

Verifikasi Otomatis Sertifikat Menggunakan *Improved SIFT* dan RANSAC Berbasis Analisis Visual Logo dan Stempel

Maulidya Prastita Syah^{*1}, Wahyu Syaifullah Jauharis Saputra², Alfian Rizaldy Pratama³

^{1,2,3}Sains Data, Fakultas Ilmu Komputer, Universitas Pembangunan Nasional “Veteran” Jawa Timur, Indonesia.

Email: ¹22083010039@student.upnjatim.ac.id, ²wahyu.s.j.saputra.if@upnjatim.ac.id,

³alfan.fasilkom@upnjatim.ac.id

Abstrak

Proses verifikasi sertifikat prestasi pada jalur Seleksi Nasional Berdasarkan Prestasi (SNBP) masih dilakukan secara manual dan menghadapi tantangan akibat tingginya jumlah dokumen serta variasi kualitas citra. Kondisi ini meningkatkan risiko kesalahan dalam menilai kredibilitas sertifikat, khususnya pada elemen visual seperti logo dan stempel yang tidak valid. Penelitian ini bertujuan mengembangkan metode otomatis dalam mengidentifikasi kredibilitas sertifikat berbasis analisis fitur visual. Metode yang digunakan adalah *Improved Scale Invariant Feature Transform (Improved SIFT)* untuk mengekstraksi fitur lokal yang stabil, serta *Random Sample Consensus (RANSAC)* untuk menyaring kecocokan fitur berdasarkan konsistensi geometris. Pencocokan dilakukan antara citra sertifikat dan citra parameter berupa logo dan stempel yang telah diidentifikasi sebagai tidak valid. Pengujian dilakukan pada 200 citra sertifikat yang terdiri dari dua kelas, yaitu kredibel dan tidak kredibel yang menunjukkan *Improved SIFT* mampu meningkatkan kualitas representasi fitur dengan akurasi sebesar 0.47 dibandingkan *SIFT* standar sebesar 0.16. Selanjutnya, *RANSAC* mampu menyaring *false match* dengan peningkatan akurasi dari 0.47 menjadi 0.91 setelah *RANSAC*. Kontribusi penelitian ini adalah mengintegrasikan *Improved SIFT* dan *RANSAC* untuk meningkatkan validitas pencocokan fitur visual dalam mendeteksi indikasi ketidak-kredibelan sertifikat pada citra dengan variasi kualitas tinggi. Dengan demikian, metode yang diusulkan mampu meningkatkan keandalan sistem dalam proses verifikasi otomatis berbasis analisis visual.

Kata kunci: *Improved SIFT*, kredibilitas sertifikat, pencocokan fitur, *RANSAC*, sertifikat prestasi.

Abstract

The verification process of achievement certificates in the Seleksi Nasional Berdasarkan Prestasi (SNBP) pathway is still conducted manually and faces challenges due to the large volume of documents and variations in image quality. This condition increases the risk of errors in assessing certificate credibility, particularly in visual elements such as logos and stamps that are not valid. This study aims to develop an automated method for identifying certificate credibility based on visual feature analysis. The proposed method utilizes the *Improved Scale Invariant Feature Transform (Improved SIFT)* to extract stable local features, and *Random Sample Consensus (RANSAC)* to filter feature matches based on geometric consistency. Feature matching is performed between certificate images and parameter images consisting of logos and stamps identified as invalid references. Experiments conducted on 200 certificate images, consisting of credible and non-credible classes, show that *Improved SIFT* improves feature representation quality, achieving an accuracy of 0.47 compared to 0.16 using standard *SIFT*. Furthermore, the application of *RANSAC* effectively reduces false matches, increasing accuracy from 0.47 to 0.91. The contribution of this study is the integration of *Improved SIFT* and *RANSAC* to enhance the validity of visual feature matching in detecting indications of non-credible certificates under varying image quality conditions. Thus, the proposed method improves the reliability of automated certificate verification based on visual analysis.

Keywords: *Improved SIFT*, certificate credibility, feature matching, *RANSAC*, achievement certificate.

This work is an open access article and licensed under a Creative Commons Attribution-NonCommercial ShareAlike 4.0 International (CC BY-NC-SA 4.0)



1. PENDAHULUAN

Seleksi Nasional Berdasarkan Prestasi (SNBP) merupakan jalur penerimaan mahasiswa baru di Indonesia yang menitikberatkan pada prestasi akademik dan non-akademik siswa tanpa melalui ujian tertulis [1]. Dalam mekanisme seleksi ini, sertifikat prestasi menjadi dokumen pendukung penting yang

merepresentasikan capaian siswa, seperti penghargaan lomba, prestasi akademik, maupun bentuk pengakuan resmi lainnya [2]. Namun demikian, peningkatan jumlah peserta SNBP setiap tahun secara langsung berdampak pada bertambahnya jumlah sertifikat yang harus diverifikasi oleh panitia seleksi [3]. Setiap sertifikat perlu diperiksa secara individual untuk menilai kredibilitasnya, khususnya melalui identifikasi elemen visual seperti logo dan stempel. Variasi desain sertifikat, perbedaan tampilan logo, resolusi citra, serta kualitas hasil pemindaian semakin mempersulit proses verifikasi, sehingga meningkatkan waktu pemeriksaan dan potensi terjadinya inkonsistensi maupun kesalahan penilaian [4]. Lebih lanjut, karakteristik sertifikat SNBP memiliki tantangan spesifik yang tidak selalu ditemukan pada dataset citra dokumen pada umumnya. Hal ini disebabkan oleh sifat sertifikat prestasi yang berasal dari berbagai institusi dengan desain visual yang sangat beragam, tanpa adanya standar format yang seragam, sehingga bentuk, warna, dan struktur logo dapat berbeda secara signifikan. Selain itu, pada proses pengumpulan dokumen, sertifikat sering mengalami modifikasi visual seperti penambahan cap basah, *overlay* tanda tangan, maupun kompresi berulang saat diunggah, yang dapat menutupi atau mengubah sebagian area logo. Kondisi ini menyebabkan fitur visual yang seharusnya menjadi acuan identifikasi menjadi tidak konsisten, sehingga meningkatkan kompleksitas dalam proses ekstraksi dan pencocokan fitur.

Kompleksitas tersebut semakin meningkat ketika dikaitkan dengan mekanisme verifikasi sertifikat pada proses SNBP yang hingga saat ini masih belum optimal dan sebagian besar bergantung pada pemeriksaan manual [5]. Data resmi menunjukkan bahwa jumlah peserta SNBP mencapai ratusan ribu setiap tahunnya, dengan setiap peserta diperbolehkan mengunggah lebih dari satu sertifikat [6], [7] sehingga total dokumen yang harus diverifikasi dapat mencapai jutaan berkas dalam waktu yang terbatas. Volume dokumen yang besar serta keberagaman format sertifikat ini menimbulkan tantangan signifikan bagi proses verifikasi manual. Salah satu permasalahan utama adalah adanya potensi sertifikat yang tidak kredibel. Di antara berbagai elemen visual pada sertifikat, logo institusi memiliki peran penting sebagai indikator identitas dan keaslian penerbit. Proses verifikasi logo secara manual dalam skala besar menjadi tidak efisien dan rentan terhadap kesalahan manusia, sehingga diperlukan pendekatan otomatis yang mampu menganalisis parameter visual secara konsisten dan akurat.

Salah satu metode yang banyak digunakan dalam bidang *computer vision* untuk ekstraksi fitur visual adalah *Scale Invariant Feature Transform* (SIFT), yang mampu mendeteksi ciri lokal unik yang invarian terhadap perubahan skala, rotasi, dan pencahayaan [8]. Penelitian sebelumnya menunjukkan bahwa pendekatan berbasis SIFT dapat mendeteksi logo dan menganalisis citra dokumen pada berbagai kondisi visual [9], [10]. Namun, SIFT konvensional memiliki keterbatasan pada aplikasi skala besar, terutama karena kompleksitas komputasi yang tinggi serta kerentanan terhadap kesalahan pencocokan fitur ketika terdapat pola visual yang mirip namun tidak relevan [11], [12]. Dalam penelitian sebelumnya juga, menerapkan metode tambahan berupa validasi geometris menggunakan algoritma *Random Sample Consensus* (RANSAC) untuk meningkatkan keandalan hasil pencocokan [13]. Untuk mengidentifikasi posisi penelitian ini terhadap penelitian sebelumnya, Tabel 1 menyajikan ringkasan metode, temuan, serta keterbatasan dari beberapa penelitian terkait.

