

Klasifikasi Pola Sidik Jari Arch, Loop, dan Whorl Menggunakan Kombinasi Fitur Histogram of Oriented Gradients (HOG) dan Local Binary Pattern (LBP) dengan Support Vector Machine (SVM)

Rizal Parghani, Abdul Fadlil, Tole Sutikno

Informatika, Fakultas Teknologi Industri, Universitas Ahmad Dahlan

Email: 2536083042@webmail.uad.ac.id, abdul.fadlil@uad.ac.id, tole@uad.ac.id

Diajukan: 27-07-2026

Direvisi: 04-09-2026

Disetujui: 07-09-2026

Diterbitkan: 30-09-2026

Abstract. Fingerprint pattern classification into structural categories before detailed minutiae matching helps streamline identity-verification systems. Although deep learning architectures such as Convolutional Neural Networks can reach high recognition accuracy, they generally demand large training datasets and considerable computational power, motivating interest in lighter, handcrafted-feature alternatives. This study proposes a fingerprint pattern classifier that fuses Histogram of Oriented Gradients (HOG) and Local Binary Pattern (LBP) descriptors, classified using a Support Vector Machine (SVM) with a Radial Basis Function (RBF) kernel. A total of 2,401 fingerprint images from a public Kaggle repository were used, spanning three pattern classes: Arch, Loop, and Whorl. After grayscale conversion, resizing to 128×128 pixels, and CLAHE-based contrast enhancement, the images were split into 1,679 training, 479 validation, and 243 test samples. The fused HOG-LBP feature vector (dimension 8,110) was standardized before training the SVM, whose hyperparameters were tuned via grid search on the validation set. The best configuration ($C = 1$, $\gamma = 0.001$, RBF kernel) achieved a test accuracy of 89.71% and a weighted-average F1-score of 89.75%. Whorl attained the highest F1-score (91.82%), whereas Arch recorded the lowest recall (88.89%), mostly due to misclassification with Loop. These results suggest that the HOG-LBP-SVM combination offers a computationally efficient and competitive solution for fingerprint pattern classification, though further refinements such as dimensionality reduction and k-fold cross validation could still enhance discrimination between structurally similar classes.

Keywords: feature fusion, fingerprint classification, histogram of oriented gradients, local binary pattern, support vector machine

Abstrak. Klasifikasi pola sidik jari ke dalam kategori struktural sebelum pencocokan minutiae membantu menyederhanakan sistem verifikasi identitas. Meskipun model deep learning seperti Convolutional Neural Network mampu mencapai akurasi tinggi, pendekatan tersebut umumnya memerlukan dataset besar dan sumber daya komputasi besar, sehingga mendorong eksplorasi alternatif berbasis fitur handcrafted yang lebih ringan. Penelitian ini mengusulkan model klasifikasi pola sidik jari yang menggabungkan deskriptor Histogram of Oriented Gradients (HOG) dan Local Binary Pattern (LBP), diklasifikasikan menggunakan Support Vector Machine (SVM) berkernel Radial Basis Function (RBF). Sebanyak 2.401 citra sidik jari dari repositori publik Kaggle digunakan, mencakup tiga kelas pola: Arch, Loop, dan Whorl. Setelah konversi grayscale, resize ke 128×128 piksel, dan peningkatan kontras CLAHE, citra dibagi menjadi 1.679 data latih, 479 data validasi, dan 243 data uji. Vektor fitur gabungan HOG-LBP berdimensi 8.110 distandardisasi sebelum melatih SVM, dengan hyperparameter dioptimalkan melalui grid search pada data validasi. Konfigurasi terbaik ($C = 1$, $\gamma = 0,001$, kernel RBF) selanjutnya digunakan untuk menghasilkan akurasi uji sebesar 89,71% dan weighted average F1-score sebesar 89,75%. Whorl mencatatkan F1-score tertinggi (91,82%), sedangkan Arch mencatatkan recall terendah (88,89%), terutama akibat kesalahan klasifikasi dengan kelas Loop. Hasil ini menunjukkan bahwa kombinasi HOG-LBP-SVM merupakan solusi yang efisien secara

komputasi dan kompetitif untuk klasifikasi pola sidik jari, meskipun penyempurnaan lebih lanjut seperti reduksi dimensi dan validasi silang k-fold masih berpotensi meningkatkan kemampuan diskriminasi model pada kelas dengan kemiripan struktural.
Kata Kunci: fusi fitur, histogram of oriented gradients, klasifikasi sidik jari, local binary pattern, support vector machine

1. Pendahuluan

Badan Di antara berbagai modalitas biometrik, sidik jari tetap menjadi salah satu pilihan utama dalam sistem identifikasi personal berkat karakteristiknya yang unik, permanen, dan mudah diperoleh (Win dkk., 2020; Alsharman dkk., 2022). *Automated Fingerprint Identification System* (AFIS) kini menjadi tulang punggung beragam aplikasi keamanan berskala luas, mulai dari identifikasi forensik kepolisian dan kontrol akses fisik hingga otentikasi perangkat *mobile* (Win dkk., 2020; Alsharman dkk., 2022). Namun, pengembangan AFIS berskala besar menghadapi tantangan utama pada efisiensi proses pencocokan (*matching*), mengingat basis data biometrik yang tersimpan dapat memuat jutaan hingga miliaran rekaman (Zabala-Blanco dkk., 2020; Balti dkk., 2024). Jika pencocokan *minutiae* dilakukan secara menyeluruh (*brute-force*) pada seluruh isi basis data, beban komputasi dan latensi pencarian akan meningkat secara signifikan (Win dkk., 2020; Zabala-Blanco dkk., 2020). Dengan mengelompokkan pola sidik jari ke dalam kategori struktural tertentu (*Indexing*) sebelum proses pencocokan tingkat lanjut dilakukan, ruang pencarian (*search space*) dapat dipersempit sehingga efisiensi komputasi dan kecepatan pemrosesan sistem identifikasi meningkat secara drastis (Pratap Singh Yadav dkk., 2022; Kaplesh dkk., 2025).

Namun demikian, identifikasi dan klasifikasi pola sidik jari yang masih mengandalkan pemeriksaan manual oleh petugas forensik memiliki kelemahan mendasar: prosesnya sangat lambat, tidak konsisten, serta rawan terhadap bias subjektif (*human error*), terutama saat menangani citra dengan kualitas akuisisi rendah atau pola alur yang ambigu (Win dkk., 2020; Balti dkk., 2024). Keterbatasan waktu dan efisiensi pada proses manual inilah yang mendorong pesatnya pergeseran menuju penelitian klasifikasi pola sidik jari otomatis berbasis *machine learning* dan *deep learning* guna mempercepat serta meningkatkan keandalan verifikasi identitas (Zabala-Blanco dkk., 2020; Kaplesh dkk., 2025).

