

KLASIFIKASI RAS WAJAH BERBASIS EMBEDDING FACENET DAN SUPPORT VECTOR MACHINE

Deliana Putri Maharani¹, Muntahanah²

1,2) Prodi Teknik Informatika, Fakultas Teknik, Universitas Muhammadiyah Bengkulu, Indonesia

Article Info

Article history:

Received: 21 Mei 2026

Revised: 06 Mei 2026

Accepted: 03 Juni 2026

ABSTRACT

Abstrak

Klasifikasi ras wajah merupakan salah satu permasalahan dalam bidang pengenalan pola citra yang memiliki potensi penerapan luas, mulai dari sistem verifikasi identitas hingga analisis demografis melalui data visual. Keterbatasan metode konvensional seperti PCA dan LBP dalam menangani variasi citra wajah mendorong pengembangan pendekatan yang lebih optimal. Penelitian ini bertujuan membangun sistem klasifikasi ras wajah menggunakan kombinasi model FaceNet sebagai ekstraktor fitur dan Support Vector Machine (SVM) sebagai pengklasifikasi. Dataset FairFace digunakan dengan empat kategori ras, yaitu Black, East Asian, Indian, dan White, dengan total 2.800 citra yang terbagi menjadi 2.400 data latih dan 400 data validasi secara seimbang. Model FaceNet berbasis InceptionResNetV1 pretrained menghasilkan embedding wajah berdimensi 512, yang selanjutnya diklasifikasikan menggunakan SVM berkonfigurasi kernel RBF. Hasil evaluasi menunjukkan akurasi validasi sebesar 88,75% dengan macro average F1-score 0,8875. Kelas East Asian mencatat performa tertinggi (F1-score 0,9500) sedangkan kelas Indian memperoleh nilai terendah (0,8200). Pendekatan ini memanfaatkan representasi pretrained sehingga dapat diterapkan pada kondisi data terbatas tanpa memerlukan pelatihan model dari awal.

Kata Kunci: FaceNet, Support Vector Machine, Klasifikasi Ras Wajah, Embedding Wajah, Transfer Learning

Abstract

Facial race classification is a pattern recognition problem with broad application potential, ranging from identity verification systems to visual-based demographic analysis. The limitations of conventional methods such as PCA and LBP in handling complex facial image variations encourage the development of more robust approaches. This study aims to build a facial race classification system using a combination of FaceNet as a feature extractor and Support Vector Machine (SVM) as a classifier. The FairFace dataset is used, covering four racial categories Black, East Asian, Indian, and White with a total of 2,800 images divided into 2,400 training samples and 400 validation samples in a balanced distribution. The FaceNet model based on pretrained InceptionResNetV1 generates 512-dimensional face embeddings, which are then classified using an SVM with RBF kernel configuration. Evaluation results show a validation accuracy of 88.75% with a macro average F1-score of 0.8875. The East Asian class records the highest performance (F1-score 0.9500) while the Indian class yields the lowest (0.8200). This approach leverages pretrained facial representations without requiring model training from scratch, making it suitable for limited-data scenarios.

Keywords: FaceNet, Support Vector Machine, Facial Race Classification, Face Embedding, Transfer Learning

Djtechno: Jurnal Teknologi Informasi oleh Universitas Dharmawangsa Artikel ini bersifat open access yang didistribusikan di bawah syarat dan ketentuan dengan Lisensi Internasional Creative Commons Attribution NonCommercial ShareAlike 4.0 ([CC-BY-NC-SA](https://creativecommons.org/licenses/by-nc-sa/4.0/)).



1. PENDAHULUAN

Wajah manusia merupakan salah satu modalitas biometrik yang memiliki keunikan tinggi dan dapat dimanfaatkan untuk mengidentifikasi berbagai karakteristik individu, termasuk informasi demografis seperti ras. Dalam ranah pengenalan pola berbasis citra, klasifikasi ras wajah menjadi topik yang semakin penting seiring dengan pesatnya perkembangan teknologi kecerdasan buatan dan pengolahan citra digital. Teknologi ini memiliki potensi penerapan yang luas, mulai dari sistem keamanan publik, proses verifikasi identitas, hingga penelitian di bidang biomedis dan sosiologi komputasional. Wajah manusia menyimpan berbagai atribut visual yang dapat dibedakan, seperti warna kulit, struktur tulang wajah, bentuk mata, serta proporsi fitur wajah yang secara umum menunjukkan variasi antar kelompok ras [1].