Tabel 1. State of the art

No.	Judul	Metode	Temuan	Keterbatasan
1	<i>Automatic Logo Extraction and Detection for Document Verification using SIFT and SURF</i> [9]	SIFT dan SURF digunakan untuk mengekstrak logo dari sertifikat. Penggunaan keduanya bertujuan mengidentifikasi dokumen dengan fitur logo visual.	Metode ini mencapai akurasi ~96% pada verifikasi dokumen melalui logo. Kombinasi SIFT-SURF efektif mendeteksi logo institusi meski bentuknya bervariasi.	SIFT lambat dan tidak mengatasi volume besar dokumen SNBP. Kecepatan komputasi rendah membatasi verifikasi berskala besar
2	<i>Image Identification Using SIFT Algorithm: Performance Analysis against Different Image Deformations</i> [10]	Performa SIFT dianalisis terhadap deformasi citra (rotasi, skala, efek <i>fish-eye</i> , motion blur). Tingkat <i>true/false positive</i> dihitung untuk banyak pasangan citra.	Hasilnya menunjukkan SIFT sangat robust terhadap rotasi dan penskalaan. Namun performa menurun pada distorsi kuat seperti efek <i>fish-eye</i> atau blur gerak.	SIFT kurang tahan terhadap deformasi ekstrem, yang dapat menyebabkan <i>false match</i> tinggi. Kinerjanya terpengaruh negatif

				oleh distorsi optik berat.
3	<i>Research on Image Matching of Improved SIFT Algorithm Based on Stability Factor and Feature Descriptor Simplification</i> [11]	<i>Improved</i> SIFT diterapkan dengan faktor stabilitas tambahan dan deskriptor disederhanakan (96 dimensi) untuk pencocokan fitur. Pendekatan ini mengurangi dimensi fitur untuk mempercepat proses pencocokan.	Perbaikan ini meningkatkan kecepatan ~30% dan mengurangi kesalahan pencocokan. Waktu komputasi lebih singkat tanpa menurunkan akurasi secara signifikan.	Metode ini belum dilakukan pada berbagai kondisi nyata dan dataset besar.
4	<i>Image Stitching Quality Evaluation and Improvement Based on SIFT Features and RANSAC Algorithm</i> [13]	SIFT digabung dengan RANSAC untuk menilai dan meningkatkan penjahitan citra (<i>stitching</i>). RANSAC mengeliminasi <i>outlier</i> dari ekstraksi fitur SIFT	Pendekatan ini meningkatkan kualitas <i>stitching</i> : ketajaman tepi ~0,78 dan detail tersimpan ~75% Hasil jahitan image <i>stitching</i> menjadi lebih alami dan akurat dibanding metode standar.	Penggunaan SIFT konvensional memakan komputasi yang lama

Berdasarkan Tabel 1, penelitian sebelumnya menunjukkan bahwa metode berbasis SIFT dan kombinasinya mampu mendeteksi serta mencocokkan fitur visual pada citra dokumen dengan tingkat akurasi yang baik [9], tetapi masih memiliki keterbatasan dalam efisiensi komputasi dan belum mampu menangani verifikasi dokumen berskala besar dengan variasi visual kompleks seperti pada sertifikat SNBP. Penyederhanaan deskriptor pada *Improved* SIFT terbukti meningkatkan efisiensi pencocokan tanpa penurunan akurasi yang signifikan, tetapi belum dilengkapi mekanisme validasi geometris sehingga masih rentan terhadap *false match* pada citra dengan kondisi kompleks [11]. Selain itu, analisis performa SIFT terhadap berbagai deformasi citra menunjukkan bahwa metode ini masih rentan terhadap distorsi tertentu seperti blur dan efek optik, yang menyebabkan penurunan akurasi pencocokan [10]. Integrasi SIFT dan RANSAC mampu meningkatkan kualitas pencocokan melalui eliminasi *outlier*, tetapi masih terbatas pada konteks tertentu dan belum diterapkan secara spesifik pada verifikasi dokumen dengan karakteristik visual kompleks seperti sertifikat [13].


Selain itu, penelitian lain oleh Isik [14] menunjukkan bahwa berbagai metode ekstraksi fitur seperti ORB, SURF, KAZE, dan lainnya memiliki keunggulan masing-masing dalam hal efisiensi dan ketahanan terhadap variasi citra, di mana ORB cenderung lebih cepat secara komputasi, sementara SIFT dan KAZE menawarkan akurasi yang lebih tinggi pada kondisi transformasi tertentu. Namun, metode berbasis fitur biner seperti ORB umumnya memiliki *trade-off* terhadap ketahanan terhadap *noise* dan distorsi kompleks, sehingga kurang optimal pada citra sertifikat yang memiliki variasi kualitas tinggi. Di sisi lain, pendekatan berbasis OCR kurang sesuai karena fokus pada ekstraksi informasi tekstual dan tidak mempertimbangkan karakteristik visual seperti logo dan stempel yang menjadi indikator utama dalam verifikasi sertifikat. Sementara itu, metode berbasis *deep learning* seperti *Convolutional Neural Network* (CNN) memang mampu, tetapi memerlukan dataset berskala besar, proses pelatihan yang kompleks, serta sumber daya komputasi yang tinggi, sehingga kurang efisien untuk implementasi pada sistem verifikasi dokumen dengan keterbatasan data.

Berdasarkan tabel dan uraian tersebut, dapat disimpulkan bahwa meskipun metode berbasis SIFT dan pengembangannya telah menunjukkan performa yang baik dalam ekstraksi dan pencocokan fitur visual, masih terdapat celah pada aspek efisiensi komputasi dan keandalan pencocokan pada kondisi citra yang kompleks. *Improved* SIFT mampu mengatasi sebagian permasalahan dengan meningkatkan efisiensi melalui penyederhanaan deskriptor, sehingga lebih sesuai untuk pemrosesan dalam skala besar. Namun, tanpa mekanisme validasi tambahan, hasil pencocokan fitur masih berpotensi mengandung pasangan yang tidak relevan, terutama pada citra sertifikat dengan variasi kualitas, distorsi, dan *noise* yang tinggi. Oleh karena itu, dalam penelitian ini digunakan *Improved* SIFT untuk menghasilkan fitur yang lebih efisien dan stabil, serta dikombinasikan dengan algoritma RANSAC yang berperan dalam memvalidasi kecocokan fitur secara geometris sehingga hanya mempertahankan pasangan fitur yang konsisten. Integrasi kedua metode ini diharapkan mampu meningkatkan akurasi dan keandalan sistem dalam mengidentifikasi kredibilitas sertifikat berdasarkan karakteristik visual logo dan stempel.

Berdasarkan permasalahan tersebut, penelitian ini berkontribusi dalam tiga hal. Pertama, menerapkan *Improved SIFT* dengan deskriptor 96 dimensi pada konteks verifikasi visual sertifikat prestasi yang memiliki variasi kualitas citra tinggi. Kedua, mengintegrasikan RANSAC untuk memvalidasi kecocokan fitur secara geometris guna mengurangi *false match*. Ketiga, mengevaluasi dampak integrasi tersebut terhadap akurasi klasifikasi sertifikat kredibel dan tidak kredibel.

2. METODE PENELITIAN

Penelitian ini mengusulkan pendekatan otomatis untuk mengidentifikasi kredibilitas sertifikat prestasi pada jalur Seleksi Nasional Berdasarkan Prestasi (SNBP) dengan memanfaatkan analisis fitur visual. Secara umum, tahapan penelitian seperti ditunjukkan pada Gambar 1 yang meliputi persiapan data, *preprocessing*, ekstraksi fitur, pencocokan fitur, validasi geometris, dan penentuan kredibilitas sertifikat.




