ke- i dari vektor *descriptor* fitur yang dibandingkan.

n : dimensionalitas dari *descriptor*.

$\sum_{i=1}^n (...)$: penjumlahan total di setiap dimensi.

b. Oriented FAST dan Rotated BRIEF (ORB)

ORB merupakan metode ekstraksi fitur berbasis *descriptor* biner 256-bit yang lebih efisien, sehingga sangat cocok untuk aplikasi *real-time* [19]. ORB merupakan gabungan dari dua metode FAST (untuk mendeteksi titik penting) dan BRIEF (untuk membuat *descriptor* biner yang ringan dan cepat dihitung). Dalam eksperimen ini, parameter $nfeatures$ diatur secara spesifik menjadi 2000 sementara parameter lainnya seperti $scaleFactor$ sebesar 1.2 dan $nlevels$ 8. ORB menghasilkan *descriptor* yang koresponden dibandingkan menggunakan perhitungan jarak *hamming distance*, sesuai persamaan (2) di bawah ini:

$$d_H(x, y) = \sum_{i=1}^n x_i \oplus y_i \quad (2)$$

Dimana :

$d_H(x, y)$: Jarak hamming antara dua *descriptor* fitur (x dan y)



$\sum_{i=1}^n (...)$: Penjumlahan total di setiap dimensi.

$x_i \oplus y_i$: Operasi XOR (eksklusif OR) antara bit ke- i dari *descriptor* (x dan y).

c. KAZE

KAZE menghasilkan *float descriptor* yang berbasis pada *non-linear scale space*. Algoritma ini dipilih untuk menguji apakah keunggulan teknisnya dalam mempertahankan detail tepi (*edges*) citra pada saat skala dapat memberikan stabilitas deteksi fitur yang superior [14]. Dalam eksperimen ini, parameter threshold diatur secara spesifik menjadi $1e - 4$ (0.0001). Parameter penting lainnya seperti *nOctaveLayers* 4 dan *nOctaves* 4 menggunakan nilai bawaan yang sama seperti SIFT, *descriptor* KAZE dicocokkan menggunakan perhitungan jarak *euclidean distance* ($L_2 - Norm$), sesuai persamaan (1).

2.4 Validasi Geometris Fitur (Pencocokan)

Tahap pencocokan fitur bertujuan untuk mengidentifikasi pasangan *keypoint* yang koresponden antar citra A dan citra B dari 52 Pasangan citra uji. Proses ini melibatkan penentuan norma jarak, penyaringan *ratio test*, dan validasi geometris menggunakan RANSAC. Berikut adalah ini adalah langkah dari proses pencocokan fitur:

a. Penentuan Pencocok (Matcher Selection)

Penentuan metode *matcher* disesuaikan dengan jenis *descriptor* yang dihasilkan oleh algoritma SIFT dan KAZE. Menggunakan *brute-force matcher* dengan perhitungan jarak l_2 -norm (*euclidean distance*), sesuai persamaan (1). Sedangkan ORB menggunakan *brute-force matcher* dengan perhitungan jarak *hamming distance* untuk *descriptor* biner, sesuai Persamaan (2).

b. Penyaringan Rasio (Ratio Test)

Setelah pencocokan awal, dilakukan penyaringan *match* menggunakan *lowe's ratio test* untuk memfilter kecocokan yang ambigu. *Match* yang dipertahankan adalah yang memiliki rasio jarak antara *match* terbaik pertama (D1) dan *match* terbaik kedua (D2) di bawah 0,75, sehingga mengurangi *false positive*. *Match* yang lolos penyaringan ini dicatat sebagai rata-rata *good match*.

c. Validasi Geometris (RANSAC)

