

Implementasi *Face Recognition* Berbasis *Support Vector Machine* dan *MediaPipe*

Muhammad Naufal Sutardi¹, Ramzy Atchallah Putra², Hotniel Diasi Sianturi³, Rafi Muhammad Rusydan⁴, Athala Fazli Maula⁵, Endang Purnama Giri⁶, Gema Parasti Mindara⁷

^{1,2,3,4,5,7}Program Studi Teknologi Rekayasa Perangkat Lunak, Sekolah Vokasi, IPB University, Indonesia

⁶Program Studi Ilmu Komputer, Sekolah Data Sains Matematika dan Informatika, IPB University, Indonesia

¹naufalsutardi@apps.ipb.ac.id, ²ramzyatchallah@apps.ipb.ac.id, ³nieldiasisianturi@apps.ipb.ac.id,

⁴rafi31rusydan@apps.ipb.ac.id, ⁵athalafazlimaula@apps.ipb.ac.id, ⁶endang_pg@apps.ipb.ac.id,

⁷gemaparasti@apps.ipb.ac.id

Abstrak

Autentikasi berbasis biometrik dengan wajah menawarkan kemudahan dan keamanan, namun akurasinya masih dipengaruhi dengan adanya perubahan pencahayaan, pose, ekspresi, dan *occlusion*. Penelitian ini mengimplementasikan sistem *face recognition* yang ringan dan praktis dengan deteksi wajah menggunakan *MediaPipe Face Mesh*, ekstraksi fitur melalui *face encoding* (dengan dukungan pola tepi ala HOG), dan klasifikasi identitas memakai *Support Vector Machine* (SVM) dengan tiga varian kernel yang dibandingkan secara sistematis. Sistem dikembangkan dalam *Python* (*MediaPipe*, *OpenCV*, *scikit-learn*) dengan antarmuka *web* untuk pendaftaran dan identifikasi wajah. Data uji berupa citra wajah pengguna yang diubah menjadi vektor *embedding*, kemudian pelatihan/validasi dilakukan memakai *5-fold cross-validation* dan perbandingan beberapa kernel SVM. Hasil menunjukkan sistem mampu mengenali wajah dengan baik pada kondisi pencahayaan normal dan pose *frontal*. Kernel *Linear* memberikan akurasi rata-rata tertinggi 99,38% (*confusion matrix* 100%), disusul RBF 98,72% dan *Polynomial* 96,11%. Mekanisme stabilisasi *confidence* antar *frame* membuat tampilan identifikasi lebih halus dan konsisten. Meski demikian, ukuran data yang terbatas membuat performa belum sepenuhnya merepresentasikan kondisi nyata dan masih rentan terhadap *occlusion* serta pencahayaan ekstrim (indikasi *overfitting*). Temuan ini mengindikasikan bahwa kombinasi *MediaPipe*, *face encoding* dan SVM efektif untuk *face recognition* skala kecil atau menengah, dan riset lanjutan perlu menambah variasi data, skenario pengambilan, serta strategi augmentasi atau regularisasi untuk meningkatkan *robustness* di lingkungan nyata.

Kata kunci: *face recognition*, pengolahan citra, *computer vision*, *machine learning*, autentikasi biometrik

1. Pendahuluan

Pengenalan wajah (*face recognition*) telah digunakan untuk berbagai bidang seperti presensi ataupun sistem keamanan pada perangkat tertentu. Dengan *face recognition* ini pengguna akan dimudahkan dalam sistem autentikasi yang lebih aman yang menghilangkan penggunaan kata sandi atau autentikasi perangkat keras pihak ketiga, yang menyediakan solusi autentikasi tanpa kata sandi yang lebih aman (Oduguwa & Arabo, 2024). Selain itu dari segi keamanan saat adanya perangkat pengguna yang dicuri, penyerang tidak dapat mengakses akun karena autentikasi biometrik diperlukan untuk menyelesaikan *login* dan autentikasi memerlukan konfirmasi biometrik, oleh karena itu, penyerang juga memerlukan biometrik fisiologis milik pengguna (Mahnamfar et al., 2024). Namun masih terdapat hal yang perlu diperhatikan dalam proses pengenalan wajah ini dapat dilihat pada beberapa penelitian ini. Wang et al. (2020) serta Zhao et al. (2024) menun-

jukkan bahwa perubahan pencahayaan, variasi pose, ekspresi, serta *occlusion* (misal masker, kacamata) memang menyebabkan penurunan akurasi pada sistem pengenalan wajah dan ekspresi, terutama saat sistem diuji di luar kondisi laboratorium. Studi-studi *benchmarking* menemukan bahwa *occlusion* adalah salah satu faktor yang paling drastis menurunkan performa, bahkan lebih dari perubahan pose atau pencahayaan saja (Zhao et al., 2024).