Identifikasi ras wajah berbasis citra digital bukan merupakan permasalahan yang sederhana. Meskipun fitur visual wajah dapat diamati secara langsung, terdapat berbagai tantangan dalam proses ekstraksi fitur, seperti perbedaan kondisi pencahayaan, variasi sudut pengambilan gambar, kualitas resolusi citra, serta perbedaan ekspresi wajah. Selain itu, beberapa kelompok ras memiliki kemiripan karakteristik visual yang cukup tinggi sehingga menyulitkan proses pembedaan jika hanya mengandalkan representasi piksel mentah. Metode klasifikasi berbasis fitur sederhana seperti warna atau tekstur sering kali menghasilkan performa yang kurang optimal karena tidak mampu menangkap informasi wajah secara lebih mendalam dan komprehensif [2]. Teknik ekstraksi fitur tradisional seperti *Principal Component Analysis* (PCA) dan *Local Binary Patterns* (LBP) juga memiliki keterbatasan ketika dihadapkan pada variasi data wajah yang kompleks dan beragam.

Dalam mengatasi permasalahan tersebut, metode berbasis pembelajaran mesin dan pembelajaran mendalam (*deep learning*) telah menunjukkan kinerja yang lebih baik. Berbagai algoritma telah digunakan secara luas dalam klasifikasi citra wajah, seperti *Convolutional Neural Network* (CNN), *K-Nearest Neighbor* (K-NN), *Random Forest*, *Decision Tree*, *Logistic Regression*, serta *Support Vector Machine* (SVM). Masing-masing metode memiliki karakteristik, kelebihan, dan keterbatasan masing-masing dalam menangani permasalahan klasifikasi berbasis citra wajah [3]. Model *deep learning end-*

to-end seperti CNN umumnya membutuhkan jumlah data pelatihan yang sangat besar agar dapat menghasilkan performa optimal. Oleh karena itu, penelitian ini menggunakan kombinasi FaceNet sebagai ekstraktor fitur wajah dan SVM sebagai algoritma klasifikasi. FaceNet merupakan model berbasis *deep learning* yang mampu merepresentasikan citra wajah ke dalam bentuk vektor *embedding* berdimensi tinggi yang memuat karakteristik penting wajah [1]. Kombinasi metode tersebut dinilai lebih praktis untuk diterapkan pada kondisi data terbatas tanpa memerlukan pelatihan model dari awal [4].

Penerapan *deep learning* dalam kehidupan nyata telah berkembang pesat, salah satunya pada sistem absensi berbasis pengenalan wajah. Wahyuni dan Sulaeman (2022) mengimplementasikan algoritma *deep learning* untuk sistem absensi kehadiran pegawai berbasis deteksi wajah dan membuktikan efektivitasnya dalam kondisi operasional nyata [5]. Siswanti et al. (2025) mengembangkan sistem deteksi wajah tersamar menggunakan VGGFace dan SVM yang mampu mengenali wajah dengan akurasi tinggi meskipun terdapat gangguan penutupan [6]. Sementara itu, Akbar et al. (2024) menunjukkan bahwa CNN mampu mengklasifikasikan ekspresi wajah dengan performa yang kompetitif, memperkuat posisi *deep learning* sebagai solusi unggulan dalam pengenalan pola berbasis citra wajah [7].


Sejumlah penelitian terdahulu telah mengeksplorasi penggunaan FaceNet dan strategi berbasis *embedding* dalam konteks klasifikasi wajah. Pratama dan Ningrum (2025) menerapkan kombinasi MTCNN, InceptionResNetV1, dan SVM dalam sistem pengenalan wajah dengan akurasi tinggi meskipun pada kondisi citra yang bervariasi [2]. Satriawan dan Widhiarso (2023) menggunakan CNN untuk pengenalan jenis kelamin wajah dan memperoleh akurasi 92% [3]. Meldyantono dan Poetro (2025) mengimplementasikan FaceNet dalam sistem absensi berbasis pengenalan wajah dan membuktikan keunggulan model tersebut dalam kondisi variasi pencahayaan dan pose [8]. Berdasarkan kajian tersebut, penelitian ini mengembangkan kerangka serupa yang diterapkan pada permasalahan klasifikasi ras wajah menggunakan dataset FairFace dengan empat kategori ras: *Black*, *East Asian*, *Indian*, dan *White*.