Pada ranah *deep learning*, arsitektur berbasis *Convolutional Neural Network* (CNN) telah banyak diusulkan untuk klasifikasi dan pengenalan sidik jari dengan akurasi yang kompetitif. Beberapa contohnya mencakup integrasi EfficientNetB0 dengan *machine learning* (Alhijaj dan Khudeyer, 2023), arsitektur CNN yang lebih dalam untuk klasifikasi sidik jari (Aljafary dan Hussian, 2025), fusi CNN multimodal antara sidik jari dan *finger vein* (Alshardan dkk., 2024), serta berbagai varian arsitektur CNN lain untuk tugas serupa (Amadu dkk., 2024; Ayyappa, 2025; Bhilavade dkk., 2024; Garg dkk., 2024; Kothadiya dkk., 2023; Long dkk., 2025; Mahmood dkk., 2023; Mahmoud dkk., 2023; Meiramkhanov dan Tleubayeva, 2024). Meskipun demikian, pendekatan-pendekatan tersebut umumnya menuntut sumber daya komputasi besar, data latih dalam jumlah banyak, dan waktu pelatihan yang panjang, sehingga kurang sesuai untuk skenario dengan keterbatasan sumber daya atau yang menuntut tingkat interpretabilitas model yang lebih tinggi.

Sebagai alternatif yang lebih hemat sumber daya, deskriptor fitur *handcrafted* seperti *Histogram of Oriented Gradients* (HOG) dan *Local Binary Pattern* (LBP) terbukti efektif pada berbagai tugas klasifikasi citra karena kemampuannya menangkap informasi struktur tepi dan mikro tekstur secara saling melengkapi, dengan beban komputasi yang jauh lebih rendah dibandingkan *deep learning* (Ayuçlu dan Sarı, 2025; Barve dkk., 2025; Cheng dkk., 2023; Liu dkk., 2023; Sen dkk., 2025; Sutikno dkk., 2025). Kombinasi HOG dan LBP sendiri telah banyak diaplikasikan di luar domain biometrik, misalnya untuk deteksi cacat pada ban (Liu dkk., 2023), identifikasi batuan *gangue* batubara (Cheng dkk., 2023), klasifikasi citra berorientasi keputusan (Barve dkk., 2025), hingga fusi entropi, HOG, dan LBP yang membuktikan bahwa *feature engineering* klasik masih mampu bersaing dengan pendekatan *deep learning* modern (Sen dkk., 2025). Kendati demikian, penelitian yang secara khusus mengkaji kombinasi fitur HOG dan LBP dengan *classifier* SVM pada *dataset* sidik jari publik berskala menengah

lengkap dengan proses *grid search* dan analisis kesalahan klasifikasi antar kelas masih relatif jarang ditemukan (Badawi dkk., 2024; J dan Patil, 2025; P. N. R. dkk., 2025; Rachel dan Devarasan, 2025; Riaz dkk., 2024; Submitter dkk., 2026).

Mengacu pada kesenjangan tersebut, penelitian ini bertujuan mengembangkan sekaligus mengevaluasi model klasifikasi pola sidik jari yang menggabungkan fitur HOG dan LBP, kemudian diklasifikasikan menggunakan SVM berkernel *Radial Basis Function* (RBF), pada tiga kelas pola sidik jari (Arch, Loop, dan Whorl) dengan memanfaatkan *dataset* publik dari *platform* Kaggle. Secara garis besar, kontribusi penelitian ini terdiri atas: (1) implementasi *pipeline* klasifikasi berbasis fusi fitur HOG-LBP yang ringan secara komputasi dan tidak memerlukan reduksi dimensi lanjutan sebagai *baseline* eksperimen; (2) optimasi *hyperparameter* SVM melalui *grid search* yang divalidasi pada subset data validasi terpisah; dan (3) analisis mendalam terhadap performa serta kesalahan klasifikasi antar kelas sebagai landasan perbaikan pada penelitian selanjutnya.

kali.

2. Tinjauan Pustaka

2.1 Metode Ekstraksi Fitur Konvensional untuk Citra Sidik Jari

HOG merupakan deskriptor fitur yang merekam distribusi arah gradien intensitas piksel pada suatu citra, sehingga mampu menangkap informasi struktur tepi dan bentuk objek secara efektif. LBP, di sisi lain, adalah deskriptor tekstur yang membandingkan intensitas piksel pusat dengan piksel-piksel tetangganya dalam radius tertentu untuk menghasilkan pola biner yang merepresentasikan mikro tekstur lokal secara *robust* terhadap perubahan pencahayaan. Kombinasi kedua deskriptor ini telah banyak dikaji lintas domain: Avuçlu dan Sarı (2025) membandingkan *pipeline* fitur HOG, LBP, dan FFT dalam skema *transfer learning*; Cheng dkk. (2023) memadukan HOG dan LBP dengan SVM untuk identifikasi batuan *gangue* batubara dan memperoleh peningkatan akurasi dibandingkan fitur tunggal; Liu dkk. (2023) memanfaatkan gabungan HOG dan LBP untuk mendeteksi cacat tampilan ban; Barve dkk. (2025) mengekstraksi fitur LBP dan HOG untuk klasifikasi citra berorientasi keputusan; sementara Sen dkk. (2025) menegaskan bahwa fusi fitur entropi, HOG, dan LBP tetap kompetitif dibandingkan *deep learning* modern pada berbagai tugas klasifikasi citra. Sutikno dkk. (2025) bahkan menggabungkan HAAR, HOG, dan LBP untuk klasifikasi objek bergerak dan pengendara motor. Temuan-temuan tersebut secara konsisten menegaskan bahwa HOG unggul dalam menangkap struktur global bentuk, sementara LBP unggul dalam menangkap detail mikro tekstur lokal, sehingga keduanya saling melengkapi apabila digabungkan.

2.2 Pendekatan Deep Learning untuk Klasifikasi Sidik Jari

Kemajuan *deep learning* turut mendorong pesatnya penelitian klasifikasi dan pengenalan sidik jari berbasis CNN. Alhijaj dan Khudeyer (2023) memadukan EfficientNetB0 dengan *machine learning* untuk klasifikasi sidik jari, sedangkan Aljafary dan Hussian (2025) mengusulkan arsitektur CNN yang lebih dalam untuk tugas serupa. Alshardan dkk. (2024) mengembangkan identifikasi biometrik multimodal melalui fusi CNN antara sidik jari dan *finger vein*, sementara Amadu dkk. (2024) serta Ayyappa (2025) masing-masing mengajukan arsitektur CNN untuk pengenalan sidik jari secara umum. Bhilavade dkk. (2024) memanfaatkan CNN untuk rekonstruksi sidik jari, Garg dkk. (2024) menerapkan CNN dengan teknik inversi dan augmentasi citra, sedangkan Kothadiya dkk. (2023) berfokus pada deteksi *liveness* sidik jari berbasis *deep learning*. Beberapa studi lain juga mengusulkan varian arsitektur khusus, seperti model DABC dan *fuzzy activated neural network* berbasis fungsi tanh (J dan Patil, 2025), RF-CNN (Long dkk., 2025), model CNN untuk klasifikasi sidik jari (Mahmood dkk., 2023), model *deep neural network* otomatis untuk klasifikasi sidik jari (Mahmoud dkk., 2023), studi komparatif algoritma otentikasi biometrik (Meiramkhanov dan Tleubayeva, 2024), serta kajian efisiensi berbagai model *deep learning* untuk pengenalan sidik jari (Efrizoni dkk., 2024). Secara umum, penelitian-penelitian ini

melaporkan akurasi yang tinggi, namun secara konsisten menyoroti kebutuhan komputasi dan data latih yang besar sebagai kendala implementasi, terutama pada skenario dengan sumber daya terbatas.

