


TESIS

**PENGENALAN WAJAH DENGAN PROGRESI USIA MENGGUNAKAN  
METODE *HYBRID FEATURE* PADA FITUR TEKSTUR DAN FITUR  
GEOMETRI WAJAH**

***FACE AGE PROGRESSION USING HYBRID METHOD OF FACE  
TEXTURE AND GEOMETRIC FEATURES***



Oleh:  
**DIAH SEPTIANI**  
22/509181/PPA/06451

**PROGRAM MAGISTER KECERDASAN ARTIFISIAL  
DEPARTEMEN ILMU KOMPUTER DAN ELEKTRONIKA  
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
UNIVERSITAS GADJAH MADA  
2024**


TESIS

**PENGENALAN WAJAH DENGAN PROGRESI USIA MENGGUNAKAN  
METODE *HYBRID FEATURE* PADA FITUR TEKSTUR DAN FITUR  
GEOMETRI WAJAH**

***FACE AGE PROGRESSION USING HYBRID METHOD OF FACE  
TEXTURE AND GEOMETRIC FEATURES***

Diajukan untuk memenuhi salah satu syarat memperoleh derajat

*Master of Computer Science (AI)*



Oleh:  
**DIAH SEPTIANI**  
22/509181/PPA/06451

**PROGRAM MAGISTER KECERDASAN ARTIFISIAL  
DEPARTEMEN ILMU KOMPUTER DAN ELEKTRONIKA  
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
UNIVERSITAS GADJAH MADA  
2024**

**HALAMAN PENGESAHAN**

**TESIS**

**Pengenalan Wajah dengan Progresi Usia Menggunakan Metode  
Hybrid Feature pada Fitur Tekstur dan Fitur Geometri Wajah**

Telah dipersiapkan dan disusun oleh

**DIAH SEPTIANI**  
22/509181/PPA/06451

Telah dipertahankan di depan Tim Penguji  
pada tanggal 19 Juli 2024

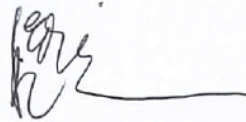
**Susunan Tim Penguji**

**Pembimbing Utama**



Wahyono, S.Kom., Ph.D.  
NIP. 111198709201711101

**Ketua Penguji**



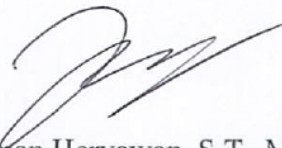
Moh. Edi Wibowo, S.Kom., M.Kom., Ph.D.  
NIP. 198109282005011001

**Anggota Penguji**



Dr. Agus Sihabuddin, S.Si., M.Kom.  
NIP. 197608102002121003

**Anggota Penguji**



Lukman Heryawan, S.T., M.T., Ph.D.  
NIP. 198010312015041001

Mengetahui,  
a.n. Dekan FMIPA UGM  
Wakil Dekan Bidang Pendidikan, Pengajaran  
dan Kemahasiswaan



Prof. Drs. Roto, M.Eng., Ph.D.  
NIP. 196711171993031020

Tesis ini telah diterima sebagai salah satu persyaratan  
untuk memperoleh gelar *Master of Computer Science in Artificial Intelligence*  
Yogyakarta, 19 Juli 2024



Afiahayati, S.Kom., M.Cs., Ph.D.  
Pengelola Program Studi Magister Kecerdasan Artifisial

## PERNYATAAN BEBAS PLAGIASI

Saya yang bertanda tangan di bawah ini :

Nama : Diah Septiani  
NIM : 22/509181/PPA/06451  
Tahun terdaftar : 2022  
Program Studi : Magister Kecerdasan Artifisial  
Fakultas : Matematika dan Ilmu Pengetahuan Alam

Menyatakan bahwa dalam dokumen ilmiah Tesis ini tidak terdapat bagian dari karya ilmiah lain yang telah diajukan untuk memperoleh gelar akademik di suatu Lembaga Pendidikan Tinggi, dan juga tidak terdapat karya atau pendapat yang pernah ditulis atau diterbitkan oleh orang/lembaga lain, kecuali yang secara tertulis disitasi dalam dokumen ini dan disebutkan sumbernya secara lengkap dalam daftar pustaka.

Dengan demikian saya menyatakan bahwa dokumen ilmiah ini bebas dari unsur-unsur plagiasi dan apabila dokumen ilmiah Tesis ini dikemudian hari terbukti merupakan plagiasi dari hasil karya penulis lain dan/atau dengan sengaja mengajukan karya atau pendapat yang merupakan hasil karya penulis lain, maka penulis bersedia menerima sanksi akademik dan/atau sanksi hukum yang berlaku.

Yogyakarta, 22 Mei 2024

Yang membuat pernyataan



(Diah Septiani)  
NIM 22/509181/PPA/06451

## PRAKATA

Puji syukur kehadiran Allah Subhanahu wa ta'ala atas limpahan rahmat, ridho, karunia serta petunjuk-Nya sehingga tugas akhir berupa penyusunan Tesis ini telah terlaksana dengan baik.