Tujuan penelitian ini adalah membangun sistem klasifikasi ras wajah yang efektif menggunakan *pipeline* FaceNet-SVM, mengevaluasi kinerja model pada 400 data validasi dari dataset FairFace yang terdiri atas 2.800 citra dengan distribusi seimbang, serta menganalisis sejauh mana representasi *embedding* FaceNet mampu mendukung proses

klasifikasi ras secara akurat. Penelitian ini diharapkan berkontribusi pada pengembangan sistem pengenalan wajah berbasis karakteristik visual, khususnya dalam klasifikasi demografis ras [4].

2. METODE PENELITIAN

Penelitian ini dirancang menggunakan metode berbasis pengolahan citra digital dengan memanfaatkan model pembelajaran mendalam sebagai ekstraktor fitur dan algoritma klasifikasi mesin untuk pengenalan ras wajah. Alur penelitian terdiri atas enam tahapan utama: akuisisi data, deteksi dan *cropping* wajah, praproses data, ekstraksi fitur menggunakan FaceNet, pelatihan model SVM, dan evaluasi model. Gambaran umum alur penelitian disajikan pada Gambar 1.



Gambar 1. Alur Penelitian Klasifikasi Ras Wajah Menggunakan FaceNet dan SVM

Berdasarkan Gambar 1 dapat dilihat bahwa alur penelitian terdiri atas enam tahapan berurutan mulai dari akuisisi data, praproses, ekstraksi fitur FaceNet, pelatihan model SVM, hingga evaluasi model yang menghasilkan klasifikasi keempat kategori ras wajah. Setiap tahapan saling bergantung sehingga kualitas pada setiap proses berpengaruh langsung terhadap akurasi klasifikasi secara keseluruhan.

2.1 Akuisisi Data

Data yang digunakan bersumber dari dataset publik *FairFace*, yaitu kumpulan citra wajah yang dirancang untuk mendukung penelitian dengan mempertimbangkan keseimbangan representasi ras, jenis kelamin, dan usia [9]. Total citra yang digunakan berjumlah 2.800, terdiri atas 2.400 data latih dan 400 data validasi, dengan distribusi seimbang 600 citra per kelas pada data latih dan 100 citra per kelas pada data validasi. Rincian distribusi data disajikan pada Tabel 1.

Tabel 1. Distribusi Subset Data FairFace yang Digunakan

Subset	Black	East Asian	Indian	White	Total
Train	600	600	600	600	2.400
Validasi	100	100	100	100	400
Total	700	700	700	700	2.800

Berdasarkan Tabel 1, distribusi data bersifat seimbang di seluruh kelas ras. Keseimbangan ini penting agar model tidak mengalami bias terhadap kelas tertentu dan evaluasi menggunakan metrik *macro-average* dapat merepresentasikan kinerja model secara adil pada seluruh kelas [10].

2.2 Deteksi dan Cropping Wajah

Dataset FairFace yang digunakan telah menyediakan citra wajah yang melalui proses seleksi dan anotasi secara sistematis. Setiap citra merupakan hasil pemotongan (cropping) yang berfokus pada area wajah sehingga tahap deteksi wajah tambahan tidak dilakukan pada penelitian ini. Pendekatan tersebut membantu menjaga konsistensi kualitas data masukan serta meningkatkan efisiensi proses komputasi. Metode deteksi wajah berbasis Convolutional Neural Network (CNN) diketahui mampu memberikan performa yang baik pada berbagai kondisi pencahayaan dan sudut pengambilan gambar [11]. Seluruh 2.800 citra pada subset yang digunakan telah memenuhi kriteria kelayakan sehingga tidak terdapat data yang tereliminasi [9].