Pendekatan *deep learning*, khususnya *Convolutional Neural Networks* (CNN) dengan *loss margin-based*, telah merevolusi dan mendominasi pengenalan wajah skala besar selama satu dekade terakhir. *Margin-based loss* seperti *ArcFace*, *CosFace*, dan varian lainnya secara konsisten menghasilkan performa terbaik di berbagai *benchmark* utama (Oinar et al., 2023). Selain performa, penelitian juga fokus pada model *lightweight* (misal: *GhostFaceNet*, *MobileFaceNet*) agar pengenalan wajah berbasis CNN dapat diterapkan di perangkat dengan sumber daya ter-

batas tanpa mengorbankan akurasi, tetap menggunakan *margin-based loss* (Liu et al., 2021). Pelatihan model CNN umumnya memerlukan *hardware* khusus seperti GPU agar proses *training* berjalan efisien. Tanpa GPU, pelatihan bisa sangat lambat dan tidak praktis untuk *dataset* besar dan juga memiliki ukuran model besar dan membutuhkan dependensi *library* yang signifikan, sehingga menyulitkan *deployment* di perangkat dengan memori terbatas (Mulugeta et al., 2024).

Itulah sebabnya penelitian ini menggunakan MediaPipe dan SVM. MediaPipe menyediakan komponen siap pakai untuk ekstraksi fitur wajah secara efisien, sehingga menurut Sanil et al. (2025), fitur yang dihasilkan menjadi sangat ringan untuk diproses oleh SVM, yang memang dikenal efisien untuk data berdimensi sedang (Siam et al., 2022). Dapat dilihat pada studi yang menggunakan 468 *landmark MediaPipe* dan SVM pada data wajah 2D menunjukkan akurasi pengenalan hingga 88% pada kasus sulit seperti identifikasi kembar identik, dengan efisiensi komputasi yang baik (Sanil et al., 2025). Pada aplikasi deteksi emosi, kombinasi MediaPipe dan SVM juga mencapai akurasi tinggi (hingga 94% pada *dataset* CK+ dan 88% pada JAFFE) (Siam et al., 2022). Selain itu, optimasi MediaPipe juga terbukti mampu meningkatkan akurasi pada tugas terkait wajah lainnya, seperti pada sistem deteksi usia wajah secara *real-time* berbasis *deep neural network* (Iskandar et al., 2025).


Sejalan dengan itu penelitian ini bertujuan untuk merancang, mengimplementasikan dan mengevaluasi sistem pengenalan wajah berbasis MediaPipe dan SVM yang dapat direplikasi. Selain itu penelitian ini juga akan menilai bagaimana langkah praproses seperti, deteksi, *cropping* atau *alignment* dasar terhadap kestabilan fitur, serta mendokumentasikan praktik baik yang mungkin relevan dengan pengembangan lainnya yang ingin mengadopsi *pipeline* serupa.

2. Metode

Pada penelitian ini akan dilakukan beberapa tahap dapat dilihat pada Gambar 1, dimulai dari analisis, desain perancangan sistem, pengembangan sistem dan pengujian. Tahapan ini akan digunakan sebagai panduan dalam pembuatan *face recognition* agar teratur dan terstruktur.

2.1 Analisis Sistem

Tahap analisa bertujuan untuk memahami kebutuhan sistem dan batasan penelitian agar proses pengembangan dapat berjalan secara terarah (D.S.S., 2021). Pada tahap ini akan dilakukan analisis terhadap kebutuhan pengguna dan juga kebutuhan fungsional dan nonfungsional terhadap sistem dan analisa perilaku sistem (Rimbawan et al., 2021). Analisis dilakukan terhadap fungsi utama sistem, yaitu mende-



Gambar 1. Tahapan Penelitian

teksi wajah, mengekstraksi fitur citra, serta mengenali identitas pengguna menggunakan algoritma SVM. Hasil analisa ini menjadi dasar dalam perancangan alur kerja dan struktur sistem pengenalan wajah yang efisien.

a. Kebutuhan Fungsional

Kebutuhan fungsional dalam penelitian ini meliputi proses pendaftaran wajah setiap pengguna sebagai dasar data pelatihan, kemudian mendeteksi wajah pada gambar dan melakukan pemotongan pada area wajah yang relevan. Setelah itu, sistem mengekstraksi *embedding* dari hasil deteksi wajah, sekaligus melakukan ekstraksi titik-titik fitur (*landmark*) menggunakan MediaPipe dan mengubahnya menjadi vektor *embedding* yang dapat diproses lebih lanjut. Identitas pengguna kemudian diklasifikasikan menggunakan algoritma *Support Vector Machine* (SVM). Pada tahap akhir, sistem menampilkan hasil prediksi dan menyimpan log sebagai bagian dari proses pencatatan dan evaluasi performa model.

b. Kebutuhan Non-Fungsional

Kebutuhan non-fungsional dalam penelitian ini menekankan bahwa proses deteksi wajah harus berjalan dengan cepat agar sistem tetap responsif dan layak digunakan dalam konteks nyata. Selain itu, model SVM yang digunakan perlu memiliki ukuran yang ringan dan memanfaatkan memori secara efisien agar tidak membebani perangkat, terutama jika diimplementasikan pada sistem dengan sumber daya terbatas. Di sisi etis, setiap pengguna harus memberikan persetujuan sebelum datanya diproses, dan seluruh data yang tersimpan wajib dijaga keamanannya untuk mencegah identifikasi yang tidak diinginkan.

c. Data dan Ruang Lingkup

Penelitian ini menggunakan sembilan orang sebagai subjek dengan total data yang mencapai 180 data, setiap subjek memiliki 20 data gambar dengan empat *pose* yang berbeda, satu *pose* menghasilkan lima gambar. Seluruh data yang diperoleh disimpan di dalam sebuah *database*. Untuk menjaga va-

liditas evaluasi model, identitas yang digunakan pada data uji tidak akan muncul pada data latih sehingga proses pengujian benar-benar mengukur kemampuan generalisasi sistem. Ruang lingkup penelitian dibatasi hanya pada proses pendaftaran, deteksi, ekstraksi fitur, dan klasifikasi wajah, tanpa membahas aspek *liveness detection* (*anti-spoofing*) maupun kondisi ekstrem dalam pengambilan gambar seperti pencahayaan buruk, pose ekstrem, atau penggunaan aksesoris yang menghalangi wajah.