Gambar 1. Tahapan Penelitian

Permasalahan verifikasi sertifikat diformulasikan sebagai proses pencocokan citra, di mana kesesuaian elemen visual berupa logo dan cap lembaga pada sertifikat uji dibandingkan dengan citra referensi menggunakan metode *Improved Scale Invariant Feature Transform (Improved SIFT)* dan *Random Sample Consensus (RANSAC)*. Secara umum, tahapan penelitian meliputi persiapan data, *preprocessing*, ekstraksi fitur, pencocokan fitur, validasi geometris, dan penentuan kredibilitas sertifikat.

2.1. Data Preparation and Preprocessing

Dataset yang digunakan dalam penelitian ini terdiri dari 200 citra sertifikat, yang terdiri dari 182 sertifikat kredibel (kelas 0) dan 18 sertifikat tidak kredibel (kelas 1). Data sertifikat diperoleh dari salah satu pihak penyelenggara SNBP di Universitas Pembangunan Nasional “Veteran” Jawa Timur. Data memiliki variasi format file seperti PDF, JPG, dan PNG dengan perbedaan resolusi serta kualitas hasil pemindaian. Untuk memastikan keseragaman data, seluruh dokumen terlebih dahulu dikonversi ke dalam format citra, di mana file PDF dipisahkan per halaman agar setiap halaman diproses sebagai satu citra independen. Dataset ini tidak dilakukan proses penyeimbangan kelas, sehingga distribusi kelas mencerminkan kondisi data nyata. Kondisi ketidakseimbangan data ini tidak mempengaruhi proses pembelajaran model karena pendekatan yang digunakan bersifat *rule-based*, namun dapat mempengaruhi interpretasi performa. Distribusi kelas yang tidak seimbang berpotensi menyebabkan nilai akurasi terlihat tinggi, meskipun kemampuan sistem dalam mendeteksi kelas minoritas (sertifikat tidak kredibel) masih terbatas. Oleh karena itu, digunakan metrik evaluasi tambahan seperti precision, recall, dan F1-score untuk memberikan gambaran performa yang lebih komprehensif.

Seluruh data digunakan sebagai data uji dalam satu skema eksperimen tanpa pembagian *training* dan *testing*, karena pendekatan yang digunakan bersifat *rule-based* dan tidak melibatkan proses pembelajaran model.



Gambar 2. Data Sertifikat Awal

Tahap *preprocessing* dilakukan untuk meningkatkan kualitas citra dan menstabilkan proses ekstraksi fitur. Proses ini meliputi konversi citra ke *grayscale* guna mengurangi kompleksitas data tanpa menghilangkan informasi penting, serta peningkatan kontras menggunakan metode *Contrast Limited Adaptive Histogram Equalization* (CLAHE) untuk memperjelas [15]. Selain itu, seluruh citra diseragamkan ke dalam format PNG untuk memastikan konsistensi kualitas citra dan menghindari kehilangan informasi akibat kompresi.

Selain data sertifikat, penelitian ini juga menggunakan data parameter berupa citra referensi logo dan stempel resmi dari beberapa lembaga sebagai acuan pencocokan fitur. Dalam penelitian ini, data parameter merepresentasikan kumpulan citra logo dan stempel yang telah dikategorikan sebagai tidak valid oleh pihak penyelenggara dengan alasan yang *confidential*, sehingga kecocokan terhadap parameter menunjukkan indikasi ketidak-kredibelan, bukan keaslian. Dengan demikian, kecocokan terhadap parameter tidak menunjukkan keaslian, melainkan indikasi bahwa sertifikat memiliki pola visual yang serupa dengan contoh yang tidak valid. Pada data parameter, dilakukan penentuan *region of interest* (ROI) secara manual dengan mengamati posisi logo atau stempel pada citra sertifikat, lalu menentukan batas area yang mencakup objek tersebut, dan melakukan pemotongan (*cropping*) citra sesuai area yang telah ditentukan. Dengan demikian, proses ekstraksi fitur hanya dilakukan pada bagian yang relevan, sehingga dapat mengurangi pengaruh elemen lain seperti teks atau latar belakang yang tidak diperlukan. Setiap parameter direpresentasikan dalam bentuk citra *grayscale* yang telah melalui proses *preprocessing* yang sama dengan data sertifikat.

2.2. Ekstraksi Fitur dengan *Improved SIFT*

Ekstraksi fitur dilakukan menggunakan algoritma *Improved Scale Invariant Feature Transform* yang merupakan pengembangan dari SIFT standar dengan peningkatan pada efisiensi dan stabilitas deteksi fitur [11]. Proses dimulai dengan pembentukan *scale-space* dari citra menggunakan fungsi *Gaussian* [16]:

$$L(x, y, \delta) = G(x, y, z) \times I(x, y) \quad (1)$$

Di mana $G(x, y, \sigma)$ merupakan kernel *Gaussian* dengan standar deviasi σ , dan $I(x, y)$ adalah citra masukan. Selanjutnya, citra *Difference of Gaussian* (DoG) dihitung untuk mendeteksi kandidat titik fitur (*keypoint*):

$$D(x, y, \delta) = (G(x, y, k\delta) - G(x, y, \delta)) \times I(x, y) \quad (2)$$

Pada SIFT standar, pembentukan skala *Gaussian* mengikuti persamaan:

$$\delta(o, s) = \delta_0 2^{o + \frac{s}{S}} \quad (3)$$

yang menghasilkan interval skala tetap pada setiap *layer*. Namun, pendekatan ini cenderung menghasilkan sejumlah *keypoint* yang kurang stabil, terutama pada citra dengan variasi kualitas. Oleh karena itu, pada *Improved SIFT* ditambahkan *stability factor* P untuk membuat interval skala menjadi lebih adaptif, sehingga hanya fitur yang konsisten yang dipertahankan. Nilai skala pada *Improved SIFT* dirumuskan sebagai:

$$\delta(s) = \sqrt{(w^s \delta_0)^2 - (w^{s-1} \delta_0)^2} \quad (4)$$

$$P = 0.4^S + 0.9 \quad (5)$$

Penambahan faktor P ini memungkinkan pengendalian sensitivitas terhadap perubahan skala dan membantu mengurangi redundansi *keypoint*, sehingga meningkatkan stabilitas serta efisiensi proses

pencocokan fitur. SIFT menggunakan parameter standar yaitu *contrast threshold* sebesar 0.04, *edge threshold* sebesar 10, dan *sigma* sebesar 1.6. Nilai *contrast threshold* sebesar 0.04 digunakan untuk mengeliminasi *keypoint* dengan kontras rendah tanpa menghilangkan terlalu banyak fitur penting pada citra, sehingga menjaga keseimbangan antara jumlah dan kualitas *keypoint*. Nilai *edge threshold* sebesar 10 berfungsi untuk membatasi deteksi pada area tepi yang tidak stabil, sehingga mengurangi fitur yang kurang representatif. Sementara itu, nilai *sigma* sebesar 1.6 digunakan sebagai parameter Gaussian untuk menghasilkan representasi skala yang stabil tanpa mengaburkan detail penting pada citra. Selanjutnya, pada tahap deskripsi fitur, SIFT standar membagi area di sekitar *keypoint* menjadi 4×4 *subregion* dengan 8 orientasi gradien, sehingga menghasilkan deskriptor berdimensi $4 \times 4 \times 8 = 128$. Deskriptor ini cukup representatif, namun memiliki kompleksitas komputasi yang tinggi.

Oleh karena itu, pada *Improved SIFT* dilakukan penyederhanaan dengan menghilangkan empat blok sudut yang kontribusinya relatif kecil terhadap pencocokan fitur. Dengan demikian, deskriptor yang digunakan menjadi $3 \times 4 \times 8 = 96$. Dalam penelitian ini, penggunaan deskriptor 96 dimensi dibandingkan dengan deskriptor standar 128 dimensi untuk menguji efektivitasnya dalam proses pencocokan fitur. Perbandingan ini dilakukan dengan menganalisis kinerja kedua deskriptor dari sisi waktu komputasi serta kemampuan dalam merepresentasikan kecocokan fitur antar citra. Melalui pengujian tersebut, diharapkan dapat diperoleh gambaran mengenai perbedaan performa antara kedua pendekatan dalam konteks verifikasi visual sertifikat.