2.3 Praproses Data

Setiap citra wajah terlebih dahulu melalui tahap praproses untuk memastikan keseragaman format masukan bagi model FaceNet. Seluruh citra diubah ukurannya menjadi 160×160 piksel sesuai standar masukan FaceNet [12]. Selain itu, nilai piksel dinormalisasi ke rentang $[-1, 1]$ melalui pengurangan rata-rata dan pembagian standar deviasi piksel. Proses normalisasi ini bertujuan menyeragamkan distribusi nilai piksel sehingga model dapat melakukan inferensi secara lebih stabil dan konsisten. Pendekatan normalisasi semacam ini telah terbukti efektif dalam meningkatkan kinerja model berbasis jaringan saraf dalam [12].

2.4 Ekstraksi Fitur Menggunakan FaceNet

FaceNet merupakan arsitektur jaringan saraf dalam yang digunakan untuk mengekstraksi fitur wajah dalam bentuk embedding berdimensi tinggi [12]. Pada penelitian ini digunakan model InceptionResNetV1 pretrained pada dataset VGGFace2 yang mampu mengekstraksi karakteristik penting wajah secara mendalam. Setiap citra wajah yang telah melalui tahap praproses diproses menggunakan FaceNet untuk menghasilkan vektor embedding berdimensi 512 sebagai representasi karakteristik wajah pada proses klasifikasi ras.

Proses ekstraksi dilakukan dalam mode inferensi tanpa pelatihan ulang model FaceNet. Embedding yang dihasilkan kemudian disimpan dalam berkas *.npz* dan digunakan sebagai fitur masukan pada algoritma Support Vector Machine (SVM) pada tahap pelatihan dan evaluasi model [12]. Pendekatan ini memungkinkan proses klasifikasi dilakukan secara lebih efisien tanpa memerlukan pelatihan jaringan saraf dari awal.

2.5 Pelatihan Model SVM

Support Vector Machine (SVM) merupakan algoritma pembelajaran mesin yang bekerja dengan mencari *hyperplane* optimal pada ruang fitur berdimensi tinggi agar data antar kelas dapat dipisahkan dengan margin semaksimal mungkin [13]. Dalam penelitian ini, strategi *One-vs-Rest* (OvR) diterapkan untuk menangani klasifikasi multikelas, di mana satu pengklasifikasi biner dibentuk untuk setiap kelas ras secara terpisah. Model dikonfigurasi menggunakan kernel *Radial Basis Function* (RBF) dengan parameter regularisasi $C = 1,0$ dan $\gamma = \text{'scale'}$. Pemilihan kernel RBF didasarkan pada kemampuannya memodelkan batas keputusan yang bersifat non-linear, yang merupakan karakteristik umum dari data *embedding* wajah berdimensi tinggi [13]. Berbeda dengan kernel linear yang hanya mampu memisahkan data secara linear, kernel RBF dapat menangkap pola distribusi fitur yang lebih kompleks sehingga lebih sesuai untuk permasalahan klasifikasi ras wajah yang memiliki variasi visual tinggi. Penelitian sebelumnya menunjukkan bahwa kernel RBF secara konsisten memberikan performa yang baik pada permasalahan klasifikasi berbasis citra berdimensi tinggi [14]. Setelah pelatihan selesai, model SVM beserta *label encoder* disimpan dalam berkas *.joblib* untuk digunakan pada tahap evaluasi dan prediksi.

2.6 Evaluasi Model

Evaluasi model menggunakan metrik akurasi, presisi, *recall*, dan F1-score untuk setiap kelas ras [15]. Keempat metrik tersebut dinyatakan pada Persamaan di bawah ini.

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN}$$

$$Precision = \frac{TP}{TP + FP}$$

$$Recall = \frac{TP}{TP + FN}$$

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall}$$

Pada persamaan di atas, TP (*True Positive*) adalah jumlah prediksi positif yang benar, TN (*True Negative*) adalah jumlah prediksi negatif yang benar, FP (*False Positive*) adalah prediksi positif yang salah, dan FN (*False Negative*) adalah prediksi negatif yang salah. Nilai-nilai TP, TN, FP, dan FN untuk setiap kelas dapat dibaca langsung dari *confusion matrix* yang disajikan pada Gambar 2. Selain metrik numerik, *confusion matrix* juga ditampilkan untuk memberikan gambaran visual mengenai distribusi kesalahan prediksi model pada setiap kelas ras [15].