Untuk memvalidasi keakuratan geometris *match*, diterapkan algoritma RANSAC (*Random Sample Consensus*) [14]. RANSAC bekerja secara iteratif untuk menemukan model matematika yang paling akurat (dalam kasus ini, Matriks Homografi, H) yang menjelaskan sebagian besar data *keypoint* (*inlier*), sambil menoleransi data yang salah (*outlier*) [20]. Prosesnya melibatkan sampling acak dari subset minimal data, perhitungan Matriks Homografi, dan pengujian semua titik data lainnya terhadap model H yang telah dihitung. Matriks Homografi (H) adalah matriks 3×3 yang memetakan koordinat titik x dari Citra A ke titik x' di Citra B, sesuai persamaan berikut ini:

$$\begin{pmatrix} x' \\ y' \\ w' \end{pmatrix} = H \begin{pmatrix} x \\ y \\ w \end{pmatrix} \quad (3)$$

Dimana:

H : matriks homografi (3×3) yang menggambarkan transformasi geometris antara dua citra.

$\begin{pmatrix} x \\ y \\ w \end{pmatrix}$: vektor koordinat homogen dari titik *keypoint* di citra A.

$\begin{pmatrix} x' \\ y' \\ w' \end{pmatrix}$: vektor koordinat homogen dari titik *keypoint* yang diproyeksikan

d. Metrik Akurasi

Tahap validasi ini menghasilkan metrik utama akurasi, yaitu Rasio *Inlier*. Rasio ini mengukur persentase pasangan *keypoint* yang valid (lolos RANSAC) terhadap total *match* yang lolos *Ratio Test*, sesuai Persamaan (4):

$$\text{Rasio Inlier} = \frac{\text{Jumlah Inlier}}{\text{Jumlah Good Matches}} \quad (4)$$

2.5 Metrik dan Prosedur Evaluasi Performa

Evaluasi performa dirancang untuk menilai efektivitas (*akurasi* dan *stabilitas*) dan efisiensi (*waktu*) algoritma SIFT, KAZE, dan ORB dalam ekstraksi dan pencocokan fitur rambu lalu lintas, dengan mengadopsi pendekatan kuantitatif multi-dimensi. Akurasi pencocokan diukur melalui Rata-rata *Inlier Ratio* (persamaan 4), yang merupakan metrik utama akurasi, serta Rata-rata *Good Matches*, yang mencatat jumlah *match* yang lolos filter *Ratio Test*. Di sisi efisiensi, metrik yang digunakan adalah Rata-rata *tTotal* (waktu eksekusi total dari deteksi hingga RANSAC) untuk memverifikasi kecocokan algoritma pada aplikasi *real-time* ADAS. Untuk menganalisis *bottleneck* komputasi, waktu juga dipecah menjadi Rata-rata *tDeteksi*(s) dan Rata-rata *tMatch*(s).

Selain itu, evaluasi juga mencakup dua metrik yang berkaitan dengan kualitas dan konsistensi fitur. Kualitas fitur diukur melalui Rata-rata *Keypoints* yang mengindikasikan sensitivitas algoritma terhadap detail citra. Sementara itu, Rata-rata Rasio Selisih *Keypoints* (%) digunakan untuk mengukur stabilitas detektor dan kemampuan generalisasi. Nilai metrik ini, di mana nilai yang lebih rendah menunjukkan konsistensi deteksi yang lebih baik antara dua citra yang serupa, sangat penting untuk mengevaluasi *robustness* algoritma terhadap variasi kondisi pencitraan rambu lalu lintas. Seluruh hasil metrik dievaluasi dengan membuat tabel ringkasan dan disajikan melalui visualisasi grafik batang untuk memudahkan analisis *trade-off* antara akurasi, efisiensi, dan stabilitas.

3. HASIL DAN PEMBAHASAN

3.1 Analisis Kualitatif Fitur dan Pencocokan


Analisis kualitatif fitur dan hasil pencocokan dilakukan pada pasangan citra rambu lalu lintas terpilih untuk mendapatkan bukti visual dan naratif mengenai kinerja algoritma di bawah kondisi pencitraan yang bervariasi. Analisis ini didukung oleh metrik jumlah fitur yang diringkas pada Tabel 1.