2.2 Desain/Perancangan

Pada tahap desain, fokus utamanya adalah menentukan alur sistem dan struktur file agar proses pengembangan lebih terarah serta mudah diuji ulang (Spreckelsen et al., 2020). Dalam pembuatan sistem *face recognition*, alur yang digunakan meliputi pemberian *input* berupa gambar, kemudian dilanjutkan dengan proses deteksi wajah untuk menemukan area relevan. Setelah wajah terdeteksi, sistem melakukan pembuatan *embedding* dan mengekstraksi fitur-fitur penting dari wajah tersebut. Tahap selanjutnya adalah klasifikasi untuk menentukan identitas berdasarkan fitur yang telah diekstraksi, hingga akhirnya menghasilkan *output* berupa prediksi identitas.

a. Perangkat dan Perangkat Lunak


Dalam pembuatan sistem *face recognition* ini, perangkat yang digunakan mencakup sebuah *laptop* atau PC yang dilengkapi kamera atau *webcam* sebagai alat untuk menangkap citra wajah. Pengembangan sistem dilakukan menggunakan bahasa pemrograman *Python* karena kelengkapan pustaka pendukung yang relevan untuk pemrosesan citra dan *machine learning*. Selain itu, *Supabase* digunakan sebagai media penyimpanan data agar proses manajemen, akses, dan pengelolaan *dataset* wajah dapat dilakukan secara terstruktur.

2.3 Pengembangan

Tahap pengembangan akan dilakukan pengkodean dari analisa dan perancangan yang sudah dilakukan sebelumnya (Pramono et al., 2020). Pada tahap ini akan dilakukan *coding* untuk pembuatan *face recognition* menggunakan *MediaPipe* dan *Support Vector Machine* (SVM). Pembuatan program *coding* ini dilakukan di *framework Flask* dengan menggunakan *Phyton*.

2.4 Pengujian

Tahap pengujian ini akan memastikan bahwa sistem bukan hanya sekedar jalan, tetapi juga bisa mencapai target dan efisiensi menjalankan aplikasi yang telah dibuat pada *laptop* atau *computer* dengan kamera (Arsal et al., 2020). Pengujian dilakukan



Gambar 2. Halaman *Registration Wajah*

dengan melakukan uji coba dengan melakukan *face recognition* pada *laptop*. Hasil pengujian akan memudahkan dalam melakukan pengecekan pada alur sistem dan kualitas dari prediksi model.

3. Hasil dan Pembahasan

3.1 Hasil Implementasi Sistem

Tahapan implementasi dilakukan berdasarkan rancangan yang telah dijelaskan pada bagian metode, dimulai dari proses deteksi wajah menggunakan *MediaPipe FaceMesh* hingga klasifikasi identitas dengan *Support Vector Machine* (SVM). Sistem dikembangkan menggunakan bahasa pemrograman *Python* dengan pustaka *MediaPipe*, *OpenCV*, dan *scikit-learn*.

Aplikasi ini memiliki antarmuka berbasis *web* yang dirancang agar mudah digunakan oleh pengguna saat melakukan proses pendaftaran wajah. Tampilan utama antarmuka terdiri dari tiga komponen utama, yaitu *Camera Feed*, *Registration Controls*, dan *Model Training*.

Bagian *Camera Feed* berfungsi untuk menangkap citra wajah secara langsung melalui kamera perangkat, sedangkan *Registration Controls* digunakan untuk memasukkan nama pengguna dan memulai proses pengambilan beberapa sudut wajah. Selanjutnya, modul *Model Training* berfungsi untuk melatih ulang model pengenalan wajah menggunakan data yang telah diregistrasikan.

Selain ketiga komponen utama tersebut, sistem juga menyediakan fitur tambahan berupa *Dataset Management* yang terletak pada bagian bawah antarmuka. Fitur ini digunakan untuk menghapus atau memperbarui data pengguna yang sudah tersimpan di dalam sistem.

Pada Gambar 2 di atas merupakan tampilan antarmuka halaman pendaftaran wajah pada sistem. Pada halaman ini terdapat bagian kamera untuk menangkap citra wajah dari pengguna, kolom untuk menginput nama pengguna, dan fitur pelatihan model pada bagian *Model Training*. Sistem ini dirancang agar setiap proses yaitu mulai dari perekaman citra wajah, penyimpanan data, pelatihan model, hingga proses identifikasi dapat dijalankan secara terintegrasi dalam satu aplikasi.

3.2 Hasil Pemrosesan Citra

Pada tahap pemrosesan citra diawali dengan pengambilan gambar wajah pengguna melalui kamera *laptop* menggunakan *OpenCV*. Gambar yang diperoleh masih dalam format *BGR*, kemudian dikonversi menjadi *RGB* agar sesuai dengan format yang dibutuhkan oleh *MediaPipe* saat memproses deteksi wajah.