3. HASIL DAN PEMBAHASAN

Hasil penelitian pada setiap tahapan disajikan secara terstruktur, mulai dari persiapan data, ekstraksi fitur menggunakan FaceNet, pelatihan model SVM, hingga evaluasi performa model secara keseluruhan. Setiap subbab dilengkapi dengan tabel, visualisasi, serta pembahasan hasil untuk memberikan gambaran yang jelas mengenai kinerja model yang dikembangkan.

3.1 Persiapan Data

Dari total 2.800 citra yang diproses, seluruh data berhasil dimuat tanpa adanya kehilangan sampel. Setiap citra diubah ukurannya menjadi 160×160 piksel dan dinormalisasi sebelum memasuki tahap ekstraksi fitur. Distribusi akhir data disajikan pada Tabel 2.

Tabel 2. Distribusi Data Penelitian per Kelas Ras

Kelas Ras	Data Latih	Data Validasi	Total
Black	600	100	700
East Asian	600	100	700
Indian	600	100	700
White	600	100	700
Total	2.400	400	2.800

Berdasarkan Tabel 2, distribusi data pada keempat kelas ras bersifat seimbang dengan masing-masing kelas memiliki 600 sampel pada data latih dan 100 sampel pada data validasi. Keseimbangan distribusi ini penting untuk meminimalkan potensi bias model terhadap kelas tertentu sekaligus memastikan bahwa evaluasi menggunakan metrik *macro-average* dapat merepresentasikan kinerja model secara adil pada seluruh kelas [10].

3.2 Ekstraksi Embedding Wajah

Seluruh citra yang telah melalui tahap praproses dimasukkan ke dalam model FaceNet (InceptionResNetV1 *pretrained VGGFace2*) untuk mengekstraksi representasi fitur wajah. Setiap citra menghasilkan vektor *embedding* berdimensi 512 yang disimpan dalam berkas *.npz*. Dimensi dan ukuran matriks hasil ekstraksi disajikan pada Tabel 3.

Tabel 3. Dimensi Matriks Embedding Hasil Ekstraksi FaceNet

Subset	Jumlah Sampel	Dimensi Embedding	Berkas (.npz)
Train	2.400	2400×512	$\pm 4,9$ MB
Validasi	400	400×512	$\pm 1,0$ MB

Berdasarkan Tabel 3, ekstraksi fitur menghasilkan matriks berdimensi 2400×512 untuk data latih dan 400×512 untuk data validasi. Vektor *embedding* 512-dimensi merupakan keluaran model InceptionResNetV1 *pretrained* yang merangkum informasi visual wajah secara kompak sehingga perbedaan antar kelas ras dapat dipisahkan dengan lebih baik oleh SVM [16]. Pendekatan *transfer learning* ini terbukti lebih efisien dibandingkan pelatihan CNN secara *end-to-end* pada kondisi data terbatas [10].

3.3 Pelatihan Model SVM

Model SVM dilatih menggunakan matriks *embedding* hasil ekstraksi FaceNet dengan konfigurasi kernel RBF, $C = 1,0$, dan $\gamma = \text{'scale'}$. Rincian konfigurasi disajikan pada Tabel 4.

Tabel 4. Konfigurasi Pelatihan Model SVM

Parameter	Nilai / Konfigurasi
Algoritma	Support Vector Machine (SVM)
Kernel	RBF (Radial Basis Function)
Parameter C	1,0
Parameter gamma	'scale' = $1/(n_{\text{fitur}} \times \text{Var}(X))$
Strategi multikelas	One-vs-Rest (OvR)
Jumlah kelas output	4 (Black, East Asian, Indian, White)
Dimensi fitur input	512 (embedding FaceNet)
Penyimpanan model	svm_model.joblib + label_encoder.joblib

Berdasarkan Tabel 4, kernel RBF dipilih karena kemampuannya memodelkan batas keputusan non-linear yang tidak dapat ditangani oleh kernel linear, sesuai dengan karakteristik data *embedding* wajah berdimensi tinggi. Penelitian terdahulu juga menunjukkan bahwa kernel RBF secara konsisten memberikan performa yang baik pada permasalahan klasifikasi citra berdimensi tinggi [14].