Tabel 1. Rata-rata Jumlah Keypoint Terdeteksi Dan Good Matches (n=52 Pairs)

| Algoritma | Rata-rata Keypoints | Rata-rata Good Matches | Rata-rata Rasio Selisih Keypoints (%) |
|-----------|---------------------|------------------------|---------------------------------------|
| ORB | 74.75 | 41.21 | 41.21 |
| KAZE | 219.24 | 23.27 | 23.27 |
| SIFT | 120.36 | 43.00 | 49.60 |

Analisis kualitatif ini dimulai dengan mencermati data pada Tabel 1. Hasil menunjukkan bahwa KAZE secara konsisten mendeteksi jumlah keypoint rata-rata tertinggi sekitar 219.24 dan menghasilkan Good Matches terbanyak yaitu 77.10, mengindikasikan sensitivitas tertinggi terhadap detail. Sebaliknya, ORB mendeteksi jumlah keypoint paling sedikit yaitu 74.75.

Keunggulan KAZE terletak pada stabilitas deteksi, dibuktikan dengan Rasio Selisih Keypoint terendah yaitu 23.27%, yang menunjukkan bahwa detektor Non-linear Scale Space ini adalah yang paling konsisten dalam menghadapi variasi pencitraan rambu. Sementara itu, SIFT adalah yang paling tidak stabil sekitar 49.60%, memperkuat dugaan bahwa SIFT sangat rentan terhadap variasi kecil dalam citra pada resolusi rendah.



Gambar 2. Hasil pencocokan fitur algoritma ORB (a), SIFT (b), KAZE (c)

Visualisasi kualitatif dari hasil pencocokan fitur (Gambar 2) lebih lanjut menjelaskan temuan ini, hasil SIFT menunjukkan *match* yang paling sedikit dan tersebar, yang sejalan dengan metrik ketidakstabilan tertinggi yaitu 49.60% dan akurasi terendah pada keseluruhan hasil eksperimen. Selanjutnya, pada hasil ORB menghasilkan *match* yang terpusat dan konsisten secara geometris di area inti rambu, sebuah pola yang berkorelasi kuat dengan Rasio Inlier tertinggi pada analisis kuantitatif. Sementara itu, pada hasil KAZE menunjukkan distribusi *keypoint* yang paling padat di sepanjang tepi rambu, yang merupakan bukti visual dari Rasio Selisih *Keypoint* terendah sekitar 23.27%, mengindikasikan stabilitas deteksi terbaik.

3.2 Analisis Data Kuantitatif

Analisis data kuantitatif didasarkan pada rata-rata metrik kinerja yang diukur dari 52 pasangan citra uji. Data ini mencakup Akurasi (Inlier Ratio), Efisiensi (Waktu Total), kualitas fitur (Keypoints), dan stabilitas deteksi (Rasio Selisih Keypoints).

Tabel 2. Rata-rata Hasil Kinerja SIFT, KAZE, dan ORB (n=52 Pairs)

| Algoritma | Rata-rata Inlier Ratio | Rata-rata tDeteksi (s) | Rata-rata tMatch (s) | Rata-rata tRANSAC (s) | Rata rata tTotal (s) |
|-----------|------------------------|------------------------|----------------------|-----------------------|----------------------|
| ORB | 0.6575 | 0.0030 | 0.0003 | 0.0022 | 0.0056 |
| KAZE | 0.4644 | 0.0864 | 0.0069 | 0.0126 | 0.1059 |
| SIFT | 0.4524 | 0.0198 | 0.0039 | 0.0080 | 0.0317 |


Data kuantitatif yang tersaji pada Tabel 2 menunjukkan adanya *trade-off* yang signifikan antar algoritma. ORB mendominasi di metrik hasil akhir, muncul sebagai algoritma paling efisien, rata-rata total waktu 0.0056 detik dan menjadikannya paling akurat dengan Rasio Inlier 0.6575. Kecepatan ini menjadikannya ideal untuk aplikasi *real-time*. Di sisi lain, KAZE adalah algoritma yang paling lambat yaitu 0.1059 detik, namun memiliki keunggulan pada aspek stabilitas deteksi yang tinggi yaitu Rasio Selisih *Keypoints* 23.27%. Sementara itu, SIFT menempati peringkat terendah pada aspek akurasi maupun stabilitas, menegaskan bahwa algoritma ini memiliki keterbatasan serius dalam konteks eksperimen beresolusi rendah.