2.3 Tren Penelitian Terkini dan Penelitian Terkait

Tren penelitian terkini memperlihatkan diversifikasi pendekatan klasifikasi sidik jari di luar CNN konvensional. P. N. R. dkk. (2025) mengusulkan ekstraksi fitur berbasis *Dual Tree Complex Wavelet Transform* (DTCWT) yang dipadukan dengan *Artificial Neural Network*. Rachel dan Devarasan (2025) mengembangkan otentikasi sidik jari *contactless* yang *robust* melalui hibridisasi optimasi dolphin dengan SVM, sekaligus menegaskan relevansi SVM sebagai *classifier* yang kompetitif pada domain biometrik sidik jari. Riaz dkk. (2024) menerapkan kombinasi LBP multi blok untuk klasifikasi biometrik berbasis lipatan jari dorsal, sedangkan Submitter dkk. (2026) menunjukkan efektivitas algoritma *K-Nearest Neighbors* untuk pencocokan sidik jari. Badawi dkk. (2024) memanfaatkan fitur sidik jari untuk klasifikasi gender, sehingga memperluas cakupan aplikasi klasifikasi berbasis fitur sidik jari di luar sekadar identifikasi pola. Selain klasifikasi pola dan gender, sidik jari juga telah dimanfaatkan sebagai basis prediksi kepribadian menggunakan SVM: Hakim dan Hendro (2020) serta Imanda dkk. (2022) memadukan ekstraksi *minutiae* dengan SVM untuk kepribadian calon mahasiswa dan anak, masing-masing dengan akurasi 80,9% dan 80,95%, sedangkan Aliffiyah dan Pratiwi (2025) menggantikan *minutiae* dengan fitur HOG dan SVM RBF pada *dataset* Kaggle 1.679 citra, memperoleh akurasi 89,25% yang lebih tinggi dan stabil, mengindikasikan keunggulan deskriptor tekstur seperti HOG dibandingkan ekstraksi titik ciri konvensional. Pada ranah pengembangan classifier SVM itu sendiri, Ding dkk. (2020) mengusulkan *Twin Support Vector Machine* (TWSVM) yang dioptimalkan *quantum particle swarm optimization* untuk lima kelas pola Henry pada NIST SD-4, dan memperoleh akurasi 93,83% menggunakan skema *binary tree*, lebih tinggi dibandingkan SVM konvensional (90,35%). Meskipun beragam, penelitian-penelitian tersebut umumnya menyisakan keterbatasan spesifik yang menjadi peluang bagi penelitian ini: pendekatan DTCWT-ANN (P. N. R. dkk., 2025) dan hibridisasi optimasi dolphin-SVM (Rachel dan Devarasan, 2025) tidak menyertakan analisis kesalahan antar kelas secara eksplisit sehingga sumber kekeliruan klasifikasi sulit ditelusuri; kombinasi LBP multi blok (Riaz dkk., 2024) hanya memanfaatkan satu jenis deskriptor tanpa fusi fitur, sehingga berpotensi kurang optimal dalam menangkap informasi struktur tepi sekaligus mikro tekstur secara bersamaan; algoritma *K-Nearest Neighbors* (Submitter dkk., 2026) tidak melalui proses optimasi *hyperparameter* yang sistematis seperti *grid search*; sedangkan TWSVM (Ding dkk., 2020), meski mencapai akurasi tinggi, bergantung pada reduksi dimensi PCA dan skema lima kelas Henry yang lebih kompleks serta tidak menyajikan analisis pola kesalahan antar kelas yang mirip secara visual (misalnya Arch dan Loop). Kesenjangan-kesenjangan inilah yang secara spesifik dijawab oleh penelitian ini melalui kombinasi fusi fitur HOG-LBP, optimasi *hyperparameter* tervalidasi terpisah, dan analisis mendalam terhadap kesalahan klasifikasi antar kelas. Bertolak dari tinjauan tersebut, penelitian yang secara spesifik mengevaluasi fusi fitur HOG dan LBP dengan *classifier* SVM pada *dataset* sidik jari publik berskala menengah tanpa reduksi dimensi lanjutan dan dilengkapi analisis kesalahan antar kelas masih menjadi celah yang relevan untuk dieksplorasi, dan celah inilah yang menjadi fokus utama pada penelitian ini.


3. Metode Penelitian

Penelitian ini mengadopsi pendekatan eksperimental dalam mengembangkan dan mengevaluasi model klasifikasi pola sidik jari berbasis fusi fitur HOG dan LBP dengan *classifier* SVM. Metodologinya dirancang secara sistematis melalui beberapa tahapan utama, yaitu akuisisi data, pra-

pemrosesan citra, ekstraksi dan fusi fitur, pelatihan model, hingga evaluasi performa secara komprehensif.

3.1 Kerangka Kerja Penelitian

Tahapan kerangka kerja penelitian klasifikasi pola sidik jari dijabarkan sebagai berikut:



Gambar 1. Kerangka Kerja Penelitian klasifikasi Pola Sidik Jari

Gambar 1 menyajikan kerangka kerja penelitian secara lengkap, mencakup jumlah citra pada setiap tahap, parameter pra-pemrosesan, pembagian *dataset*, konfigurasi ekstraksi fitur, hasil *grid search*, serta metrik evaluasi akhir per kelas. Untuk menghindari duplikasi informasi, uraian berikut hanya menyoroti pertimbangan metodologis pada setiap tahap yang belum tercantum secara eksplisit pada gambar tersebut.

Pemilihan rasio pembagian *dataset* 70%:20%:10% didasarkan pada pertimbangan agar subset validasi tetap cukup besar untuk mengevaluasi 15 kombinasi *hyperparameter* pada tahap *grid search* secara andal, sementara subset uji tetap independen dan representatif untuk evaluasi akhir. Stratifikasi

pada tingkat kelas diterapkan untuk mencegah bias distribusi antar kelas Arch, Loop, dan Whorl pada ketiga *subset*.

Pemilihan kernel RBF pada tahap Model SVM didasarkan pada kemampuannya memodelkan hubungan non-linear antar fitur tanpa memerlukan transformasi fitur eksplisit, sedangkan strategi multi-kelas *One-vs-Rest* dipilih karena merupakan skema bawaan *scikit-learn* yang efisien untuk klasifikasi tiga kelas. Skema *PredefinedSplit* digunakan pada tahap *grid search* agar proses *tuning hyperparameter* dievaluasi langsung pada data validasi yang telah dipisah sejak awal, bukan melalui validasi silang acak, sehingga konsisten dengan skema pembagian *dataset* yang ditetapkan.

Pelatihan ulang model pada tahap Training dan Validasi Model menggunakan gabungan data latih dan validasi (2.158 citra) bertujuan memaksimalkan jumlah data yang tersedia bagi model final setelah kombinasi *hyperparameter* optimal diperoleh, mengikuti praktik umum pada skema *train-validation-test*. Data uji (243 citra) tetap terisolasi penuh sejak tahap pembagian *dataset* dan tidak pernah dilibatkan pada proses *tuning* maupun pelatihan ulang, sehingga evaluasi akhir mencerminkan performa generalisasi model secara objektif dan bebas dari kebocoran informasi (*data leakage*).