2.3. Validasi dengan RANSAC

Setelah proses ekstraksi fitur menggunakan *Improved SIFT*, dilakukan pencocokan fitur antara citra sertifikat uji dan citra referensi untuk memperoleh pasangan titik yang berkorespondensi [17]. Pencocokan fitur dilakukan menggunakan *Brute Force Matcher* dengan metrik jarak *Euclidean* (L_2 norm). Untuk meningkatkan kualitas pencocokan awal, digunakan *Lowe's ratio test* dengan *threshold* sebesar 0.75 untuk menyaring pasangan fitur yang ambigu. Hasil pencocokan ini selanjutnya divalidasi menggunakan RANSAC untuk memperoleh *inlier* yang konsisten secara geometris. RANSAC menggunakan model transformasi homografi dengan parameter *reprojection error threshold* sebesar 5 piksel sebagai batas toleransi kesalahan proyeksi. Parameter lain seperti jumlah iterasi maksimum (*maxIters*) dan tingkat kepercayaan menggunakan nilai default dari implementasi OpenCV, yaitu masing-masing sebesar 2000 iterasi dan 0.995 [18]. Pemilihan parameter tersebut bertujuan untuk menjaga keseimbangan antara toleransi terhadap noise dan ketepatan dalam menentukan pasangan fitur yang konsisten secara geometris. Sementara untuk nilai *threshold inlier* di tentukan untuk masing-masing data parameter dan dibahas lebih dalam di klasifikasi.

RANSAC bekerja dengan memilih sejumlah kecil pasangan titik secara acak untuk membentuk model transformasi geometris, dalam hal ini homografi. Homografi digunakan untuk merepresentasikan hubungan proyeksi antara dua bidang citra.

Untuk setiap model yang dihasilkan, seluruh pasangan titik diuji dengan menghitung *error* proyeksi:

$$Error = \frac{1}{N} \sum_{i=1}^N \|x_i - H \hat{x}_i\| \quad (6)$$

Pasangan titik dengan *error* di bawah ambang batas dikategorikan sebagai *inlier*, sedangkan sisanya sebagai *outlier*. Model terbaik dipilih berdasarkan jumlah *inlier* terbanyak, sehingga hanya fitur yang konsisten secara geometris yang digunakan pada tahap selanjutnya.

2.4. Klasifikasi Kredibilitas Sertifikat

Pada penelitian ini, label 0 merepresentasikan sertifikat yang kredibel, yaitu sertifikat yang **tidak terdeteksi** memiliki kecocokan dengan data parameter berupa logo atau stempel yang telah diidentifikasi sebagai tidak valid oleh pihak penyelenggara. Sementara itu, label 1 merepresentasikan sertifikat tidak kredibel, yaitu sertifikat yang **terdeteksi** memiliki kecocokan dengan parameter logo atau stempel tertentu. Klasifikasi dilakukan berdasarkan jumlah *inlier* hasil RANSAC pada area logo dan stempel. Suatu pasangan titik dikategorikan sebagai *inlier* apabila memenuhi kondisi [19]:

$$\|x_i - H \hat{x}_i\| < \epsilon \quad (7)$$

di mana ϵ merupakan *reprojection error threshold* yang digunakan untuk membedakan pasangan titik yang konsisten secara geometris. Pada penelitian ini digunakan nilai $\epsilon = 5$ piksel. Penggunaan *inlier* sebagai dasar klasifikasi dipilih karena pasangan fitur yang termasuk *inlier* telah melalui proses validasi geometris, sehingga lebih merepresentasikan kecocokan yang valid dibandingkan *good matches* yang masih berpotensi mengandung *false match* [20]. Sertifikat dengan kemiripan tinggi terhadap pola tidak kredibel akan menghasilkan jumlah *inlier* yang besar.

$$Label = \begin{cases} 1, \text{Tidak Kredibel,} & \text{jika } n_{inlier} \geq T_i \text{ dan } r \geq R \\ 0, \text{Kredibel,} & \text{lainnya} \end{cases}$$

dengan:

$$Label = \begin{cases} 10, & \text{untuk logo a} \\ 5, & \text{untuk logo b} \\ 6, & \text{untuk logo c} \\ 6, & \text{untuk stempel a} \\ 6, & \text{untuk stempel b} \\ 5, & \text{default} \end{cases} \quad R = 0.6$$

di mana T_i adalah *threshold* jumlah *inlier* untuk setiap parameter logo/stempel, dan r adalah rasio *inlier* terhadap jumlah pasangan fitur. Nilai *threshold* jumlah *inlier* untuk setiap parameter logo dan stempel serta rasio minimum r ditentukan secara empiris melalui serangkaian pengujian awal pada subset data. Pengujian dilakukan dengan mencoba beberapa kombinasi nilai *threshold* dan mengevaluasi kinerja sistem berdasarkan keseimbangan antara *precision* dan *recall*. Berdasarkan hasil eksperimen tersebut, diperoleh bahwa nilai *threshold inlier* yang optimal bervariasi untuk setiap parameter, yaitu sebesar 10 untuk *logo_a*, 5 untuk *logo_b*, 6 untuk *logo_c*, serta 6 untuk *stempel_a* dan *stempel_b*. Selain itu, rasio minimum kecocokan ditetapkan sebesar $r \geq 0.6$ untuk memastikan bahwa pasangan fitur yang dipertahankan memiliki konsistensi geometris yang cukup kuat. Pemilihan nilai-nilai ini didasarkan pada hasil pengujian yang menunjukkan performa terbaik dalam meminimalkan kesalahan deteksi sekaligus mempertahankan kemampuan sistem dalam mengenali pola visual yang relevan.

2.5. Evaluasi

Evaluasi kinerja sistem dilakukan menggunakan confusion matrix dengan membandingkan hasil prediksi sistem terhadap label *ground truth* [21]. Pengujian dilakukan satu kali pada seluruh dataset tanpa pembagian data latih dan uji serta tanpa proses pengulangan atau *cross-validation*, mengingat metode yang digunakan bersifat *rule-based* dan tidak melibatkan proses pembelajaran model.

Setiap citra sertifikat diproses melalui tahapan ekstraksi fitur menggunakan *Improved SIFT*, pencocokan fitur, validasi geometris menggunakan *RANSAC*, serta klasifikasi kredibilitas berdasarkan jumlah dan rasio *inlier*. Hasil prediksi yang diperoleh kemudian dibandingkan dengan label *ground truth* untuk menghitung kinerja sistem menggunakan metrik evaluasi berupa *accuracy*, *precision*, *recall*, dan *F1-score*.

Evaluasi ini bertujuan untuk mengukur kemampuan sistem dalam membedakan sertifikat kredibel dan tidak kredibel secara keseluruhan. Selain itu, analisis juga didukung dengan jumlah *inlier* hasil *RANSAC* yang merepresentasikan kekuatan kecocokan visual antara citra sertifikat dan parameter. Untuk memperkuat interpretasi hasil, dilakukan visualisasi pencocokan fitur guna melihat kesesuaian titik-titik fitur secara langsung.