3.3 Pembahasan Hasil dan Perbandingan Metrik

Pembahasan ini menganalisis *trade-off* utama dan menjelaskan hasil eksperimen berdasarkan prinsip kerja masing-masing algoritma dalam konteks citra rambu lalu lintas beresolusi rendah.

3.3.1 Analisis Efisiensi Komputasi (Waktu)

Analisis efisiensi komputasi dilakukan dengan membandingkan Rata-rata Total Waktu eksekusi dari ketiga algoritma, yang disajikan secara visual melalui grafik batang pada Gambar 3.




Gambar 3. Grafik Perbandingan Rata-rata Total Waktu Model

Hierarki efisiensi komputasi sangat ditentukan oleh jenis descriptor yang digunakan, sebagaimana terlihat pada Tabel 2 dan divisualisasikan pada Gambar 3. Grafik Rata-rata Total Waktu. ORB mencatatkan Total Waktu terendah yaitu 0.0056 s yang ditunjukkan bar terpendek, karena menggunakan *Binary Descriptor* 256-bit dan Hamming Distance untuk pencocokan, yang secara komputasi jauh lebih ringan. Sebaliknya, KAZE adalah yang paling lambat yaitu 0.1059 s, ditandai dengan bar terpanjang, disebabkan oleh biaya komputasi yang mahal dari pembangunan Ruang Skala Non-linear yang kompleks. SIFT berada di tengah dengan waktu 0.0317s, dipengaruhi oleh biaya tinggi Deteksi DoG dan perhitungan Float Descriptor 128-dimensi.

3.3.2 Analisis Akurasi (Rasio Inlier) dan Kualitas Fitur

Kinerja algoritma dalam hal akurasi diukur berdasarkan Rasio Inlier, yaitu persentase kecocokan yang valid secara geometris setelah eliminasi *outlier* oleh RANSAC. Hasil perbandingan Rasio Inlier untuk ketiga algoritma disajikan secara visual pada Gambar 4.




Gambar 4. Grafik Perbandingan Rata-rata Inlier Ratio Model

Hasil akurasi pada Tabel 2 dan Gambar 4. Grafik Rata-rata Rasio Inlier menunjukkan anomali di mana Binary Descriptor ORB yaitu 0.657, melampaui Float Descriptor SIFT dan KAZE. Temuan ini mengindikasikan bahwa pada citra beresolusi rendah, *keypoint* ORB, meskipun berjumlah lebih sedikit yaitu 74.75 dari Tabel 1, adalah yang paling andal dan konsisten secara geometris. Hal ini dikontraskan dengan KAZE (Gambar 5. Grafik Rata-rata *Keypoint*), yang mendeteksi *keypoint* terbanyak 219.24, namun memiliki akurasi yang rendah yaitu 0.4644. Kondisi ini menunjukkan bahwa banyaknya fitur yang diekstrak SIFT dan KAZE adalah fitur yang tidak *repeatable* (berulang) atau *noise*, sehingga gagal divalidasi oleh filter RANSAC, yang berujung pada Rasio Inlier yang lebih rendah.

3.3.3 Analisis Stabilitas Deteksi (Rasio Selisih Keypoint)

Stabilitas deteksi fitur dievaluasi menggunakan Rasio Selisih Keypoint, yang mengukur konsistensi persentase jumlah *keypoint* yang dideteksi oleh setiap algoritma pada pasangan citra yang berbeda. Hasil perbandingan Rasio Selisih Keypoint (persentase terendah menunjukkan stabilitas terbaik) untuk ketiga algoritma disajikan secara visual pada Gambar 5.