Proses deteksi wajah yang memanfaatkan *MediaPipe* digunakan untuk mengenali wajah dan mampu menghasilkan koordinat *landmark* yang merepresentasikan bagian-bagian penting pada wajah, seperti mata, hidung, dan rahang. Penggunaan *MediaPipe* sebagai ekstraktor fitur wajah juga diterapkan pada penelitian lain dan terbukti efektif saat dikombinasikan dengan metode klasifikasi *Support Vector Machine* (SVM) (Revanza et al., 2025).

Pada tahap ekstraksi fitur tidak dilakukan pelatihan model sendiri, melainkan menggunakan model pralatih dari *library face_recognition*, sehingga jumlah *epoch* pelatihan model ekstraktor fitur tidak didefinisikan dalam penelitian ini. Tahap klasifikasi menggunakan algoritma SVM dari *Scikit-learn* yang juga tidak menggunakan parameter *epoch* seperti pada jaringan saraf, tetapi melakukan optimasi sampai *konvergen* pada setiap fold *cross-validation*.

Dengan wajah yang telah terdeteksi dan disejajarkan, sistem melakukan tahap selanjutnya yaitu ekstraksi fitur menggunakan kombinasi metode *Histogram of Oriented Gradients* (HOG) dan *encoding* vektor wajah. HOG digunakan untuk menangkap pola tepi dan arah gradien dari wajah, sedangkan *encoding* menghasilkan representasi numerik yang unik untuk setiap individu.

Hasil dari proses ekstraksi fitur tersebut berupa representasi numerik dari karakteristik wajah setiap pengguna. Representasi tersebut kemudian dimanfaatkan sebagai *input* pada tahap pelatihan model *Support Vector Machine* (SVM) untuk mengenali identitas pengguna secara otomatis berdasarkan pola fitur yang telah dibentuk.

3.3 Hasil Pelatihan Model

Tahap pelatihan dilakukan untuk membangun model pengenalan wajah berdasarkan data fitur yang telah dihasilkan dari proses ekstraksi pada tahap sebelumnya. Pelatihan ini menggunakan algoritma *Support Vector Machine* (SVM) dengan beberapa jenis kernel untuk menentukan hasil model dengan performa terbaik. Untuk mengukur performansi model akan menggunakan *confusion matrix*. *Confusion matrix* merupakan matriks yang digunakan untuk memprediksi jumlah data, baik itu data benar ataupun data yang salah (Permadi & Gumilang, 2024).

Dari struktur tabel *confusion matrix* pada Gambar 3, *confusion matrix* terdiri dari 4 nilai (Pratiwi et al., 2021):

		(Positif) 1	(Negatif) 0
Actual Values	(Positif) 1	TP	FP
	(Negatif) 0	FN	TN
		Predicted Values	

Gambar 3. Struktur tabel *confusion matrix* (Permadi & Gumilang, 2024)

1. TP (*True Positif*), merupakan jumlah data positif yang terklasifikasi dengan benar oleh sistem.
2. TN (*True Negatif*), merupakan jumlah data negatif yang terklasifikasi dengan benar oleh sistem.
3. FP (*False Positif*), merupakan yaitu jumlah data positif namun terklasifikasi salah oleh sistem.
4. FN (*False Negatif*), merupakan jumlah data negatif namun terklasifikasi salah oleh sistem.

Dari data-data di atas, maka akurasi akan didapat melalui seluruh data benar dibagi dengan seluruh data sampel. Dalam konteks *confusion matrix*, jumlah prediksi benar adalah jumlah elemen diagonal (kelas aktual=kelas prediksi), sedangkan jumlah seluruh sampel adalah jumlah seluruh elemen pada *confusion matrix*. Nilai akurasi dapat diperoleh dengan persamaan di bawah,

$$\text{Akurasi} = (TP + TN) / (TP + TN + FP + FN) \times 100\% \quad (1)$$

Presisi digunakan untuk melihat berapa proporsi yang benar-benar positif, dari semua data yang diklasifikasikan positif. Nilai presisi dapat diperoleh dengan persamaan dibawah,

$$\text{Presisi} = TP / (TP + FP) \times 100\% \quad (2)$$




Recall digunakan untuk melihat seberapa banyak kasus positif dari semua data yang aktualnya benaran positif. Nilai *recall* dapat diperoleh dengan persamaan dibawah,

$$\text{Recall} = TP / (TP + FN) \times 100\% \quad (3)$$

F1 Score digunakan ketika adanya ketidakseimbangan kelas dalam *dataset*. *F1 Score* dilakukan dengan cara menghitung rata-rata harmonis antara *precision* dan *recall*. Nilai *F1 score* dapat diperoleh dengan persamaan dibawah,

$$F1 = 2 \times \text{Presisi} \times \text{Recall} / (\text{Presisi} + \text{Recall}) \times 100\% \quad (4)$$

Pada Gambar 4 hasil pengujian model SVM dengan kernel linear menunjukkan *Confusion Matrix* dimana seluruh nilai berada pada diagonal utama,

Gambar 4. Pengujian Model SVM dengan Kernel *Linear*Gambar 6. Pengujian model SVM dengan kernel *radial basis function*Gambar 5. Pengujian model SVM dengan kernel *polynomial*

yang berarti bahwa semua data yang diuji berhasil diklasifikasikan dengan benar. Dari hasil tersebut menunjukkan bahwa kernel linear memberikan performa yang sangat baik.