3.4 Hasil Evaluasi Model

Evaluasi model dilakukan menggunakan 400 data validasi yang sepenuhnya terpisah dari data pelatihan. Hasil evaluasi mencakup perhitungan metrik akurasi, presisi, *recall*, dan F1-score berdasarkan nilai TP (*True Positive*), TN (*True Negative*), FP (*False Positive*), dan FN (*False Negative*) yang dapat dibaca langsung dari *confusion matrix* pada Gambar 2. Secara keseluruhan, model FaceNet-SVM mencapai akurasi validasi sebesar 88,75%. Laporan klasifikasi lengkap disajikan pada Tabel 5.

Tabel 5. Laporan Klasifikasi Model FaceNet SVM pada Data Validasi

Kelas Ras	Precision	Recall	F1-Score	Support
Black	0,8980	0,8800	0,8889	100
East Asian	0,9500	0,9500	0,9500	100
Indian	0,8200	0,8200	0,8200	100
White	0,8824	0,9000	0,8911	100
Accuracy	–	–	0,8875	400
Macro avg	0,8876	0,8875	0,8875	400
Weighted avg	0,8876	0,8875	0,8875	400

Berdasarkan Tabel 5, kelas *East Asian* menunjukkan performa terbaik dengan nilai *precision*, *recall*, dan *F1-score* yang identik sebesar 0,9500. Kelas *Black* memperoleh *F1-score* sebesar 0,8889 dengan keseimbangan *precision* (0,8980) dan *recall* (0,8800) yang baik. Pada kelas *White*, *recall* (0,9000) lebih tinggi dibandingkan *precision* (0,8824), mengindikasikan kecenderungan *over-predict*. Sementara itu, kelas *Indian* memiliki *F1-score* terendah (0,8200) akibat ambiguitas klasifikasi dengan kelas lain yang memiliki kemiripan karakteristik visual tinggi. Pola ini sejalan dengan temuan penelitian terdahulu yang menunjukkan kelas *Indian* dan *Asian* cenderung lebih sulit diklasifikasikan pada sistem berbasis *deep learning* [17].



Gambar 2. Confusion Matrix Model FaceNet-SVM pada Data Validasi (n = 400)

Berdasarkan Gambar 2, kelas *East Asian* memiliki jumlah prediksi benar tertinggi (95 dari 100), dikonfirmasi oleh *F1-score*-nya yang mencapai 0,9500. Kelas *White* dan

Black masing-masing diklasifikasikan benar sebanyak 90 dan 88 sampel. Kelas *Indian* menunjukkan pola kesalahan terbesar, dengan 8 sampel terprediksi sebagai *Black* dan 9 sampel sebagai *White*, mengindikasikan tumpang tindih fitur visual antar kelas tersebut. Nilai *macro average F1-score* sebesar 0,8875 menunjukkan kemampuan generalisasi model yang baik di seluruh kelas ras [18].

Hasil penelitian ini juga memiliki implikasi praktis yang relevan. Anggraeni dan Damanik (2025) menunjukkan bahwa arsitektur MTCNN mampu menangani deteksi multi-wajah secara simultan pada berbagai dimensi piksel, yang mengindikasikan potensi pengembangan sistem ini untuk skenario pengawasan kelompok [19]. Nurpadilah dan Setiyaningsih (2025) merancang aplikasi absensi berbasis pengenalan wajah menggunakan CNN yang terbukti efektif dalam kondisi ruangan nyata, menegaskan relevansi sistem berbasis embedding wajah untuk diimplementasikan pada lingkungan terkontrol [20]. Temuan-temuan tersebut mendukung prospek pengembangan sistem FaceNet-SVM yang diusulkan dalam penelitian ini menuju implementasi yang lebih luas.