Gambar 5. Grafik Perbandingan Rata-rata Selisih Keypoints Model

Stabilitas deteksi mengukur konsistensi fitur yang diekstrak terhadap variasi pencitraan, dan hasilnya (Tabel 1) secara kuat memvalidasi desain KAZE. Gambar 5. Grafik Rata-rata Rasio Selisih *Keypoint* menunjukkan bahwa KAZE adalah algoritma paling stabil dengan Rasio Selisih *Keypoints* terendah (23.27%) yang ditunjukkan dengan bar terpendek. Stabilitas ini terjadi karena KAZE menggunakan Perambatan Anisotropik yang secara efektif mempertahankan ketajaman detail tepi rambu, memastikan detektor konsisten menemukan *keypoint* yang sama pada citra yang serupa. Sebaliknya, SIFT adalah yang paling tidak stabil (49.60%), mengonfirmasi bahwa algoritma berbasis DoG rentan terhadap variasi kecil dalam citra rambu pada resolusi yang dibatasi.

3.4 Pembahasan

Hasil eksperimen pada *dataset* rambu lalu lintas secara tegas membuktikan adanya *trade-off* yang berbeda dari skenario lain. ORB secara konsisten menghasilkan Rasio *Inlier* tertinggi (0.6575) dan mendominasi efisiensi komputasi dengan eksekusi rata-rata hanya 0.0056 detik. Kecepatan ini sesuai dengan tujuan ORB sebagai detektor ringan untuk aplikasi *real-time*. Temuan ini memvalidasi studi lain yang menekankan bahwa *trade-off* antara akurasi dan kecepatan menjadi kriteria pemilihan algoritma, dan *Binary Descriptor* ideal untuk perangkat terbatas [10][13].

Kontribusi temuan ini terletak pada keunggulan empiris ORB yang melampaui SIFT pada metrik akurasi geometris. Meskipun SIFT secara teori unggul terhadap perubahan skala dan rotasi, SIFT gagal bersaing di semua metrik kritis, mencatatkan akurasi terendah (0.4524) dan Rasio Selisih *Keypoint* tertinggi (49.60%). Temuan ini selaras dengan studi yang menunjukkan penurunan kinerja SIFT pada citra resolusi rendah atau di bawah kondisi *real-world*. Sementara itu, KAZE menawarkan stabilitas unik. Meskipun menjadi yang paling lambat (0.1059 detik), KAZE merupakan detektor paling stabil dengan Rasio Selisih *Keypoint* terendah (23.27%), yang merupakan bukti empiris dari keunggulan teknisnya dalam mempertahankan detail tepi (*edges*) citra, analisis ini menegaskan bahwa tidak ada solusi tunggal. ORB unggul pada efisiensi dan akurasi (paling optimal untuk ADAS *real-time*), sementara KAZE menunjukkan *robustness* fitur terbaik (cocok untuk analisis *post-processing*). SIFT dan studi *deep learning* terbaru menunjukkan potensi integrasi

metode deteksi tradisional dan pembelajaran mendalam untuk meningkatkan *robustness*, meski memerlukan sumber daya pelatihan besar.

Namun demikian, penelitian ini belum melakukan pengujian signifikansi statistik seperti t-test atau ANOVA untuk memastikan apakah perbedaan performa antar algoritma bersifat signifikan secara statistik. Oleh karena itu, hasil yang diperoleh pada penelitian ini masih bersifat evaluasi empiris pada dataset dan skenario pengujian yang digunakan, sehingga analisis statistik yang lebih mendalam dapat menjadi arah pengembangan pada penelitian selanjutnya. Secara keseluruhan, hasil penelitian menunjukkan bahwa ORB memiliki potensi untuk implementasi real-time berbasis komputasi ringan, sedangkan KAZE lebih unggul dalam menjaga konsistensi fitur. Temuan ini juga membuka peluang integrasi metode feature matching tradisional dengan pendekatan deep learning untuk meningkatkan *robustness* pada kondisi lingkungan yang lebih kompleks.