Pada Gambar 5 pengujian model SVM dengan kernel *polynomial* menunjukkan hasil *Confusion Matrix* yang cukup baik juga dimana terdapat 1 kesalahan prediksi pada kelas 7, walaupun memiliki kesalahan tapi hasil pengujian dari model SVM ini masih cukup baik walau berada di bawah kernel *linear*.

Pada Gambar 6 merupakan pengujian model SVM dengan kernel *radial basis function* dengan hasil *Confusion Matrix* yang memiliki beberapa kesalahan yaitu pada 3 kelas, namun hasil ini masih menunjukkan bahwa kernel RBF tetap memberikan performa yang baik, namun belum seoptimal kernel linear pada *dataset* yang digunakan dalam penelitian ini.

Pada gambar di atas adalah hasil evaluasi dari 180 model dengan jumlah 9 kelas. Hasil evaluasi model ditunjukkan melalui tiga *confusion matrix* untuk kernel, *Linear* (Gambar 4), *Polynomial* (Gambar 5), dan RBF (Gambar 6).


Berdasarkan *confusion matrix* untuk kernel *Linear*, seluruh sampel pada sembilan kelas berhasil dik-

lasifikasikan dengan benar tanpa terdapat kesalahan prediksi. Kondisi ini menghasilkan nilai akurasi, presisi, *recall*, dan *F1-score* sebesar 100%. Hasil ini mengindikasikan bahwa pemisahan fitur antar kelas sangat baik sehingga model linear mampu mengklasifikasikan dengan sempurna. Namun, performa yang sangat tinggi ini perlu dianalisis kembali untuk memastikan tidak terjadi *data leakage* atau *overfitting*, terutama bila data pengujian tidak sepenuhnya independen dari data pelatihan.


Untuk hasil dari kernel *poly*, model dapat menghasilkan akurasi dengan nilai 99,44%, dimana terdapat satu kesalahan pada kelas 7 yang diprediksi sebagai kelas 1. Hasil presisi dari kernel ini adalah 99,86% dan hasil *recall*-nya adalah 99,44%. Untuk hasil dari *F1 Score* dari kernel *poly* ini adalah 99,64%. Hasil ini menunjukkan bahwa kernel *Polynomial* masih memiliki performa yang sangat baik, namun sedikit kurang stabil dibanding kernel *Linear*.

Untuk hasil kernel RBF, model dapat menghasilkan akurasi dengan nilai 98,33%, dimana terdapat kesalahan pada kelas 4 yang diprediksi sebagai kelas 6, kelas 7 yang diprediksi sebagai kelas 1, dan kelas 8 yang diprediksi sebagai kelas 6. Hasil presisi dari kernel ini adalah 96,72% dan hasil *recall*-nya adalah 98,33%. Untuk hasil dari *F1 Score*-nya adalah 97,51%. Hasil ini menunjukkan bahwa kernel RBF masih memiliki performa yang sangat baik, namun sedikit kurang stabil dibanding kernel *Linear* dan *Polynomial*.

Secara keseluruhan, visualisasi dari ketiga *confusion matrix* tersebut mengindikasikan bahwa kernel *Linear* memberikan performa paling konsisten dalam pemetaan fitur wajah ke kelas yang benar. Dominasi nilai pada diagonal serta minimnya *noise* di luar diagonal memperlihatkan bahwa model dengan kernel *Linear* mampu mengenali identitas wajah dengan lebih akurat dibandingkan dengan kernel *Polynomial* maupun RBF.



Gambar 7. Hasil Identifikasi Ketika Sistem Berhasil Mengenali Wajah Pengguna

Gambar 8. Hasil Identifikasi Ketika Wajah Terdeteksi Tetapi Tidak Dikenali (*Unknown*)

3.4 Hasil Identifikasi Wajah

Setelah pelatihan model SVM selesai, tahap selanjutnya adalah mengevaluasi performa sistem dalam mengenali wajah secara *real-time*. Pengujian ini dilaksanakan pada halaman *Face Recognition*, di mana MediaPipe digunakan untuk mendeteksi wajah dan hasil klasifikasinya langsung ditampilkan pada panel *Recognition Results*. Guna memverifikasi konsistensi sistem, pengujian diulang sebanyak lima kali dengan variasi kondisi pencahayaan yang berbeda.

Pada halaman *Identify* ini, kamera diaktifkan untuk menampilkan wajah pengguna secara langsung pada area *Live Camera Feed*. Sistem kemudian mendeteksi wajah menggunakan *MediaPipe Face Mesh* dan menampilkan hasil pengenalan pada panel *Recognition Results*. Panel tersebut menampilkan identitas pengguna yang dikenali, nilai *confidence score*, serta status pengenalan (*Recognized* atau *Unknown*).

Dari lima kali pengujian, sistem berhasil mengenali wajah pengguna sebanyak tiga kali yang dapat dilihat pada Gambar 7 wajah yang sebelumnya didaftar sebagai Rafi dapat dideteksi dengan benar sebagai Rafi. Pada kondisi pencahayaan normal dan sedikit redup, sistem dapat menampilkan label nama pengguna dengan benar disertai *confidence score* yang sesuai, serta memberikan tanda kotak hijau pada area wajah sebagai indikator keberhasilan pengenalan.