3. HASIL DAN PEMBAHASAN

3.1. Hasil Ekstraksi Fitur

Pada tahap ekstraksi fitur, setiap citra sertifikat diproses menggunakan metode *Improved SIFT* untuk mendeteksi *keypoints* yang merepresentasikan karakteristik visual pada area logo dan stempel. Proses ini menghasilkan sejumlah *keypoints* beserta deskriptornya yang bersifat *invariant* terhadap

perubahan skala, rotasi, dan pencahayaan. *Improved SIFT* dalam penelitian ini juga berpengaruh pada kestabilan fitur yang dihasilkan, di mana proses penyaringan berbasis *stability factor* serta penyederhanaan deskriptor membantu mempertahankan fitur yang paling representatif dan mengurangi fitur yang kurang informatif



Gambar 3. Data Hasil Ekstraksi

Gambar 3 menunjukkan hasil ekstraksi fitur menggunakan metode *Improved SIFT* pada dua contoh citra sertifikat. Titik-titik berwarna yang tersebar pada gambar merupakan *keypoints* yang berhasil dideteksi oleh algoritma, di mana setiap titik merepresentasikan area dengan perubahan intensitas atau tekstur yang signifikan, seperti tepi huruf, garis dekoratif, logo, maupun stempel. *Keypoints* ini dihasilkan melalui proses *scale-space construction* dan *Difference of Gaussian* (DoG), kemudian disaring menggunakan *stability factor* sehingga hanya fitur yang stabil dan informatif yang dipertahankan. Pada citra pertama, terdeteksi sebanyak 4492 *keypoints*, sedangkan pada citra kedua terdeteksi sebanyak 5134 *keypoints*. Perbedaan jumlah *keypoints* ini menunjukkan bahwa citra kedua memiliki kompleksitas visual yang lebih tinggi, ditandai dengan lebih banyak detail grafis, variasi tekstur, dan elemen dekoratif dibandingkan citra pertama. Namun, jumlah *keypoints* yang terlalu banyak juga perlu dikontrol, sehingga pada *Improved SIFT* dilakukan penyaringan agar hanya fitur yang paling relevan yang digunakan pada tahap pencocokan selanjutnya.

Untuk mengevaluasi efektivitas penyederhanaan deskriptor, dilakukan perbandingan antara SIFT standar dengan deskriptor 128 dimensi dan *Improved SIFT* dengan deskriptor 96 dimensi. Pengujian dilakukan pada dataset yang sama tanpa melibatkan proses RANSAC, sehingga perbandingan yang dilakukan merefleksikan performa deskriptor secara langsung. Parameter yang dianalisis meliputi jumlah rata-rata *keypoints*, jumlah rata-rata *good matches*, akurasi klasifikasi, serta waktu komputasi.

Tabel 2. Perbandingan SIFT Standar dan *Improved SIFT*

Metode	Dimensi	Rata-rata <i>Keypoints</i>	Rata-rata <i>Good Matches</i>	Akurasi	Waktu Komputasi
SIFT Standar	128	9292.08	17.93	0.16	79.5 s
<i>Improved SIFT</i>	96	3716.43	9.09	0.47	72.8 s

Pada Tabel 2 terlihat bahwa SIFT standar menghasilkan jumlah *keypoints* yang jauh lebih banyak dengan rata-rata sebesar 9292.08 dibandingkan *Improved SIFT* yang menghasilkan rata-rata 3716.43 *keypoints*. Hal serupa juga terlihat pada jumlah *good matches*, di mana SIFT menghasilkan rata-rata 17.93 sedangkan *Improved SIFT* sebesar 9.09. Meskipun demikian, jumlah fitur yang lebih banyak tidak selalu menghasilkan kualitas pencocokan yang lebih baik. Hal ini tercermin pada hasil evaluasi, di mana SIFT standar hanya menghasilkan akurasi sebesar 0.16, sedangkan *Improved SIFT* menunjukkan performa yang lebih baik dengan akurasi sebesar 0.47. Hal ini menunjukkan bahwa jumlah *keypoints* dan *good matches* yang tinggi pada SIFT justru meningkatkan kemungkinan terjadinya *false match*, sehingga menurunkan kualitas klasifikasi. Peningkatan performa *Improved SIFT* dibandingkan SIFT standar tidak hanya disebabkan oleh berkurangnya jumlah *keypoints*, tetapi juga oleh peningkatan kualitas dan stabilitas fitur yang dihasilkan. Penyaringan berbasis *stability factor* memungkinkan sistem mempertahankan *keypoints* dengan respon yang lebih kuat dan konsisten terhadap perubahan skala, sehingga mengurangi fitur yang berasal dari *noise* atau area kurang representatif sesuai dengan penelitian sebelumnya. Selain itu, penyederhanaan deskriptor dari 128

menjadi 96 dimensi berkontribusi dalam mengurangi redundansi informasi, sehingga representasi fitur menjadi lebih ringkas namun tetap diskriminatif dalam proses pencocokan.

Secara teknis, deskriptor dengan dimensi lebih rendah cenderung meningkatkan kemampuan pemisahan antar fitur, sehingga mengurangi kemungkinan terjadinya *false match* akibat kemiripan lokal yang tidak signifikan. Hal ini sejalan dengan temuan pada penelitian sebelumnya yang menunjukkan bahwa SIFT konvensional rentan terhadap kesalahan pencocokan pada citra dengan pola visual yang mirip atau mengalami distorsi tertentu. Sebaliknya, *Improved SIFT* menghasilkan fitur yang lebih selektif dan stabil, sehingga mampu meningkatkan kualitas pencocokan citra. Dari sisi komputasi, *Improved SIFT* juga menunjukkan waktu pemrosesan yang lebih rendah dibandingkan SIFT standar, yaitu 72.8 detik dibandingkan 79.5 detik pada lingkungan pengujian yang sama.

Untuk memastikan bahwa perbedaan performa tersebut tidak terjadi secara kebetulan, dilakukan uji signifikansi menggunakan *paired t-test*. Hasil pengujian menunjukkan nilai *p-value* sebesar 2.79×10^{-14} atau 0.0000000000000279 yang lebih kecil dari batas signifikansi 0.05, sehingga dapat disimpulkan bahwa perbedaan performa antara kedua metode bersifat signifikan secara statistik. Dengan demikian, penyederhanaan deskriptor pada *Improved SIFT* menunjukkan kecenderungan menghasilkan pencocokan fitur yang lebih stabil, yang tercermin dari peningkatan akurasi serta berkurangnya pengaruh *false match* pada citra sertifikat dengan variasi kondisi visual yang tinggi.

3.2. Hasil Pencocokan Fitur *Improved SIFT* Sebelum dan Setelah RANSAC

Berdasarkan hasil pada subbab sebelumnya, analisis selanjutnya difokuskan pada penggunaan *Improved SIFT* untuk mengevaluasi kualitas pencocokan fitur dengan melibatkan proses validasi geometris menggunakan RANSAC. Pada tahap ini dilakukan analisis terhadap hasil pencocokan fitur antara citra sertifikat dan citra parameter logo atau stempel dengan membandingkan dua kondisi, yaitu sebelum dan setelah penerapan RANSAC. Pencocokan fitur sebelum RANSAC hanya mengandalkan jumlah *good matches* yang dihasilkan dari kesamaan deskriptor, sehingga masih berpotensi mengandung pasangan fitur yang tidak relevan (*mismatch*). Sementara itu, setelah penerapan RANSAC, dilakukan penyaringan lebih lanjut berdasarkan konsistensi geometris antar titik, sehingga hanya pasangan fitur yang benar-benar sesuai secara spasial (*inliers*) yang dipertahankan. Perbandingan ini bertujuan untuk menunjukkan perbedaan kualitas hasil pencocokan, di mana jumlah *good matches* mencerminkan kemiripan awal secara lokal, sedangkan jumlah *inliers* merepresentasikan kecocokan yang lebih valid dan *robust*. Dengan demikian, analisis pada subbab ini berfokus pada sejauh mana RANSAC mampu meningkatkan keandalan pencocokan fitur serta mengurangi kesalahan deteksi dalam proses verifikasi logo dan stempel pada sertifikat. Berikut di ditampilkan tabel hasil pencocokan fitur yang berisi jumlah *keypoint*, jumlah *good match*, *best parameter*, dan *ground truth* dari 10 sampel data dari total 200 data:

Tabel 3. Hasil Pencocokan Sebelum RANSAC

nama_file	num_keypoints	good_matches	best_parameter	GT
424002712-1.png	2907	13	logo_c	1
424002851-1.png	4727	8	logo_c	0
424013271-2.png	2247	9	logo_c	0
424015283-3.png	2758	6	logo_c	1
424015509-1.png	4492	9	logo_a	0
424015542-1.png	1028	14	logo_a	0
424019419-1.png	3320	10	logo_a	1
424020118-1.png	5134	10	logo_a	0
424026300-2.png	1517	14	stempel_b	1
424032068-1.png	2629	6	logo_a	0