4. KESIMPULAN

Penelitian ini menunjukkan bahwa setiap algoritma feature matching memiliki karakteristik performa yang berbeda pada citra rambu lalu lintas resolusi rendah. ORB memberikan keseimbangan terbaik antara efisiensi komputasi dan akurasi pencocokan dengan waktu eksekusi rata-rata tercepat sebesar 0.0056 detik dan rasio inlier tertinggi sebesar 0.6575 pada skenario pengujian yang digunakan. Hasil ini mengindikasikan bahwa binary descriptor seperti ORB masih memiliki potensi untuk diterapkan pada sistem dengan keterbatasan komputasi dan kebutuhan respons cepat. Namun demikian, hasil penelitian ini masih terbatas pada kondisi dataset pengujian dan belum merepresentasikan lingkungan nyata yang lebih kompleks seperti cuaca ekstrem, blur, noise, maupun degradasi citra dari sensor kendaraan. Sementara itu, KAZE menunjukkan konsistensi deteksi fitur yang lebih baik dengan rasio selisih keypoint terendah sebesar 23.27%, yang mengindikasikan kemampuan menjaga kestabilan fitur pada perubahan visual tertentu, meskipun memiliki waktu komputasi paling tinggi sebesar 0.1059 detik. Di sisi lain, SIFT menunjukkan performa yang relatif lebih rendah dengan rasio inlier sebesar 0.4524 dan rasio selisih keypoint tertinggi sebesar 49.60%, yang menunjukkan bahwa descriptor berbasis floating-point tidak selalu optimal pada citra resolusi rendah dengan informasi visual terbatas. Secara keseluruhan, hasil penelitian memperlihatkan bahwa pemilihan algoritma feature matching tidak hanya ditentukan oleh akurasi, tetapi juga dipengaruhi oleh kebutuhan efisiensi komputasi, stabilitas fitur, dan karakteristik data yang digunakan. Oleh karena itu, penelitian selanjutnya dapat difokuskan pada evaluasi menggunakan kondisi lingkungan yang lebih kompleks, penerapan teknik peningkatan kualitas citra, serta perbandingan dengan pendekatan deep learning modern untuk memperoleh pemahaman yang lebih komprehensif mengenai batas performa masing-masing metode.

REFERENCES

- [1] F. Alzami, M. Naufal, H. A. Azies, S. Winarno, and M. A. Soeleman, "Time Distributed MobileNetV2 with Auto-CLAHE for Eye Region Drowsiness Detection in Low Light Conditions," *Int. J. Adv. Comput. Sci. Appl.*, vol. 15, no. 11, 2024, doi: 10.14569/IJACSA.2024.0151146.
- [2] H. Nadeem *et al.*, "Road Feature Detection for Advance Driver Assistance System Using Deep Learning," *Sensors*, vol. 23, no. 9, p. 4466, May 2023, doi: 10.3390/s23094466.
- [3] V. Radojčić and M. Dobrojević, "Traffic Sign Recognition Using Computer Vision," in *Proceedings of the International Scientific Conference - Sinteza 2025*, Beograd, Serbia: Singidunum University, 2025, pp. 10–15. doi: 10.15308/Sinteza-2025-10-15.
- [4] S. B. Wali *et al.*, "Vision-Based Traffic Sign Detection and Recognition Systems: Current Trends and Challenges," *Sensors*, vol. 19, no. 9, p. 2093, May 2019, doi: 10.3390/s19092093.
- [5] V. K. C. -, "The Evolution and Impact of Advanced Driver-Assistance Systems," *Int. J. Sci. Technol.*, vol. 16, no. 1, p. 2915, Mar. 2025, doi: 10.71097/IJSAT.v16.i1.2915.
- [6] X. R. Lim, C. P. Lee, K. M. Lim, T. S. Ong, A. Alqahtani, and M. Ali, "Recent Advances in Traffic Sign Recognition: Approaches and Datasets," *Sensors*, vol. 23, no. 10, p. 4674, May 2023, doi: 10.3390/s23104674.
- [7] S. Gunasekara, D. Gunarathna, and M. Dissanayake, "Advanced Driver-Assistance System with Traffic Sign Recognition for Safe and Efficient Driving," *Int. J. Recent Innov. Trends Comput. Commun.*, vol. 9, no. 9, pp. 11–15, Sep. 2021, doi: 10.17762/ijritcc.v9i9.5488.
- [8] K. V. Houde, K. S. Chakravarthy, P. M. Kamble, and R. Hegadi, "Analysis of SIFT, SURF, and ORB feature extraction techniques for 3D reconstruction of mango trees," in *Third Asia Conference on Computer Vision, Image Processing, and Pattern Recognition (CVIPPR 2025)*, L. Chen, Ed., Xiamen, China: SPIE, Jul. 2025, p. 18. doi: 10.1117/12.3076267.
- [9] Q. Chen *et al.*, "Horticultural Image Feature Matching Algorithm Based on Improved ORB and LK Optical Flow," *Remote Sens.*, vol. 14, no. 18, p. 4465, Sep. 2022, doi: 10.3390/rs14184465.
- [10] A. Smaali, S. Ben Alla, and A. Touhafi, "TSRACE-AI: Traffic Sign Recognition Accelerated with Co-Designed Edge AI Based on Hybrid FPGA Architecture for ADAS," *Information*, vol. 16, no. 8, p. 703, Aug. 2025, doi: 10.3390/info16080703.
- [11] J. Borrego-Carazo, D. Castells-Rufas, E. Biempica, and J. Carrabina, "Resource-Constrained Machine Learning for ADAS: A Systematic Review," *IEEE Access*, vol. 8, pp. 40573–40598, 2020, doi: 10.1109/ACCESS.2020.2976513.
- [12] 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 J. Ilm. Tek. Inform. Dan Sist. Inf.*, vol. 14, no. 2, p. 821, Aug. 2025, doi: 10.35889/jutisi.v14i2.2738.