Pada salah satu pengujian dengan kondisi pencahayaan yang kurang stabil pada Gambar 8, sistem masih dapat mendeteksi keberadaan wajah, tetapi tidak dapat mengenali identitasnya. Pada kasus ini, sistem menampilkan status *Unknown* dengan bingkai



Gambar 9. Tampilan Sistem Ketika wajah Tidak Terdeteksi

berwarna merah, yang menunjukkan bahwa fitur wajah tidak cukup sesuai dengan data yang ada di basis pelatihan.

Gambar 9 menunjukkan pengujian di mana wajah tidak terdeteksi sama sekali. Hal ini terutama dipengaruhi oleh pencahayaan latar belakang yang terlalu kuat (*backlighting*), sehingga landmark wajah tidak dapat dibaca dengan baik oleh MediaPipe. Kondisi ini menunjukkan bahwa keberhasilan deteksi sangat dipengaruhi oleh kualitas pencahayaan saat pengambilan citra.

Secara keseluruhan, tingkat keberhasilan sistem dalam mengenali wajah berada pada kisaran 60% dari total percobaan. Variasi hasil identifikasi sangat dipengaruhi oleh kondisi pencahayaan, di mana pencahayaan berlebih maupun terlalu minim dapat menyebabkan penurunan kualitas deteksi wajah. Namun demikian, pada kondisi cahaya yang cukup stabil, sistem bekerja dengan baik dan memberikan hasil identifikasi yang konsisten.


3.5 Analisis Implementasi Sistem

Sistem pengenalan wajah yang dikembangkan menggabungkan teknologi *web-based application* dengan pemrosesan citra digital. Implementasi dilakukan menggunakan arsitektur *client-server*, di mana sisi klien bertugas menangkap citra wajah menggunakan kamera perangkat, sedangkan sisi *server* memproses citra tersebut untuk ekstraksi fitur dan klasifikasi identitas.

Pustaka *MediaPipe* digunakan di sisi klien untuk mendeteksi wajah secara *real-time* serta memastikan posisi wajah pengguna sesuai instruksi, seperti menghadap ke depan, ke kanan, ke kiri, dan berkedip. Pendekatan ini meningkatkan kualitas data citra yang dikirim ke *server* dan meminimalkan kesalahan deteksi.

Di sisi *server*, sistem dibangun dengan *framework Flask* berbasis *Python*, serta pustaka *OpenCV* dan *face_recognition* untuk melakukan konversi warna, deteksi wajah, dan ekstraksi fitur. Hasil ekstraksi disimpan dalam basis data *Supabase* untuk proses pelatihan dan identifikasi menggunakan algoritma *Support Vector Machine (SVM)*.

Secara keseluruhan, sistem yang diimplementasikan telah berfungsi sesuai rancangan. Proses



Gambar 10. Flowchart sistem pengenalan wajah berbasis MediaPipe dan SVM

komunikasi antara klien dan *server* berjalan secara *real-time*, dan integrasi antara *MediaPipe*, *OpenCV*, dan *SVM* menunjukkan keterpaduan antara teknologi pemrosesan citra dengan metode klasifikasi dalam menghasilkan sistem pengenalan wajah yang efektif.

Pada Gambar 10 menunjukkan alur utama dimulai dari aktivasi kamera dan deteksi wajah pengguna, kemudian citra yang ditangkap dikirim ke *server*, ekstraksi fitur, hingga klasifikasi identitas dengan *SVM*, dan hasilnya akan ditampilkan pada *browser*.

3.6 Analisis Tahapan Pemrosesan Citra

Tahapan pemrosesan citra pada sistem ini diawali dari proses akuisisi citra melalui kamera yang dikontrol oleh *MediaPipe*. Pustaka ini memastikan wajah terdeteksi dan berorientasi sesuai instruksi agar citra yang dikirim ke *server* memiliki kualitas yang baik.

Setelah citra diterima, dilakukan pra-pemrosesan dengan *OpenCV*, yaitu konversi warna dari BGR ke RGB agar sesuai dengan format yang digunakan oleh *library face_recognition*. Selanjutnya, sistem menjalankan deteksi wajah menggunakan



Gambar 11. Kode Proses Deteksi dan Ekstraksi Fitur Wajah



Gambar 12. Kode Pelatihan Model SVM dengan Cross Validation

metode *Histogram of Oriented Gradients* (HOG) untuk menentukan posisi wajah, kemudian melakukan ekstraksi fitur wajah (*face encoding*) menjadi vektor 128 dimensi yang merepresentasikan ciri unik setiap individu.

Secara keseluruhan, rangkaian proses ini efektif menghasilkan data fitur wajah yang konsisten, sehingga mendukung kinerja model *SVM* pada tahap pengenalan identitas.

3.7 Analisis Pelatihan Model

Pelatihan model dilakukan menggunakan algoritma *Support Vector Machine* (SVM) dengan tiga jenis kernel, yaitu *Linear*, *RBf*, dan *Polynomial*. *Dataset* yang digunakan terdiri dari 9 individu dengan masing-masing 20 *embedding* wajah. Uji performa dilakukan menggunakan metode 5-fold *cross-validation* untuk menghitung rata-rata akurasi dan menghindari bias data. Hasil menunjukkan bahwa kernel *Linear* menghasilkan akurasi tertinggi sebesar 99.38% dengan *confusion matrix* 100%, sedangkan kernel *RBf* dan *Polynomial* masing-masing mencapai 98.72% dan 96.11%.