4. SIMPULAN

Penelitian ini berhasil mengembangkan sistem klasifikasi ras wajah berbasis kombinasi *embedding* FaceNet dan algoritma SVM menggunakan dataset FairFace yang mencakup empat kategori ras (*Black, East Asian, Indian, White*) dengan total 2.800 citra. Model mencapai akurasi validasi 88,75% dengan *macro average F1-score* 0,8875. Kelas *East Asian* mencatat *F1-score* tertinggi (0,9500), sementara kelas *Indian* terendah (0,8200) akibat kemiripan karakteristik visual. Kelas *Black* dan *White* menunjukkan kinerja yang kompetitif dengan *F1-score* masing-masing 0,8889 dan 0,8911. Pendekatan *transfer learning* FaceNet-SVM terbukti efektif dan efisien tanpa memerlukan pelatihan jaringan dari awal. Untuk pengembangan selanjutnya disarankan: (1) optimasi *hyperparameter* SVM menggunakan *grid search* atau *Bayesian optimization*; (2) eksplorasi arsitektur yang lebih mutakhir seperti *Vision Transformer* (ViT); serta (3) perluasan dataset dengan variasi pencahayaan, pose, dan resolusi yang lebih beragam agar kemampuan generalisasi model pada kondisi nyata meningkat. Sistem ini berpotensi diintegrasikan ke dalam aplikasi verifikasi identitas berbasis atribut demografis serta kajian sosiologi komputasional berbasis data visual.