- [13] X. Sun and P. Chang, “Robust Perspective Correction for Real-World Crack Evolution Tracking in Image-Based Structural Health Monitoring,” 2025, *arXiv*. doi: 10.48550/ARXIV.2506.22437.
- [14] S. A. K. Tareen and Z. Saleem, “A comparative analysis of SIFT, SURF, KAZE, AKAZE, ORB, and BRISK,” in *2018 International Conference on Computing, Mathematics and Engineering Technologies (iCoMET)*, Sukkur, Pakistan: IEEE, Mar. 2018, pp. 1–10. doi: 10.1109/ICOMET.2018.8346440.
- [15] Z. Yan, H. Wang, Q. Ning, and Y. Lu, “Robust Image Matching Based on Image Feature and Depth Information Fusion,” *Machines*, vol. 10, no. 6, p. 456, Jun. 2022, doi: 10.3390/machines10060456.
- [16] M. Isik, “Comprehensive empirical evaluation of feature extractors in computer vision,” *PeerJ Comput. Sci.*, vol. 10, p. e2415, Nov. 2024, doi: 10.7717/peerj-cs.2415.
- [17] M. Naufal, H. Al Azies, and R. M. Brilianto, “Enhanced Brain Tumor Classification through Gamma Correction in Deep Learning,” *SISTEMASI*, vol. 13, no. 6, p. 2348, Nov. 2024, doi: 10.32520/stmsi.v13i6.4474.
- [18] A. V. N. M. Hemateja, “Traffic Sign Dataset - Classification.” Accessed: Apr. 15, 2026. [Online]. Available: <https://www.kaggle.com/datasets/ahemateja19bec1025/traffic-sign-dataset-classification>
- [19] L. Cai, Y. Ye, X. Gao, Z. Li, and C. Zhang, “An improved visual SLAM based on affine transformation for ORB feature extraction,” *Optik*, vol. 227, p. 165421, Feb. 2021, doi: 10.1016/j.ijleo.2020.165421.
- [20] P. Li, M. Wang, J. Fu, and Y. Wang, “Plane Detection Based on an Improved RANSAC Algorithm,” in *2023 IEEE 3rd International Conference on Computer Communication and Artificial Intelligence (CCAI)*, Taiyuan, China: IEEE, May 2023, pp. 211–215. doi: 10.1109/CCAI57533.2023.10201261.