Nilai akurasi yang sangat tinggi ini menunjukkan bahwa fitur wajah hasil ekstraksi citra sudah sangat representatif pada skala data kecil. Namun, karena jumlah data masih terbatas, performa model belum sepenuhnya mencerminkan kondisi sebenarnya dan berpotensi mengalami *overfitting*. Meskipun demikian, hasil ini menunjukkan bahwa kombinasi antara *face encoding* dan algoritma *SVM* mampu mengenali pola wajah dengan sangat baik dan efisien.



Gambar 13. Kode Proses Identifikasi dan Stabilisasi *Confidence* Wajah

3.8 Analisis Hasil Identifikasi Wajah

Tahap identifikasi wajah dilakukan untuk mengenali pengguna yang telah terdaftar dalam sistem. Proses ini memuat model SVM hasil pelatihan sebelumnya, kemudian menerima citra wajah secara *real-time* melalui kamera. Setiap citra yang diterima akan melalui tahap deteksi, ekstraksi fitur, dan prediksi identitas berdasarkan nilai probabilitas tertinggi. Untuk menjaga kestabilan hasil pengenalan, sistem menerapkan mekanisme stabilisasi nilai *confidence* agar prediksi tidak berubah secara tiba-tiba antar *frame*.

Potongan kode pada Gambar 13 menunjukkan bagian utama dari proses identifikasi wajah yang digunakan pada sistem.

Berdasarkan hasil implementasi, sistem mampu mengenali wajah pengguna dengan tingkat keakuratan tinggi pada kondisi pencahayaan normal dan posisi frontal. Proses stabilisasi nilai *confidence* terbukti efektif dalam mengurangi fluktuasi hasil prediksi antar *frame*, sehingga tampilan identifikasi pada antarmuka *web* menjadi lebih halus dan konsisten. Kesalahan identifikasi masih dapat terjadi ketika wajah tertutup sebagian atau dalam kondisi pencahayaan ekstrim, namun secara keseluruhan sistem telah berfungsi dengan baik pada skala data terbatas.

3.9 Keterbatasan dan Rencana Pengembangan

Sistem pengenalan wajah yang dikembangkan sudah mampu bekerja dengan baik pada skala kecil dan kondisi terkontrol. Namun, sistem ini masih memiliki beberapa keterbatasan. Jumlah data pelatihan yang terbatas, yaitu hanya 9 individu dengan masing-masing 20 *embedding*, membuat model belum mampu mengenali variasi wajah yang lebih kompleks seperti ekspresi ekstrim, pencahayaan rendah, atau rotasi wajah besar. Selain itu, proses identifikasi masih bergantung pada koneksi jaringan dan kualitas kamera yang digunakan, sehingga hasil pengenalan dapat menurun pada kondisi lingkungan yang tidak ideal.

Untuk pengembangan selanjutnya, sistem dapat diperluas dengan menambahkan jumlah data latih dari berbagai kondisi pencahayaan dan sudut pandang agar model lebih *robust*. Penerapan metode

data *augmentation* atau penggunaan algoritma berbasis *deep learning* seperti *Convolutional Neural Network* (CNN) juga dapat meningkatkan kemampuan generalisasi model. Selain itu, integrasi *real-time face tracking* dan optimasi penyimpanan *embedding* di *server* akan membuat sistem lebih efisien dan siap diterapkan pada skala yang lebih besar.

4. Kesimpulan

Penelitian ini menunjukkan bahwa kombinasi *MediaPipe FaceMesh* dengan algoritma *machine learning Support Vector Machine* (SVM) mampu menghasilkan sistem pengenalan wajah yang akurat dan baik. Melalui ekstraksi fitur menggunakan kombinasi metode *Histogram of Oriented Gradients* (HOG) dan *encoding* vektor wajah, sistem berhasil mengenali wajah dengan tingkat akurasi berbeda pada tiga jenis kernel. Pada kernel linear akurasi sebesar 99.38% kernel, sedangkan kernel *Polynomial* dan RBF menghasilkan akurasi yang lebih rendah, masing-masing hanya sekitar 96.23%. Meskipun berbeda tingkat akurasi, namun model mampu membedakan identitas wajah secara konsisten.

Hasil implementasi juga menunjukkan bahwa sistem berjalan secara *real-time* dan efektif dalam pengenalan wajah serta mampu mengenali wajah pengguna dengan tingkat keakuratan tinggi pada kondisi pencahayaan normal dan posisi frontal. Hal ini menunjukkan bahwa kombinasi antara *face encoding* dan algoritma SVM mampu mengenali pola wajah dengan sangat baik dan efisien.

Meskipun demikian, penelitian ini masih terbatas pada jumlah data dan kondisi pencahayaan tertentu. Untuk penelitian selanjutnya disarankan untuk menambah jumlah data dan menambahkan teknologi keamanan *liveness* detection guna mengembangkan sistem agar lebih adaptif dan akurat.