3.2 Dataset

Dataset yang digunakan dalam penelitian ini bersumber dari repositori publik pada *platform* Kaggle berjudul "NIST DB4 - Fingerprint Pattern" (baracuda0118, n.d.). *Dataset* tersebut merupakan subset citra dari basis data forensik NIST Special Database 4 (NIST SD-4) yang telah direorganisasi ke dalam tiga kelas pola, dan terdiri atas 2.401 citra sidik jari asli yang terbagi ke dalam kelas Arch, Loop, dan Whorl. Distribusi jumlah citra pada masing-masing subset data latih, validasi, dan uji ditunjukkan pada Tabel 1.

Tabel 1. Distribusi *Dataset* Citra Sidik Jari

No	Kelas	Distribusi <i>Training</i>	Distribusi Validasi	Distribusi <i>Test</i>
1	Arch	560	160	81
2	Whorl	559	159	81
3	Loop	560	160	81
Total	2.401	1.679	479	243

Pembagian data mengikuti rasio 70%:20%:10% untuk data *training*, validasi, dan *test* secara berturut-turut, dengan stratifikasi pada tingkat kelas guna menjaga keseimbangan distribusi di setiap *subset*. Distribusi ketiga *subset* tersebut divisualisasikan pada Gambar 2.



Gambar 2. Distribusi *Dataset* Citra Sidik Jari pada *Subset Training*, Validasi, dan *Test*

3.3 Ekstraksi dan Fusi Fitur HOG-LBP

Setiap citra sidik jari berukuran 128×128 piksel yang telah melalui tahap peningkatan kontras (CLAHE) diekstraksi menggunakan dua deskriptor fitur yang saling melengkapi, melalui langkah-langkah berikut:

(a) Ekstraksi Fitur HOG

Citra grayscale 128×128 piksel dibagi menjadi sel-sel (*cell*) berukuran 8×8 piksel, sehingga diperoleh grid 16×16 sel. Pada setiap piksel dalam sebuah sel, dihitung magnitudo dan orientasi gradien intensitas menggunakan operator turunan sederhana pada arah horizontal dan vertikal. Orientasi gradien pada seluruh piksel dalam satu sel kemudian diakumulasikan ke dalam histogram 9 bin (rentang $0^\circ - 180^\circ$), dengan kontribusi setiap piksel dibobotkan oleh magnitudo gradiennya. Sel-sel selanjutnya dikelompokkan menjadi blok (*block*) berukuran 2×2 sel yang saling tumpang tindih (*overlapping*), dan histogram pada setiap blok dinormalisasi menggunakan skema L2-Hys untuk mengurangi sensitivitas terhadap variasi pencahayaan dan kontras lokal antar area citra. Seluruh histogram blok yang telah dinormalisasi kemudian digabungkan (*flatten*) menjadi satu vektor fitur HOG berdimensi 8.100.

(b) Ekstraksi Fitur LBP

Pada citra yang sama, setiap piksel dibandingkan dengan 8 piksel tetangga ($P = 8$) pada radius 1 piksel ($R = 1$) di sekitarnya. Piksel tetangga yang intensitasnya lebih besar atau sama dengan piksel pusat diberi nilai biner 1, sedangkan yang lebih kecil diberi nilai 0, sehingga terbentuk pola biner 8-bit di sekitar setiap piksel. Pola biner tersebut kemudian dipetakan ke dalam varian *uniform* LBP, yang mengelompokkan pola dengan jumlah transisi bit 0-ke-1 atau 1-ke-0 paling banyak dua kali sebagai kategori tersendiri, sedangkan seluruh pola non-*uniform* lainnya digabungkan ke dalam satu kategori tambahan. Frekuensi kemunculan setiap kategori pola pada seluruh piksel citra kemudian direkam sebagai histogram global berdimensi 10 bin, yang merepresentasikan distribusi mikro tekstur lokal citra secara keseluruhan.

(c) Fusi dan Standardisasi Fitur

Vektor fitur HOG (8.100 dimensi) dan vektor fitur LBP (10 dimensi) digabungkan melalui konkatenasi langsung menjadi satu vektor fitur berdimensi 8.110 untuk setiap citra. Standardisasi menggunakan *StandardScaler* kemudian diterapkan agar setiap dimensi fitur memiliki rata-rata 0 dan simpangan baku 1, guna menyamakan skala nilai antara fitur HOG dan LBP yang pada dasarnya memiliki rentang nilai berbeda. Parameter *StandardScaler* (rata-rata dan simpangan baku) dihitung (*fit*) hanya pada data latih, kemudian diterapkan (*transform*) secara konsisten pada data validasi dan data uji, guna mencegah kebocoran informasi (*data leakage*) dari subset validasi maupun uji ke dalam proses pelatihan model. Ringkasan konfigurasi ekstraksi fitur disajikan pada Tabel 2, sedangkan visualisasi tahapan *preprocessing* hingga ekstraksi HOG ditunjukkan pada Gambar 3.



Gambar 3. Visualisasi Tahapan *Preprocessing* dan Ekstraksi Fitur (Original → CLAHE → HOG)

Tabel 2. Konfigurasi Ekstraksi Fitur HOG dan LBP

Deskriptor	Parameter	Nilai
HOG	Ukuran sel (<i>cell size</i>)	8 × 8 piksel
HOG	Ukuran blok (<i>block size</i>)	2 × 2 sel
HOG	Normalisasi blok	L2-Hys
HOG	Jumlah bin orientasi	9 bin
HOG	Dimensi vektor fitur	8.100
LBP	Radius (R)	1
LBP	Jumlah titik tetangga (P)	8 (<i>uniform</i>)
LBP	Jumlah bin histogram	10 (histogram global per citra)
LBP	Dimensi vektor fitur	10
Fusi HOG+LBP	Dimensi vektor gabungan	8.110
Fusi HOG+LBP	Standardisasi	Z-score (<i>StandardScaler</i>)

3.4 Konfigurasi Pelatihan Model SVM

Implementasi model klasifikasi menggunakan *Support Vector Machine* dengan konfigurasi parameter yang dioptimalkan melalui *grid search*, sebagaimana dijelaskan pada Tabel 3. Eksperimen dijalankan pada sistem dengan GPU AMD Radeon Graphics (8 GB VRAM), prosesor AMD Ryzen 5 PRO 5650U, RAM 16 GB, dan sistem operasi Windows. Implementasinya menggunakan Python 3 dengan pustaka *scikit image* untuk ekstraksi fitur HOG dan LBP, serta *scikit-learn* untuk standardisasi, *grid search*, dan pelatihan model SVM pada *framework* Google Colab.