Tabel 4. Hasil Pencocokan Sesudah RANSAC

nama_file	num_keypoints	inliers	inlier_ratio	best_parameter	GT
424002712-1.png	2907	9	0.692308	logo_c	1

424002851-1.png	4727	5	0.625000	stempel_b	0
424013271-2.png	2247	0	0.000000	None	0
424015283-3.png	2758	4	0.666667	logo_c	1
424015509-1.png	4492	6	0.666667	logo_a	0
424015542-1.png	1028	5	0.357143	logo_a	0
424019419-1.png	3320	6	0.857143	stempel_b	1
424020118-1.png	5134	5	0.500000	logo_a	0
424026300-2.png	1517	12	0.857143	stempel_b	1
424032068-1.png	2629	4	0.666667	logo_a	0


Tabel 3 dan Tabel 4 menampilkan perbandingan hasil pencocokan fitur pada 10 sampel citra sertifikat dari total 200 data, baik sebelum maupun setelah penerapan RANSAC. Pada kondisi sebelum RANSAC, ditunjukkan jumlah *good matches* yang merepresentasikan banyaknya pasangan fitur yang dianggap mirip berdasarkan kedekatan deskriptor. Namun, nilai ini belum sepenuhnya mencerminkan kecocokan yang valid, karena tidak mempertimbangkan hubungan geometris antar titik. Akibatnya, jumlah *good matches* yang tinggi tidak selalu berbanding lurus dengan label *ground truth*, sehingga mengindikasikan adanya *false match* akibat kemiripan lokal antar fitur.

Setelah penerapan RANSAC, proses pencocokan mengalami perubahan, di mana hanya pasangan fitur yang konsisten secara geometris (*inliers*) yang dipertahankan. Hal ini menunjukkan bahwa permasalahan utama pada tahap pencocokan bukan terletak pada kemampuan deskriptor dalam menemukan kemiripan lokal, melainkan pada keterbatasan metode awal dalam memvalidasi kesesuaian spasial antar fitur. Dengan kata lain, *good matches* cenderung *over-estimate* kecocokan, sedangkan *inliers* memberikan representasi kecocokan yang lebih valid dan robust.

Selain itu, penggunaan *inlier ratio* memberikan ukuran yang lebih informatif dibandingkan jumlah *good matches*, karena mampu menggambarkan proporsi kecocokan valid terhadap total pasangan fitur. Nilai rasio yang tinggi (mendekati 1) menunjukkan bahwa sebagian besar kecocokan bersifat konsisten secara geometris, sedangkan nilai rasio rendah mengindikasikan dominasi *false match*. Hal ini memperkuat bahwa validasi geometris melalui RANSAC berperan penting dalam meningkatkan kualitas pencocokan fitur, terutama pada citra dengan kompleksitas visual tinggi.

Sebagai contoh, pada citra dengan nama file 424002712-1.png, jumlah *good matches* sebanyak 13 berkurang menjadi 9 *inliers* dengan rasio sekitar 0.69, yang menunjukkan bahwa sebagian besar kecocokan awal memang valid. Sebaliknya, pada citra 424013271-2.png, meskipun memiliki *good matches*, tidak ditemukan *inliers* setelah RANSAC (rasio 0), yang mengindikasikan bahwa kecocokan awal didominasi oleh *false match* dan tidak memiliki konsistensi geometris. Kondisi ini menegaskan bahwa tanpa RANSAC, sistem cenderung menghasilkan estimasi kecocokan yang bias, sedangkan dengan RANSAC, kecocokan yang dipertahankan lebih representatif terhadap hubungan visual yang sebenarnya.


Selain dalam bentuk tabel, perbandingan hasil pencocokan fitur juga ditunjukkan melalui visualisasi antara citra sertifikat dan citra parameter, baik sebelum maupun setelah penerapan RANSAC.



Gambar 4. Visualisasi Pencocokan sebelum RANSAC

Pada Gambar 4 diatas yaitu sebelum RANSAC, garis-garis pencocokan (*matches*) terlihat lebih banyak dan tersebar, namun tidak semuanya menunjukkan hubungan yang benar karena masih terdapat pasangan fitur yang tidak konsisten secara spasial. Hal ini menyebabkan munculnya garis pencocokan yang menyimpang atau menghubungkan bagian yang tidak relevan.

Berikut juga ditampilkan perbandingan sebelum RANSAC dan sesudah RANSAC pada data sertifikat yang sama:



Gambar 5. Pencocokan Sebelum dan Sesudah RANSAC

Berdasarkan visualisasi pencocokan fitur pada gambar tersebut, terlihat perbedaan yang jelas antara hasil sebelum dan setelah penerapan RANSAC. Pada pencocokan awal, garis *matching* masih menghubungkan beberapa titik yang tidak sepenuhnya relevan, sehingga pola hubungan antar fitur tampak kurang terarah. Hal ini menunjukkan bahwa meskipun terdapat kemiripan deskriptor, tidak semua pasangan fitur merepresentasikan kesesuaian objek yang sebenarnya. Setelah diterapkan RANSAC, jumlah garis pencocokan berkurang dan hanya menyisakan pasangan titik yang konsisten secara geometris. Garis *matching* yang tersisa cenderung terfokus pada area yang benar, yaitu bagian logo dan stempel, dengan arah dan posisi yang lebih selaras. Kondisi ini mengindikasikan bahwa pencocokan yang dihasilkan setelah RANSAC memiliki tingkat keandalan yang lebih tinggi, karena mampu mengeliminasi *false match* dan mempertahankan hanya kecocokan yang valid. Dengan demikian, perbandingan ini menegaskan bahwa RANSAC tidak hanya menyaring jumlah pasangan fitur, tetapi juga meningkatkan kualitas pencocokan secara signifikan, sehingga hasilnya lebih representatif dalam proses verifikasi visual sertifikat.

3.3. Hasil Evaluasi


Pada tahap evaluasi, dilakukan analisis kinerja sistem dalam mengklasifikasikan sertifikat ke dalam kategori kredibel dan tidak kredibel dengan membandingkan hasil sebelum dan setelah penerapan RANSAC. Evaluasi ini bertujuan untuk menilai pengaruh proses penyaringan geometris terhadap akurasi dan keandalan sistem dalam mendeteksi kesesuaian logo dan stempel. Dengan membandingkan hasil prediksi terhadap data *ground truth* pada kedua kondisi, dapat diamati perbedaan performa sistem, khususnya dalam mengurangi kesalahan deteksi seperti *false match*.

Tabel 5. Hasil Kedua Prediksi Sertifikat

Kategori	GT (Aktual)	Prediksi (Tanpa RANSAC)	Prediksi (Dengan RANSAC)
0	182	84	173
1	18	116	27


Tabel 5 menunjukkan perbandingan distribusi antara data aktual (*ground truth*) dan hasil prediksi sistem sebelum dan sesudah penerapan RANSAC. Pada kondisi tanpa RANSAC, sistem menghasilkan prediksi yang tidak seimbang, di mana jumlah sertifikat yang terdeteksi sebagai kelas 1 (memiliki logo) sangat berlebih (116 dibandingkan 18 pada data aktual), yang mengindikasikan tingginya *false positive*. Kondisi ini menunjukkan bahwa proses pencocokan berbasis deskriptor saja cenderung menghasilkan estimasi kecocokan yang berlebihan (*over-estimation*), karena tidak mempertimbangkan konsistensi geometris antar fitur.