Daftar Pustaka

- Arsal, M., Wardijono, B. A., & Anggraini, D. (2020): *Face recognition untuk akses pegawai bank menggunakan deep learning dengan metode CNN*, Jurnal Nasional Teknologi dan Sistem Informasi, 6(1), 55–63. <https://doi.org/10.25077/teknosi.v6i1.2020.55-63>.
- D.S.S., G. A. (2021): *Analisa kebutuhan kebutuhan sistem informasi manajemen perusahaan dagang*, Kurawal: Jurnal Teknologi, Informasi dan Industri, 4(1), 17–30. <https://doi.org/10.33479/kurawal.v4i1.400>.
- Iskandar, M., Azizah, N., & Jaya, F. (2025): *Real-time face age detection system based on deep neural networks with MediaPipe optimization for enhanced accuracy*, Jurnal Sistem Cerdas, 8(3), 297–305. <https://doi.org/10.37396/jsc.v8i3.593>.
- Liu, W., Zhou, L., & Chen, J. (2021): *Face recognition based on lightweight convolutional neu-*

- ral networks, Information, 12(5), 191. <https://doi.org/10.3390/info12050191>.
- Mahnafar, A., Bicakci, K., & Uzunay, Y. (2024): *ROSTAM: A passwordless web single sign-on solution mitigating server breaches and integrating credential manager and federated identity systems*, Computers & Security, 139, 103739. <https://doi.org/10.1016/j.cose.2024.103739>.
- Mulugeta, A. K., Sharma, D. P., & Mesfin, A. H. (2024): *Deep learning for medicinal plant species classification and recognition: A systematic review*, Frontiers in Plant Science, 14, 1286088. <https://doi.org/10.3389/fpls.2023.1286088>.
- Oduguwa, T., & Arabo, A. (2024): *Passwordless authentication using a combination of cryptography, steganography, and biometrics*, Journal of Cybersecurity and Privacy, 4(2), 278–297. <https://doi.org/10.3390/jcp4020014>.
- Oinar, C., Le, B. M., & Woo, S. S. (2023): *KappaFace: Adaptive additive angular margin loss for deep face recognition*, IEEE Access, 11, 137138–137150. <https://doi.org/10.1109/ACCESS.2023.3338648>.
- Permadi, M. L. B., & Gumilang, R. (2024): *Penerapan algoritma CNN (convolutional neural network) untuk deteksi dan klasifikasi target militer berdasarkan citra satelit*, Jurnal Sosial Teknologi, 4(2), 134–143. <https://doi.org/10.59188/jurnalsostech.v4i2.1138>.
- Pramono, A., Ardanari, P., & Maslim, M. (2020): *Pembangunan aplikasi presensi magang berbasis mobile menggunakan face recognition*, Jurnal Informatika Atma Jogja, 1(1).
- Pratiwi, B. P., Handayani, A. S., & Sarjana, S. (2021): *Pengukuran kinerja sistem kualitas udara dengan teknologi WSN menggunakan confusion matrix*, Jurnal Informatika Upgris, 6(2) <https://doi.org/10.26877/jiu.v6i2.6552>.
- Revanza, M., Bachtar, F., & Setiawan, B. (2025): *Klasifikasi emosi pada raut wajah pelajar menggunakan ekstraktor fitur Face Mesh dan metode support vector machine*, [Nama jurnal belum tercantum], 12(4), 851–858. <https://doi.org/10.25126/jtiik.124>.
- Rimbawan, R., Suharyanti, S., & Basri, A. (2021): *Simulasi penerapan teknologi face recognition pada aplikasi pendataan kehadiran karyawan/karyawati terintegrasi E-Mon sistem penggajian dengan pendekatan Eigenface dan UXD Laravel versi 5.6 berbasis cloud service*, Jurnal Pepadun, 2(1), 138–148. <https://doi.org/10.23960/pepadun.v2i1.39>.
- Sanil, G., Prakasha K., K., Prabhu, S., Nayak, V., & Jayakala, A. (2025): *Region-wise landmarks-based feature extraction employing SIFT, SURF, and ORB feature descriptors to recognize monozygotic twins from 2D/3D facial images*, F1000Research, 14, 444. <https://doi.org/10.12688/f1000research.162911.2>.
- Siam, A. I., Soliman, N. F., Algarni, A. D., Abd El-Samie, F. E., & Sedik, A. (2022): *Deploying machine learning techniques for human emotion detection*, Computational Intelligence and Neuroscience, 2022, 1–16. <https://doi.org/10.1155/2022/8032673>.
- Spreckelsen, F., Rüchardt, B., Lebert, J., Luther, S., Parlit, U., & Schlemmer, A. (2020): *Guidelines for a standardized filesystem layout for scientific data*, Data, 5(2), 43. <https://doi.org/10.3390/data5020043>.
- Wang, K., Peng, X., Yang, J., Meng, D., & Qiao, Y. (2020): *Region attention networks for pose and occlusion robust facial expression recognition*, IEEE Transactions on Image Processing, 29, 4057–4069. <https://doi.org/10.1109/TIP.2019.2956143>.
- Zhao, B., Wang, J., Ma, W., Jesslen, A., Yang, S., Yu, S., Zendel, O., Theobalt, C., Yuille, A. L., & Kortylewski, A. (2024): *OOD-CV-v2: An extended benchmark for robustness to out-of-distribution shifts of individual nuisances in natural images*, IEEE Transactions on Pattern Analysis and Machine Intelligence, 46(12), 11104–11118. <https://doi.org/10.1109/TPAMI.2024.3462293>.

Halaman ini sengaja dikosongkan