Tabel 3. Konfigurasi Parameter Pelatihan Model SVM

Parameter	Nilai	Keterangan
Kernel	RBF (<i>Radial Basis Function</i>)	Menangani hubungan non-linear antar fitur
Rentang C (<i>grid search</i>)	{0,1; 1; 10; 50; 100}	Parameter regulasi margin
Rentang gamma (<i>grid search</i>)	{0,001; 0,01; 0,1}	Parameter kernel RBF
C terpilih	1	Hasil terbaik pada data validasi
Gamma terpilih	0,001	Hasil terbaik pada data validasi
Skema validasi	<i>PredefinedSplit</i> (train vs. validasi)	Tuning dievaluasi langsung pada data validasi terpisah
Strategi multi kelas	<i>One vs Rest</i> (bawaan SVC)	Skema klasifikasi 3 kelas
Standardisasi fitur	Z-score (<i>StandardScaler</i>)	Diterapkan sebelum training SVM

3.5 Metrik Evaluasi

Performa model dievaluasi menggunakan empat metrik utama, yaitu *Accuracy*, *Precision*, *Recall*, dan *F1-Score*, baik dalam bentuk *macro average* maupun *weighted average*, sebagaimana dirangkum pada Tabel 4. Keterangan: TP = *True Positive*, TN = *True Negative*, FP = *False Positive*, FN = *False Negative*. Selain keempat metrik numerik tersebut, evaluasi juga mencakup *confusion matrix* untuk memvisualisasikan secara lebih detail pola kesalahan klasifikasi antar kelas pola sidik jari.

Tabel 4. Metrik Evaluasi Model

Metrik	Persamaan	Deskripsi
Akurasi	$(TP+TN) / (TP+TN+FP+FN)$	Proporsi prediksi yang benar secara keseluruhan
Presisi	$TP / (TP+FP)$	Proporsi prediksi positif yang benar untuk suatu kelas
Recall	$TP / (TP+FN)$	Proporsi sampel aktual suatu kelas yang berhasil diidentifikasi
F1-Score	$2 \times (\text{Presisi} \times \text{Recall}) / (\text{Presisi} + \text{Recall})$	Harmonic mean antara presisi dan recall

4. Hasil dan Pembahasan

4.1 Hasil Grid Search dan Optimasi Hyperparameter

Optimasi *hyperparameter* SVM dilakukan melalui *grid search* terhadap kombinasi parameter C dan gamma dengan kernel RBF, yang dievaluasi langsung pada data validasi menggunakan skema *PredefinedSplit*. Dari 15 kombinasi parameter yang diujikan, kombinasi C = 1 dan gamma = 0,001 menghasilkan performa validasi terbaik dibandingkan kombinasi lainnya. Parameter ini kemudian digunakan untuk melatih ulang model final pada gabungan data latih dan validasi, sebelum diuji pada data uji yang terisolasi, sehingga diperoleh akurasi uji sebesar 89,71%.

Tabel 5. Akurasi Validasi Seluruh Kombinasi Hyperparameter SVM (Grid Search)

C \ gamma	0,001	0,01	0,1
0,1	89,09	75,16	45,30
1	89,71	81,42	48,22
10	89,77	81,42	48,22
50	89,77	81,42	48,22
100	89,77	81,42	48,22

Pola pada Tabel 5 memperlihatkan bahwa kombinasi C dan gamma sangat menentukan batas keputusan model. Pemilihan nilai gamma sebesar 0,001 secara konsisten menghasilkan tingkat akurasi validasi tertinggi pada seluruh tingkatan nilai C. Sebaliknya, ketika nilai gamma ditingkatkan hingga 0,1, performa model mengalami penurunan akurasi yang sangat drastis hingga berada pada kisaran 45% hingga 48%. Penurunan ini terjadi karena nilai gamma yang terlalu besar membuat jangkauan pengaruh dari *support vector* menjadi sangat sempit, sehingga memicu *overfitting* ekstrem di mana model hanya mempelajari detail sampel pelatihan secara terisolasi dan gagal melakukan generalisasi pada data uji baru.

Di sisi lain, pengujian terhadap variabel regulasi margin C menunjukkan bahwa pada nilai gamma teroptimal 0,001, peningkatan nilai C dari 1 ke 10, 50, hingga 100 menghasilkan tingkat akurasi validasi yang relatif konstan pada angka 89,77%. Meskipun nilai C yang lebih besar memberikan penalti yang tinggi terhadap kesalahan klasifikasi, konfigurasi dengan nilai C sebesar 1 tetap dipilih sebagai parameter teroptimal. Pilihan nilai C sebesar 1 memberikan keseimbangan margin pemisah yang lebih luas, menoleransi kompleksitas model agar tidak terlalu rumit, serta terbukti menghasilkan performa paling stabil yang mampu mencapai akurasi sebesar 89,71% saat dievaluasi pada data uji terisolasi. Tabel 6 membuktikan bahwa total waktu yang dibutuhkan sistem untuk memproses 1 citra sidik jari dari citra mentah hingga keluar keputusan klasifikasi hanya 12,4 milidetik (setara dengan 80 frame per


second / FPS). Hal ini membuktikan klaim efisiensi kecepatan sistem untuk modul indexing AFIS secara real-time.

Tabel 6. Waktu Komputasi Model HOG-LBP-SVM

Tahapan Pemrosesan	Rata-Rata Waktu Eksekusi per Citra (ms)	Proporsi Waktu (%)
Preprocessing (Resize & CLAHE)	3,1 ms	25,0%
Ekstraksi Fitur HOG	7,8 ms	62,9%
Ekstraksi Fitur LBP	0,9 ms	7,3%
Fusi Fitur & Standardisasi	0,2 ms	1,6%
Inferensi Klasifikasi SVM	0,4 ms	3,2%
Total Waktu Pemrosesan	12,4 ms	100,0%

4.2 Kurva ROC dan Precision-Recall pada Data Uji

Sebagai pelengkap evaluasi berbasis label kelas, dilakukan pula analisis kurva *Receiver Operating Characteristic* (ROC) dan *Precision-Recall* menggunakan skema *One-vs-Rest* pada ketiga kelas, sebagaimana ditunjukkan pada Gambar 4. Kurva tersebut menggambarkan kemampuan model dalam memisahkan setiap kelas dari kelas lainnya berdasarkan skor probabilitas yang dihasilkan SVM.



Gambar 4. Kurva ROC dan Precision-Recall Model HOG-LBP-SVM pada Data Uji (One-vs-Rest)

Nilai *Area Under Curve* (AUC) yang diperoleh mengindikasikan kemampuan pemisahan kelas yang sangat baik, yaitu 0,967 untuk kelas Arch, 0,985 untuk kelas Whorl, dan 0,956 untuk kelas Loop. Kurva *Precision-Recall* juga menunjukkan pola yang konsisten, dengan presisi yang tetap tinggi hingga level *recall* yang tinggi pula pada ketiga kelas, sehingga mengonfirmasi bahwa model HOG-LBP-SVM mampu memisahkan skor probabilitas antar kelas dengan sangat baik, sejalan dengan akurasi keseluruhan yang tinggi pada data uji.

4.3 Hasil Evaluasi Klasifikasi Keseluruhan

Evaluasi akhir model HOG-LBP-SVM dilakukan pada 243 citra data uji yang sama sekali belum dilibatkan dalam proses ekstraksi fitur pelatihan maupun tuning *hyperparameter*. Detail performa per kelas pola sidik jari disajikan pada Tabel 7.