Sebaliknya, setelah diterapkan RANSAC, distribusi prediksi menjadi jauh lebih mendekati *ground truth*, dengan jumlah prediksi kelas 0 sebesar 173 (mendekati 182) dan kelas 1 sebesar 27 (lebih dekat ke 18). Perubahan ini menunjukkan bahwa validasi geometris berperan penting dalam mengoreksi bias deteksi pada tahap pencocokan awal, dengan menyaring pasangan fitur yang tidak memiliki hubungan spasial yang konsisten. Dengan kata lain, peningkatan performa tidak hanya berasal dari pengurangan jumlah kecocokan, tetapi dari peningkatan kualitas kecocokan yang dipertahankan. Setelah itu, ditampilkan *confusion matrix* dari masing-masing kondisi:



Gambar 6. *Confusion matrix* sebelum RANSAC

Confusion matrix pada Gambar 6 menunjukkan bahwa dari 182 data kelas 0, hanya 80 yang terklasifikasi benar, sementara 102 lainnya salah diklasifikasikan sebagai kelas 1. Pada kelas 1, dari 18 data, sebanyak 14 berhasil terdeteksi dengan benar dan 4 tidak terdeteksi. Pola ini menunjukkan bahwa sistem cenderung bersifat agresif dalam mendeteksi keberadaan logo (*over-detection*), sehingga menghasilkan banyak *false positive*. Secara teknis, kondisi ini disebabkan oleh banyaknya *good matches* yang dihasilkan dari kemiripan lokal antar fitur, meskipun tidak memiliki kesesuaian struktur global.



Gambar 7. *Confusion matrix* sesudah RANSAC

Setelah penerapan RANSAC, terlihat peningkatan signifikan pada klasifikasi kelas 0, di mana 168 dari 182 data berhasil diklasifikasikan dengan benar dan hanya 14 yang salah. Pada kelas 1, sebanyak 13 dari 18 data berhasil terdeteksi, sedangkan 5 tidak terdeteksi. Hal ini menunjukkan bahwa RANSAC mampu menyaring kecocokan fitur yang tidak konsisten sehingga hasil klasifikasi menjadi lebih stabil.

Secara keseluruhan, penerapan RANSAC mengurangi kesalahan klasifikasi terutama pada kelas 0 dengan menekan jumlah prediksi yang tidak tepat. Sebelum RANSAC, sistem cenderung *over-detect* terhadap kelas 1, sedangkan setelah RANSAC, distribusi prediksi menjadi lebih seimbang dan mendekati kondisi sebenarnya, sehingga hasil klasifikasi lebih representatif. Setelah ini, akan dibandingkan nilai akurasi presisi dan lainnya dari kedua kondisi tersebut:

Tabel 6. Hasil Evaluasi

Metode	Accuracy	Precision (1)	Recall (1)	F1-score (1)	TN	FP	FN	TP
Tanpa RANSAC	0.47	0.12	0.78	0.21	80	102	4	14
Dengan RANSAC	0.91	0.48	0.72	0.58	168	14	5	13

Tabel 6 menunjukkan nilai akurasi, *precision*, *recall*, *f1-score* dari kelas 1 (label 1), serta didukung oleh distribusi hasil prediksi dalam bentuk *True Negative* (TN), *False Positive* (FP), *False Negative* (FN), dan *True Positive* dari hasil *confusion matrix* sebelumnya dan menandakan penerapan RANSAC meningkatkan kinerja sistem. Tanpa RANSAC, sistem memiliki akurasi yang relatif rendah (0.47) dengan nilai *precision* pada kelas 1 yang sangat kecil (0.12), yang menandakan banyaknya prediksi positif yang tidak tepat (*false positive*), meskipun nilai *recall* pada kelas 1 cukup tinggi (0.78). Kondisi ini menunjukkan bahwa sistem cenderung *over-detect*, di mana banyak kecocokan fitur yang dianggap valid padahal tidak relevan. Hal ini dapat disebabkan oleh tingginya jumlah *keypoints* dan *good matches* yang dihasilkan, sehingga meningkatkan kemungkinan terjadinya *false match*, terutama pada area dengan pola visual yang mirip seperti ornamen sertifikat atau elemen grafis yang menyerupai logo.

Setelah menggunakan RANSAC, akurasi meningkat menjadi 0.91 yang menandakan peningkatan akurasi menunjukkan bahwa masalah utama pada pencocokan fitur sertifikat bukan semata pada ekstraksi fitur, tetapi pada validasi geometris kecocokan. Dengan kata lain, *Improved SIFT* menyediakan fitur yang lebih selektif, sedangkan RANSAC memastikan bahwa kecocokan yang dipertahankan benar-benar mewakili struktur visual yang konsisten. Namun, nilai *precision* naik menjadi 0.48, yang menunjukkan sistem masih menghasilkan *false positive*. Kondisi ini disebabkan oleh kemiripan elemen visual serta keterbatasan *threshold* berbasis *inlier* dalam merepresentasikan struktur global, yang diperparah oleh variasi kualitas citra. Akibatnya, sistem masih kesulitan membedakan pola yang sangat mirip sehingga *precision* belum optimal.

Setelah penerapan RANSAC, nilai *recall* menurun menjadi 0.72 yang menunjukkan terdapat pasangan fitur yang sebenarnya relevan namun tidak memenuhi konsistensi geometris sehingga dieliminasi. Hal ini mengindikasikan adanya *trade-off* antara kemampuan sistem dalam mendeteksi seluruh kasus (*recall*) dan ketepatan prediksi (*precision*). Dari sisi teknis, kondisi ini disebabkan oleh mekanisme RANSAC yang hanya mempertahankan pasangan fitur yang memiliki kesesuaian transformasi geometris yang kuat, sehingga beberapa kecocokan yang valid secara lokal namun tidak cukup konsisten secara global dapat terbuang. Temuan ini sejalan dengan penelitian sebelumnya [13] yang menyatakan bahwa integrasi SIFT dan RANSAC mampu meningkatkan keandalan pencocokan dengan mengurangi *outlier*, namun berpotensi menghilangkan sebagian *true match* dalam kondisi tertentu. Sementara nilai *F1-score* mengalami peningkatan yang signifikan dari 0.21 menjadi 0.58, yang menunjukkan adanya keseimbangan yang lebih baik antara *precision* dan *recall* setelah penerapan RANSAC. Hal ini mengindikasikan bahwa sistem tidak hanya menjadi lebih akurat secara keseluruhan, tetapi juga lebih stabil dalam mendeteksi sertifikat tidak kredibel. Secara praktis, peningkatan *F1-score* ini menunjukkan bahwa pendekatan yang diusulkan lebih andal untuk digunakan dalam proses verifikasi awal, karena mampu mengurangi kesalahan deteksi secara keseluruhan meskipun masih terdapat keterbatasan dalam mendeteksi seluruh kasus tidak kredibel secara sempurna.

Pada Tabel 6 juga dapat dilihat jumlah *True Negative* meningkat dari 80 menjadi 168 dan *False Positive* menurun drastis dari 102 menjadi 14. Hal ini menunjukkan bahwa RANSAC efektif dalam menyaring pasangan fitur yang tidak konsisten secara geometris, sehingga mengurangi kesalahan deteksi pada kelas kredibel. Namun demikian, terdapat sedikit peningkatan *False Negative* (dari 4

menjadi 5), yang menunjukkan bahwa sebagian kecocokan yang valid secara lokal ikut tereliminasi karena tidak memenuhi kriteria konsistensi geometris.

4. KESIMPULAN

Penelitian ini mengusulkan metode otomatis untuk verifikasi kredibilitas sertifikat prestasi dengan memanfaatkan kombinasi *Improved Scale Invariant Feature Transform (Improved SIFT)* dan *Random Sample Consensus (RANSAC)* yang berfokus pada analisis visual logo dan stempel. *Improved SIFT* mampu menghasilkan fitur yang lebih stabil dan representatif melalui penyaringan berbasis stability factor dan penyederhanaan deskriptor, sehingga meningkatkan kualitas ekstraksi fitur pada citra dengan variasi skala, rotasi, dan kualitas visual. Selanjutnya, penerapan RANSAC berperan dalam memvalidasi kecocokan fitur secara geometris dengan menyaring pasangan fitur yang tidak konsisten, sehingga mengurangi *false match* dan meningkatkan keandalan proses pencocokan.

Hasil ekstraksi fitur dalam skenario penelitian ini menunjukkan bahwa *Improved SIFT* mampu menghasilkan *keypoints* yang stabil dan representatif terhadap karakteristik visual sertifikat meskipun terdapat variasi skala, rotasi, dan kualitas citra. Pada tahap pencocokan fitur, diperoleh bahwa hasil *good matches* sebelum penerapan RANSAC masih mengandung banyak pasangan fitur yang tidak relevan, sehingga berpotensi menghasilkan kesalahan deteksi. Setelah diterapkan RANSAC, jumlah pasangan fitur berkurang menjadi *inliers* yang konsisten secara geometris, sehingga meningkatkan kualitas dan keandalan pencocokan fitur.