REFERENCES

- [1] F. D. Adhinata and J. Arifin, "Klasifikasi Jenis Kelamin Wajah Bermasker Menggunakan Algoritma Supervised Learning," *Jurnal Media Informatika Budidarma*, vol. 6, no. 1, pp. 229–235, Jan. 2022, doi: 10.30865/mib.v6i1.3377.
- [2] I. P. Pratama and N. K. Ningrum, "Face Recognition Using MTCNN Face Detection, ResNetV1 Feature Embeddings, and SVM Classification," *JAIC (Journal of Applied Informatics and Computing)*, vol. 9, no. 5, pp. 2049–2058, 2025, [Online]. Available: <http://jurnal.polibatam.ac.id/index.php/JAIC>
- [3] W. W. Muhammad Akbar Satriawan and S. Widhiarso, "Klasifikasi Pengenalan Wajah Untuk Mengetahui Jenis Kelamin Menggunakan Metode Convolutional Neural Network," *Jurnal Algoritme*, vol. 4, no. 1, pp. 43–52, 2023, doi: 10.35957/algoritme.v4i1.4116.
- [4] K. Q. F. I Putu Agus Aryawan, I Nyoman Purnama, "Analisis Perbandingan Algoritma CNN dan SVM pada Klasifikasi Ekspresi Wajah," *Jurnal Krisnadana*, vol. 9, no. 1, pp. 399–408, 2023, doi: 10.58982/krisnadana.v3i1.488.
- [5] M. S. Sri Wahyuni and T. Sulaeman, "Penerapan Algoritma Deep Learning untuk Sistem Absensi Kehadiran Deteksi Wajah di PT Karya Komponen Presisi," *JURNAL SIMANTIK*, vol. 7, no. 1, pp. 12–21, 2022, [Online]. Available: <https://www.simantik.fst-panca-sakti.ac.id/>
- [6] Siswanti Sri Desy, Puspita Heni, Ubaya Huda, Selly, and Herdiana Dina, "Deteksi Wajah Tersamar Menggunakan Metode VGGFace dan SVM," *Jurnal Nasional Teknologi dan Sistem Informasi*, vol. 9, no. 2, pp. 512–527, 2025.
- [7] A. T. Akbar, S. Saifullah, and H. Prapcoyo, "Klasifikasi Ekspresi Wajah Menggunakan Convolutional Neural Network," *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, vol. 11, no. 6, pp. 1399–1412, 2024, doi: 10.25126/jtik.2024118888.
- [8] A. P. Meldyanton, "Implementasi Sistem Absensi Berbasis Pengenalan Wajah Menggunakan Metode CNN dan Model FACENET," *Jurnal Mahasiswa Teknik Informatika (JATI EMAS)*, vol. 02, no. 25, pp. 25–32, 2025.
- [9] M. R. Faricsyah, Rayhan Syahputra, Jefrey Setiawan, Ema Damayanti, "Implementasi Deep Learning untuk Sistem Absensi dengan Integrasi Data Identitas Menggunakan MTCNN, FaceNet, dan SVC," *Syntax Literatur: Jurnal Ilmiah Indonesia*, vol. 5, no. 2, pp. 182–192, 2025, [Online]. Available: <https://jurnal.umpar.ac.id/index.php/sylog>
- [10] M. F. Naufal, "Analisis Perbandingan Algoritma SVM, KNN, CNN untuk Klasifikasi Citra Cuaca," *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, vol. 8, no. 2, pp. 311–318, 2021, doi: 10.25126/jtik.202184553.
- [11] K. Anwar, "Sistem Deteksi Wajah Berbasis Deep Learning Menggunakan Convolutional Neural Network (CNN)," *Journal of Computer Science and Information Technology (JOCSIT)*, vol. 1, no. 2, pp. 46–52, 2025, doi: <https://doi.org/10.70716/jocsit.v1i2.258>.
- [12] M. R. Rachmansyah, B. Rahmat, and H. E. Wahanani, "Penggunaan Deep Convolutional Neural Network (CNN) Model FaceNet untuk Fungsi Face Recognition pada Reverse Image Search," *Jurnal Informatika dan Sistem Informasi (JIFOS)*, vol. 5, no. 2, pp. 52–57, 2025.
- [13] D. I. Rifki Kosasih, Iffatul Mardhiyah, "Penerapan Algoritma Support Vector Machine Dalam Pengenalan Wajah Berdasarkan Fitur Isomap," *CESS (Journal of Computer Engineering, System and Science)*, vol. 10, no. 1, pp. 299–311, 2025, doi: DOI: <https://doi.org/10.24114/cess.v11i1.68568>.
- [14] N. Nurjihan, Saniyyah Wafa, Faturrahman and I. M. Wiguna, "Pengenalan Pola Ekspresi Wajah Untuk Pengolahan Citra Menggunakan Metode Convolutional Neural Network," *Jurnal Nasional Ilmu Komputer (JNIK)*, vol. 11, no. 4, 2024, [Online]. Available: <http://jurnal.mdp.ac.id>
- [15] A. Faizah, S. Imron, A. Rahel, P. Rewur, J. N. Makasunggal, and P. H. Saputro, "Komparasi Algoritma Support Vector Machine (SVM) dan Convolutional Neural Network (CNN) untuk Klasifikasi Ekspresi Wajah," *Jurnal Ilmiah Komputasi*, vol. 4221, no. 4, pp. 13–24, 2025.
- [16] M. K. Insani and D. B. Santoso, "Perbandingan Kinerja Model Pre-Trained CNN (VGG16, RESNET, dan INCEPTIONV3) untuk Aplikasi Pengenalan Wajah pada Sistem Absensi Karyawan," *Jurnal Ilmiah Manajemen Informatika dan Komputer (JIMIK)*, vol. 5, no. 3, pp. 2612–2622, 2024, doi: <https://journal.stmiki.ac.id/index.php/jimik/>.
- [17] A. A. Achyar, "Identifikasi Ras Wajah dengan Menggunakan Metode Deep Learning Model Keras," *Jurnal Sains dan Teknologi*, vol. 4, no. 2, pp. 112–120, 2022.
- [18] G. P. D. Kisowo, "Perbandingan Akurasi CNN dan SVM Untuk Deteksi dan Klasifikasi Aktivitas Merokok," *Jurnal Router*, vol. 2, no. 3, pp. 48–55, 2024, doi: <https://doi.org/10.62951/router.v2i3.145>.
- [19] Merry Anggraeni and H. A. Damanik, "Implementasi Arsitektur MTCNN pada Kelas Dimensi Piksel Berbeda dan Plotting Multi-Wajah pada Hasil Deteksi," *Jurnal Pekommas*, vol. 10, no. 1, pp. 91–104, 2025, doi: 10.56873/jpkm.v9i1.5843.

-
- [20] R. Nurpadilah and T. Setiyaningsih, "Perancangan Aplikasi Absensi dan Pengawasan Ruangan dengan Pengenalan Wajah menggunakan metode Convolutional Neural Network," *Jurnal TIFDA (Technology Information and Data Analysis)*, vol. 2, no. 1, pp. 13–18, 2025, doi: 10.70491/tifda.v2i1.81.