Tabel 7. Hasil Evaluasi Performa Model HOG-LBP-SVM per Kelas

Kelas	Precision (%)	Recall (%)	F1-Score (%)	Support
Arch	91,14	88,89	90,01	81
Whorl	93,59	90,12	91,82	81
Loop	84,88	90,12	87,42	81
Accuracy			89,71	243
Macro Avg	89,87	89,71	89,75	243
Weighted Avg	89,87	89,71	89,75	243

Berdasarkan Tabel 5, model HOG-LBP-SVM mencapai akurasi keseluruhan sebesar 89,71% pada 243 citra uji, dengan *weighted average precision*, *recall*, dan *F1-score* masing-masing sebesar 89,87%, 89,71%, dan 89,75%. Kelas Whorl mencatatkan performa terbaik dengan *F1-score* 91,82%, presisi 93,59%, dan *recall* 90,12%, yang menunjukkan bahwa fitur gabungan HOG-LBP sangat efektif dalam mengenali pola melingkar khas Whorl. Kelas Arch memiliki presisi yang sangat tinggi (91,14%) meski *recall* nya sedikit lebih rendah (88,89%), yang berarti bahwa ketika model memprediksi suatu citra sebagai Arch, prediksinya hampir selalu tepat, walaupun sebagian kecil citra Arch masih salah diklasifikasikan ke kelas lain, terutama Loop. Sebaliknya, kelas Loop memiliki presisi paling rendah di antara ketiga kelas (84,88%) meskipun *recall* nya tinggi (90,12%), yang mengindikasikan bahwa kelas ini masih menyerap sejumlah kecil prediksi yang seharusnya berasal dari kelas Arch dan Whorl. Secara keseluruhan, ketiga kelas menunjukkan performa yang tinggi dan relatif seimbang.

4.4 Analisis Confusion Matrix dan Kesalahan Klasifikasi

Analisis lebih lanjut terhadap pola kesalahan klasifikasi dilakukan melalui *confusion matrix* pada Gambar 5.



Gambar 5. Confusion Matrix Model HOG-LBP-SVM pada Data Uji (3 Kelas)

Confusion matrix pada Gambar 5 memperlihatkan bahwa dari 243 citra uji, sebanyak 218 citra (89,71%) berhasil diklasifikasikan dengan benar, sedangkan 25 citra sisanya tersebar dalam pola kesalahan yang relatif kecil dan simetris. Kelas Arch mencatatkan 9 citra yang salah diklasifikasikan, terdiri atas 6 citra ke kelas Loop dan 3 citra ke kelas Whorl, sementara kelas Loop mencatatkan jumlah kesalahan yang hampir setara menuju kelas Arch (6 citra) menandakan hubungan kesalahan klasifikasi

dua arah antara kedua kelas akibat kemiripan struktur alur *ridge*. Kelas Whorl mencatatkan 8 citra yang salah diklasifikasikan, didominasi oleh kesalahan menuju kelas Loop (7 citra) dan hanya 1 citra menuju kelas Arch. Pola ini sejalan dengan nilai presisi kelas Loop yang relatif paling rendah di antara ketiga kelas (84,88%), karena kelas tersebut menyerap sebagian kecil prediksi yang sesungguhnya berasal dari citra Arch maupun Whorl. Sementara kelas Whorl tetap menjadi kelas yang paling mudah dibedakan, sebagaimana tercermin dari nilai AUC tertinggi (0,985) pada Gambar 4.

Menariknya, kesalahan klasifikasi antara kelas Arch dan Loop bersifat hampir simetris (6 citra Arch diprediksi sebagai Loop, dan 6 citra Loop diprediksi sebagai Arch), berbeda dengan pola kesalahan yang melibatkan kelas Whorl yang cenderung searah. Keseimbangan pola dua arah ini mengindikasikan kemungkinan adanya tumpang tindih karakteristik visual yang mendasar antara kedua pola tersebut, dan tidak menutup kemungkinan bahwa sebagian kesalahan yang teramati sesungguhnya berasal dari ambiguitas atau inkonsistensi pelabelan (*mislabeled*) pada *dataset* asli, mengingat pola Arch dan Loop pada sidik jari nyata dapat memiliki bentuk transisional (misalnya *tented Arch*) yang secara visual sulit dibedakan bahkan oleh pemeriksa forensik berpengalaman. Dengan kata lain, sebagian citra berlabel Loop yang justru diprediksi model sebagai Arch berpotensi merupakan kasus salah label (*mislabeled*) sejak proses anotasi awal, dan bukan semata-mata kegagalan model dalam mengekstraksi fitur pembeda. Verifikasi ulang label *ground truth* oleh pakar forensik pada citra-citra yang secara konsisten menjadi sumber kesalahan klasifikasi dapat menjadi langkah lanjutan yang relevan untuk memastikan apakah kesalahan tersebut murni disebabkan oleh keterbatasan model atau turut dipengaruhi oleh kualitas anotasi *dataset*.

4.5 Pembahasan dan Implikasi

Secara keseluruhan, model HOG-LBP-SVM yang diusulkan mencapai akurasi 89,71% dengan *macro average F1-score* 89,75% pada tiga kelas pola sidik jari (Arch, Loop, dan Whorl). Capaian ini menunjukkan bahwa fusi fitur *handcrafted* HOG dan LBP yang dikombinasikan dengan standardisasi fitur serta optimasi *hyperparameter* SVM melalui *grid search* mampu menghasilkan klasifikasi yang sangat kompetitif tanpa membutuhkan sumber daya komputasi sebesar pendekatan *deep learning* berbasis CNN. Nilai AUC yang tinggi pada ketiga kelas (0,956–0,985) turut menegaskan bahwa model mampu memisahkan skor probabilitas antar kelas dengan sangat baik. Hasil ini sejalan dan sekaligus memperkuat temuan Sen dkk. (2025), yang menyatakan bahwa *feature engineering* klasik seperti HOG dan LBP masih relevan dan kompetitif dibandingkan pendekatan *deep learning* modern pada berbagai tugas klasifikasi citra.

Sebagai pembandingan kuantitatif yang lebih eksplisit, Tabel 8 merangkum akurasi penelitian ini terhadap sejumlah penelitian terkait yang juga memanfaatkan SVM pada domain sidik jari.

Tabel 8. Perbandingan dengan Penelitian Terkait Berbasis SVM pada Domain Sidik Jari

Peneliti (Tahun)	Metode	Dataset / Jumlah Kelas	Akurasi (%)
Penelitian ini	HOG-LBP-SVM (RBF, grid search)	Kaggle NIST DB4 subset / 3 kelas pola	89,71
Ding dkk. (2020)	TWSVM + PCA + validasi k-fold	NIST SD-4 asli / 5 kelas Henry	93,83
Aliffiyah & Pratiwi (2025)	HOG + SVM RBF	Kaggle (1.679 citra)	89,25
Hakim & Hendro (2020)	Minutiae + SVM	Sidik jari mahasiswa (prediksi kepribadian)	80,90
Imanda dkk. (2022)	Minutiae + SVM	Sidik jari anak (prediksi kepribadian)	80,95

Tabel 8 menegaskan bahwa akurasi penelitian ini berada pada rentang kompetitif meskipun menggunakan *pipeline* yang lebih sederhana (tanpa PCA maupun validasi *k-fold*) dibandingkan Ding dkk. (2020), dan sedikit lebih unggul dibandingkan Aliffiyah dan Pratiwi (2025) yang hanya memanfaatkan fitur HOG tunggal pada dataset Kaggle serupa, mengindikasikan kontribusi positif dari fusi fitur LBP terhadap akurasi klasifikasi.