Hasil evaluasi pada dataset dan skenario penelitian ini menunjukkan bahwa penerapan RANSAC mampu memperbaiki distribusi prediksi sehingga lebih mendekati *ground truth* serta meningkatkan kinerja klasifikasi secara signifikan. Temuan ini menunjukkan bahwa validasi geometris merupakan komponen penting dalam verifikasi visual sertifikat berbasis fitur lokal, khususnya pada citra dengan variasi kualitas tinggi. Dengan demikian, kombinasi *Improved SIFT* dan RANSAC tidak hanya meningkatkan akurasi, tetapi juga menghasilkan sistem yang lebih stabil dan selektif dalam membedakan sertifikat kredibel dan tidak kredibel.

Secara praktis, metode yang diusulkan berpotensi untuk diimplementasikan sebagai sistem verifikasi awal dalam proses seleksi berbasis prestasi, terutama dalam membantu mengurangi kesalahan deteksi dan meningkatkan objektivitas evaluasi dokumen secara otomatis. Namun, penelitian ini masih memiliki beberapa keterbatasan, di antaranya hanya memanfaatkan fitur visual logo dan stempel tanpa mempertimbangkan informasi tekstual, serta belum mampu mendeteksi manipulasi visual tingkat lanjut seperti *copy-paste* logo dengan kemiripan tinggi atau rekayasa digital. Selain itu, penggunaan dataset yang terbatas pada satu institusi menyebabkan hasil penelitian ini belum dapat digeneralisasi secara luas. Oleh karena itu, pengembangan lebih lanjut diperlukan untuk meningkatkan ketahanan sistem terhadap manipulasi visual serta memperluas cakupan dataset agar dapat meningkatkan generalisasi metode pada berbagai kondisi.

DAFTAR PUSTAKA

- [1] A. Syukur and S. Asdiqoh, "Kepuasan Sekolah/Madrasah Terhadap Pelayanan Penerimaan Mahasiswa Baru Tingkat Nasional Pada Perguruan Tinggi Keagamaan," vol. 8, no. 2, 2025, [Online]. Available: <https://ejournal.iaifa.ac.id/index.php/dirasah>
- [2] Nur Lathifatul Sholihah, "Implementasi Aneka Jalur Seleksi Penerimaan Mahasiswa Baru Di Uin Sunan Ampel Surabaya," Universitas Islam Negeri Sunan Ampel Surabaya, Surabaya, 2018.
- [3] M. Rafi and A. Rizqi, "Analisis Dampak Sistem Seleksi Penerimaan Nasional Mahasiswa Baru Berdasarkan Prestasi Tahun 2023 dengan Kualifikasi Penjurusan Pendidikan Tinggi." [Online]. Available: <https://www.researchgate.net/publication/389694046>
- [4] N. Challa, A. Shende, and M. Mullapudi, "Enhancing Document Verification Systems: A Review of Techniques, Challenges, and Practical Implementations," *International Journal of Computer Engineering and Technology (IJCET)*, vol. 15, no. 1, pp. 16–25, 2024, doi: 10.17605/OSF.IO/HVQ8E.
- [5] C. Samuel, A. Simanjorang, and N. Erzed, "Implementasi Teknologi OCR dan Model LLM untuk Otomatisasi Pengisian Formulir Berdasarkan Dokumen Sertifikat untuk Universitas Esa Unggul Bekasi," 2025.

- [6] “Siaran Pers Nomor: 03/sipers/snpmb/II/2025 Penutupan Pendaftaran SNBP 2025 | Seleksi Nasional Penerimaan Mahasiswa Baru.” Accessed: Oct. 16, 2025. [Online]. Available: <https://www.snpmb.id/blog/siaran-pers-penutupan-pendaftaran-snpb-2025>
- [7] “UNY Terima 1.450 Mahasiswa Baru Jalur SNBP | Universitas Negeri Yogyakarta.” Accessed: Apr. 30, 2026. [Online]. Available: <https://uny.ac.id/id/berita/uny-terima-1450-mahasiswa-baru-jalur-snpb>
- [8] D. G. Lowe, “Distinctive image features from scale-invariant keypoints,” *Int. J. Comput. Vis.*, vol. 60, no. 2, pp. 91–110, Nov. 2004, doi: 10.1023/B:VISI.0000029664.99615.94/METRICS.
- [9] V. V. Bhosle and V. P. Pawar, “Automatic Logo Extraction and Detection for Document Verification using SIFT and SURF,” *International Journal of Engineering Research & Technology*, vol. 6, no. 5, May 2017, doi: 10.17577/IJERTV6IS050333.
- [10] E. Karami, M. Shehata, and A. Smith, “Image Identification Using SIFT Algorithm: Performance Analysis against Different Image Deformations,” Oct. 2017, Accessed: Sep. 03, 2025. [Online]. Available: <https://arxiv.org/pdf/1710.02728>
- [11] L. Tang, S. Ma, X. Ma, and H. You, “Research on Image Matching of Improved SIFT Algorithm Based on Stability Factor and Feature Descriptor Simplification,” *Applied Sciences* 2022, Vol. 12, Page 8448, vol. 12, no. 17, p. 8448, Aug. 2022, doi: 10.3390/APP12178448.
- [12] S. Bakheet, S. Alsubai, A. Alqahtani, and A. Binbusayyis, “Robust Fingerprint Minutiae Extraction and Matching Based on Improved SIFT Features,” *Applied Sciences* 2022, Vol. 12, Page 6122, vol. 12, no. 12, p. 6122, Jun. 2022, doi: 10.3390/APP12126122.
- [13] J. Shen, “Image Stitching Quality Evaluation and Improvement Based on SIFT Features and RANSAC Algorithm,” pp. 755–766, Oct. 2024, doi: 10.2991/978-94-6463-540-9_77.
- [14] 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/TABLE-6.
- [15] Y. Seop Yu *et al.*, “Contrast Enhancement-Based Preprocessing Process to Improve Deep Learning Object Task Performance and Results,” *Applied Sciences* 2023, Vol. 13, Page 10760, vol. 13, no. 19, p. 10760, Sep. 2023, doi: 10.3390/APP131910760.
- [16] Ernawati, D. andreswari, A. Erlansari, and F. F. Coastera, “Ekstraksi Fitur Menggunakan Scale Invariant Feature Transform untuk Klasifikasi Jenis Sampah,” *Indonesian Journal of Computer Science and Engineering*, vol. 1, no. 02, pp. 37–40, Nov. 2024, doi: 10.70656/IJCSE.V1I02.119.
- [17] Y. Liu *et al.*, “Improved Feature Point Pair Purification Algorithm Based on SIFT During Endoscope Image Stitching,” *Front. Neurobot.*, vol. 16, p. 840594, Feb. 2022, doi: 10.3389/FNBOT.2022.840594/BIBTEX.
- [18] Z. Zhang, “A flexible new technique for camera calibration,” *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 22, no. 11, pp. 1330–1334, Nov. 2000, doi: 10.1109/34.888718.
- [19] T. Wei, Y. Patel, A. Shekhovtsov, J. Matas, and D. Barath, “Generalized Differentiable RANSAC,” *Proceedings of the IEEE International Conference on Computer Vision*, pp. 17603–17614, Dec. 2022, doi: 10.1109/ICCV51070.2023.01618.
- [20] Y. Jin *et al.*, “Image Matching across Wide Baselines: From Paper to Practice,” *Int. J. Comput. Vis.*, vol. 129, no. 2, pp. 517–547, Feb. 2021, doi: 10.1007/s11263-020-01385-0.
- [21] M. A. Saputra and I. Nurhaida, “Signature Originality Verification Using A Deep Learning Approach,” *Electronic Journal of Education, Social Economics and Technology*, vol. 5, no. 1, pp. 19–29, Apr. 2024, doi: 10.33122/EJESET.V5I1.310.