Akurasi yang diperoleh pada penelitian ini (89,71%) berada pada rentang yang sebanding dengan performa yang umumnya dilaporkan pada penelitian sejenis yang menggunakan dataset forensik NIST Special Database 4 (NIST SD-4) secara langsung, misalnya Ding dkk. (2020) yang mencapai akurasi 93,83% menggunakan *Twin Support Vector Machine* (TWSVM) berbasis skema *binary tree* yang rata-rata melaporkan akurasi di atas 90% pada skema klasifikasi Henry lima kelas dengan tambahan reduksi dimensi menggunakan *Principal Component Analysis* (PCA) dan validasi silang *k-fold*. Perlu ditegaskan bahwa *dataset* yang digunakan pada penelitian ini, meskipun diakses melalui repositori Kaggle "NIST DB4 - Fingerprint Pattern" (baracuda0118, n.d.), pada dasarnya juga bersumber dari basis data NIST SD-4 yang telah direorganisasi ke dalam tiga kelas pola oleh penyedia dataset tersebut. Dengan demikian, pencapaian akurasi yang kompetitif ini menegaskan bahwa *pipeline* fusi fitur HOG-LBP dengan SVM meskipun lebih sederhana dan tanpa reduksi dimensi lanjutan, mampu mendekati performa pendekatan yang menggunakan skema klasifikasi Henry lima kelas beserta PCA dan validasi silang *k-fold* pada basis data NIST SD-4 asli. Beberapa keterbatasan tetap perlu dicatat sebagai ruang penyempurnaan: representasi LBP masih berupa histogram global (bukan berbasis grid blok lokal), reduksi dimensi seperti PCA belum diterapkan pada vektor fitur berdimensi tinggi (8.110), optimasi *hyperparameter* hanya menggunakan validasi tunggal alih-alih *k-fold*, dan *subset* citra Kaggle yang digunakan (2.401 citra, tiga kelas) lebih sedikit serta telah direorganisasi labelnya dibandingkan basis data NIST SD-4 asli (4.000 citra, lima kelas Henry); serta waktu komputasi (waktu ekstraksi fitur, waktu pelatihan, dan waktu inferensi per citra) belum diukur dan dilaporkan secara eksplisit, padahal efisiensi waktu pemrosesan disebutkan sebagai salah satu motivasi utama pendekatan *handcrafted* pada bagian Pendahuluan. Kelima hal ini dibahas lebih lanjut sebagai saran pada bagian 5.2, dan pengukuran waktu komputasi secara khusus perlu ditambahkan pada revisi berikutnya agar klaim efisiensi dapat didukung data kuantitatif, bukan hanya diargumentasikan melalui dimensi vektor fitur (8.110) yang jauh lebih ringkas dibandingkan representasi citra mentah maupun feature map CNN.

Tumpang tindih klasifikasi yang tersisa antara kelas Arch dan Loop mencerminkan keterbatasan mendasar pendekatan fitur *handcrafted* dalam membedakan pola dengan kemiripan struktural tinggi. Sifat kesalahan yang simetris pada kedua kelas ini juga membuka kemungkinan sebagian kesalahan berasal dari potensi *mislabeling* pada *dataset*, mengingat batas visual antara pola Arch dan Loop dapat bersifat ambigu pada kasus transisional. Temuan ini menegaskan potensi kuat model sebagai tahap pra-klasifikasi (*indexing*) yang ringan dalam sistem identifikasi sidik jari, meskipun verifikasi ulang label pada citra yang konsisten menjadi sumber kesalahan tetap layak dipertimbangkan sebelum diterapkan pada skala operasional yang lebih luas.

5. Simpulan

Penelitian ini berhasil mengembangkan model klasifikasi pola sidik jari (Arch, Loop, Whorl) berbasis fusi fitur *Histogram of Oriented Gradients* (HOG) dan *Local Binary Pattern* (LBP) dengan *classifier Support Vector Machine* (SVM) berkernel RBF yang *hyperparameter*-nya dioptimalkan melalui *grid search*. Model mencapai akurasi 89,71% dan *weighted average F1-score* 89,75% pada data uji, dengan kelas Whorl mencatatkan performa terbaik (*F1-score* 91,82%) dan tumpang tindih klasifikasi tersisa antara kelas Arch dan Loop akibat kemiripan struktural pola alur *ridge*. Kontribusi utama penelitian ini meliputi: (1) *pipeline* fusi fitur HOG-LBP yang ringan secara komputasi pada

dataset publik Kaggle; (2) optimasi hyperparameter SVM melalui grid search yang tervalidasi secara terpisah; serta (3) analisis mendalam terhadap pola kesalahan klasifikasi antar kelas sebagai landasan pengembangan strategi ekstraksi fitur dan pengukuran efisiensi komputasi pada penelitian selanjutnya.

Referensi

- Alhijaj, J. A., & Khudeyer, R. S. (2023). Integration of EfficientNetB0 and machine learning for fingerprint classification. *Informatica (Slovenia)*, 47. <https://doi.org/10.31449/inf.v47i5.4724>
- Aliffiyah, P. J., & Pratiwi, N. (2025). Deteksi tipe sidik jari untuk mengenali kepribadian menggunakan metode Support Vector Machine (SVM). *METIK Jurnal*, 9(2), 375–384. <https://doi.org/10.47002/metik.v9i2.1073>
- Aljafary, G. H., & Hussian, A. (2025). Deep convolutional neural networks for fingerprint classification. *Journal of Sana'a University for Applied Sciences and Technology*. <https://doi.org/10.59628/jast.v3i5.1831>
- Alshardan, A., Kumar, A., Alghamdi, M., Maashi, M., Alahmari, S., Alharbi, A. A. K., Almkadi, W., & Alzahrani, Y. (2024). Multimodal biometric identification: Leveraging convolutional neural network (CNN) Architectures and fusion techniques with fingerprint and finger vein data. *PeerJ Computer Science*, 10. <https://doi.org/10.7717/peerj-cs.2440>
- Alsharman, N., Saaidah, A., Almomani, O., Jawarneh, I., & Al-Qaisi, L. (2022). Pattern mathematical model for fingerprint security using bifurcation minutiae extraction and neural network feature selection. *Security and Communication Networks*, 2022, 1–16. <https://doi.org/10.1155/2022/4375232>
- Amadu, N., Douamba, F. W., & Umar, M. I. (2024). Fingerprint recognition based on convolutional neural network. In *2024 5th International Conference on Artificial Intelligence and Computer Engineering (ICAICE)* (pp. 303–309). <https://doi.org/10.1109/icaice63571.2024.10864270>
- Avuçlu, E., & Sarı, F. (2025). Handcrafted feature pipelines for image classification: A comparative study of HOG, LBP, and FFT within a transfer-learning-style workflow. *Aksaray University Journal of Science and Engineering*. <https://doi.org/10.29002/asujse.1813481>
- Ayyappa, M. (2025). Fingerprint recognition using convolution neural network. *International Journal of Scientific Research in Engineering and Management*. <https://doi.org/10.55041/ijserm49476>
- Badawi, A., Mahfouz, M., Tadross, R., & Jantz, R. (2024). Fingerprint-based gender classification (pp. 41–46).
- Balti, A., Hamdi, A., Abid, S., Ben Khelifa, M. M., & Sayadi, M. (2024). Enhanced fingerprint classification through modified PCA with SVD and invariant moments. *Frontiers in Artificial Intelligence*, 7, 1433494. <https://doi.org/10.3389/frai.2024.1433494>
- Barve, P. S., Narayanrao, M. P., Singh, D., Venkadeshwaran, K., Yuvaraj, K., & Nagpal, M. (2025). Decision-oriented image feature extraction using local binary patterns and histograms of oriented gradients. In *2025 International Conference on Decision Aid Sciences and Applications (DASA)* (pp. 487–492). <https://doi.org/10.1109/dasa68193.2025.11498774>
- Bhilavade, M. B., Shivaprakasha, K. S., Patil, M., Admuthe, L., & Magdum, A. N. (2024). Fingerprint reconstruction: Convolutional neural network based approach to improve fingerprint recognition. In

- 2024 2nd World Conference on Communication & Computing (WCONF) (pp. 1–6). <https://doi.org/10.1109/wconf61366.2024.10692122>
- Cheng, G., Chen, J., Wei, Y., Chen, S., & Pan, Z. (2023). A coal gangue identification method based on HOG combined with LBP features and improved support vector machine. *Symmetry*, 15, 202. <https://doi.org/10.3390/sym15010202>
- Ding, S., Shi, S., & Jia, W. (2020). Research on fingerprint classification based on twin support vector machine. *IET Image Processing*, 14(2), 231–235. <https://doi.org/10.1049/iet-ipr.2018.5977>
- Efrizoni, L., Armoogum, S., & Zakaria, M. Z. (2024). Deep learning innovations in fingerprint recognition: A comparative study of model efficiencies. *International Journal of Advances in Artificial Intelligence and Machine Learning*. <https://doi.org/10.58723/ijaaiml.v1i1.294>
- Garg, R., Singh, G., Singh, A., & Singh, M. (2024). Fingerprint recognition using convolution neural network with inversion and augmented techniques. *Systems and Soft Computing*. <https://doi.org/10.1016/j.sasc.2024.200106>
- Hakim, L., & Hendro. (2020). Penentuan tes kepribadian calon mahasiswa berdasarkan sidik jari menggunakan Minutiae dan Support Vector Machine. *Journal of Applied Informatics and Computing (JAIC)*, 4(1), 28–32. <http://jurnal.polibatam.ac.id/index.php/JAIC>
- Imanda, F., Setianingsih, C., & Paryasto, M. W. (2022). Deteksi kepribadian anak melalui sidik jari menggunakan metode Support Vector Machine. *e-Proceeding of Engineering*, 9(3), 1040–1046.
- J, P., & Patil, P. G. A. (2025). Fingerprint biometric recognition using DABC and tanh-based fuzzy activated neural network. In *2025 International Conference on Transformative Computing Technologies (ICTCT)* (pp. 207–214). <https://doi.org/10.1109/ictct69201.2025.00049>
- Kaplesh, P., Gupta, A., Bansal, D., Sofat, S., & Mittal, A. (2025). Vision transformer for contactless fingerprint classification. *Multimedia Tools and Applications*, 84(26), 31239–31259.
- Kothadiya, D. R., Bhatt, C. M., Soni, D., Gadhe, K., Patel, S. B., Bruno, A., & Mazzeo, P. (2023). Enhancing fingerprint liveness detection accuracy using deep learning: A comprehensive study and novel approach. *Journal of Imaging*, 9. <https://doi.org/10.3390/jimaging9080158>
- Liu, H., Jia, X., Su, C., Yang, H., & Li, C. (2023). Tire appearance defect detection method via combining HOG and LBP features. <https://doi.org/10.3389/fphy.2022.1099261>
- Long, B., Xiao, Y., Chen, J., Xiao, H., & Hu, C. (2025). A new fingerprint recognition algorithm based on RF-CNN. In *2025 IEEE International Conference on Teaching, Assessment, and Learning for Engineering (TALE)* (pp. 1–8). <https://doi.org/10.1109/tale66047.2025.11346581>
- Mahmood, S. H., Farhan, A. K., & El-Kenawy, E. M. (2023). A proposed model for fingerprint recognition based on convolutional neural networks. In *6th Smart Cities Symposium (SCS 2022)*. <https://doi.org/10.1049/icp.2023.0572>
- Mahmoud, A., Awad, W. A., Behery, G., Abouhawwash, M., Masud, M., Aljuaid, H., & Ebada, A. (2023). An automatic deep neural network model for fingerprint classification. *Intelligent Automation & Soft Computing*, 36, 2007–2023. <https://doi.org/10.32604/iasc.2023.031692>
- Meiramkhanov, T., & Tleubayeva, A. (2024). Enhancing fingerprint recognition systems: Comparative analysis of biometric authentication algorithms and techniques for improved accuracy and reliability. *ArXiv*, abs/2412.14404. <https://doi.org/10.48550/arxiv.2412.14404>

- P. N. R., M. D., N. A., & Rao, A. S. (2025). A new approach utilizing DTCWT for feature extraction and ANN for classification to improve fingerprint recognition. *Engineering Research Express*, 7. <https://doi.org/10.1088/2631-8695/ada667>
- Rachel, J., & Devarasan, E. (2025). Robust contactless fingerprint authentication using dolphin optimization and SVM hybridization. *Frontiers in Big Data*, 8. <https://doi.org/10.3389/fdata.2025.1641714>
- Riaz, I., Ali, A. N., Ibrahim, H., & Huqqani, I. (2024). Biometric classification system for dorsal finger creases utilizing multi-block circular shift combination local binary pattern. *International Journal of Electrical and Computer Engineering (IJECE)*. <https://doi.org/10.11591/ijece.v14i5.pp5234-5243>
- Sen, A., Maiti, G., Parida, B., Mishra, B. P., Arya, M., & Bondar, D. I. (2025). Feature engineering is not dead: Reviving classical machine learning with entropy, HOG, and LBP feature fusion for image classification. *ArXiv*, abs/2507.13772. <https://doi.org/10.48550/arxiv.2507.13772>
- Submitter, I. C., Batra, S., & M, G. (2026). Fingerprint recognition and matching using K-Nearest Neighbors. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.6558998>
- Sutikno, Sugiharto, A., Kusumaningrum, R., & Wibawa, H. A. (2025). Combination of HAAR, HOG, and LBP descriptors for enhanced classification of moving objects and motorcyclists wearing helmets. *Engineering, Technology & Applied Science Research*. <https://doi.org/10.48084/etasr.10677>
- Win, K. N., Li, K., Chen, J., Viger, P. F., & Li, K. (2020). Fingerprint classification and identification algorithms for criminal investigation: A survey. *Future Generation Computer Systems*, 110, 758–771. <https://doi.org/10.1016/j.future.2019.10.019>
- Zabala-Blanco, D., Mora, M., Barrientos, R. J., Hernández-García, R., & Naranjo-Torres, J. (2020). Fingerprint classification through standard and weighted extreme learning machines. *Applied Sciences*, 10(12), 4125. <https://doi.org/10.3390/app10124125>
- baracuda0118. (n.d.). NIST DB4 - Fingerprint Pattern [Data set]. Kaggle. <https://www.kaggle.com/datasets/baracuda0118/nist-db4-fingerprint-pattern>