Dalam penyusunan Tesis ini penulis telah banyak mendapatkan dukungan, bimbingan, arahan, serta motivasi dari berbagai pihak. Oleh karena itu pada kesempatan ini penulis mengucapkan terima kasih kepada:

1. Bapak Wahyono, S.Kom., Ph.D. selaku pembimbing, yang telah memberikan arahan, bimbingan, serta kesabaran selama proses penelitian tugas akhir ini berlangsung.
2. Bapak Moh. Edi Wibowo, S.Kom., M.Kom., Ph.D. selaku ketua pengujian ujian tesis, serta Bapak Dr. Agus Sihabuddin, S.Si., M.Kom., dan Bapak Lukman Heryawan, S.T., M.T., Ph.D. selaku anggota pengujian ujian tesis.
3. Keluarga tercinta: Ummi, Bapak, Mas Arif & Mba Weni, Mba Asih & Mas Ari, Retno yang selalu menjadi sumber semangat dan do'a-do'a terbaik selama perjalanan penelitian ini.
4. Teman-teman seangkatan (Genap 2022): Annisa Zahra, Kurnia Puji, Arif Faishal Haq, Arrangi Toar.
5. Bapak Ibu dosen dan tenaga kependidikan di lingkungan Program Studi Magister Kecerdasan Artifisial, Departemen Ilmu Komputer dan Elektronika, Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Gadjah Mada, yang telah memberikan pengetahuan dan wawasan berharga selama masa studi.
6. Yayasan Pendidikan Telkom dan IT Telkom Purwokerto yang telah memberikan kemudahan dalam perizinan cuti untuk studi
7. Sahabat dan teman-teman penulis yang memberikan semangat kepada penulis selama masa studi.
8. Semua pihak yang tidak kami sebutkan satu per satu, yang telah memberikan dukungan moriil maupun materiil selama penelitian ini.

Kami menyadari bahwa penelitian ini masih memiliki keterbatasan dan ruang untuk perbaikan. Oleh karena itu, kami sangat mengharapkan dan menghargai kritik dan saran yang dapat memperbaiki penelitian kami. Akhir kata, kami berharap bahwa laporan penelitian ini dapat memberikan kontribusi kecil bagi pengembangan ilmu pengetahuan dan teknologi. Semoga penelitian ini dapat bermanfaat bagi banyak pihak. Terima kasih.

Yogyakarta, Mei 2024

Diah Septiani

## DAFTAR ISI

<b>HALAMAN PENGESAHAN TESIS.....</b>	<b>ii</b>
<b>PERNYATAAN BEBAS PLAGIASI .....</b>	<b>iii</b>
<b>PRAKATA .....</b>	<b>iv</b>
<b>DAFTAR ISI.....</b>	<b>vi</b>
<b>DAFTAR GAMBAR.....</b>	<b>viii</b>
<b>DAFTAR TABEL.....</b>	<b>x</b>
<b>INTISARI.....</b>	<b>xi</b>
<b>ABSTRACT .....</b>	<b>xii</b>
<b>BAB I PENDAHULUAN .....</b>	<b>1</b>
1.1 Latar Belakang Masalah.....	1
1.2 Rumusan Masalah .....	3
1.3 Batasan Masalah.....	3
1.4 Tujuan Penelitian .....	4
1.5 Manfaat Penelitian .....	4
1.6 Keaslian Penulisan .....	4
1.7 Sistematika Penulisan.....	4
<b>BAB II TINJAUAN PUSTAKA.....</b>	<b>6</b>
<b>BAB III LANDASAN TEORI.....</b>	<b>14</b>
3.1 Pengenalan Wajah.....	14
3.2 Progresi Usia pada Wajah .....	15
3.3 Representasi Citra Digital .....	16
3.3.1 Citra Warna .....	16
3.3.2 Citra <i>Grayscale</i> .....	17
3.3.3 Citra Biner .....	18
3.4 Pra-Pemrosesan .....	18
3.5 Ekstraksi Fitur .....	19
3.5.1 Ekstraksi Fitur Tekstur .....	20
3.5.2 Ekstraksi Fitur Geometri .....	23
3.6 <i>Support Vector Machine</i> .....	25
3.7 <i>Confusion Matrix</i> .....	28
<b>BAB IV METODOLOGI PENELITIAN.....</b>	<b>30</b>
4.1 Deskripsi Umum Penelitian .....	30

4.2	Akuisisi Data .....	31
4.3	Rancangan Model.....	33
4.3.1	<i>Algorithm Overview</i> .....	33
4.3.2	Pra-Pemrosesan .....	35
4.3.3	Ekstraksi Fitur .....	36
4.3.4	Penggabungan Fitur.....	43
4.3.5	Pemodelan (Pengenalan Wajah).....	45
4.4	Rancangan Pengujian .....	47
<b>BAB V IMPLEMENTASI.....</b>		<b>49</b>
5.1	Deskripsi Implementasi.....	49
5.1.1	Citra Masukan .....	49
5.1.2	Prapemrosesan Citra/ <i>Preprocessing</i> .....	51
5.1.3	Ekstraksi Fitur .....	53
5.1.4	<i>Support Vector Machine</i> .....	59
<b>BAB VI HASIL DAN PEMBAHASAN.....</b>		<b>61</b>
6.1	Hasil Pembagian Data .....	61
6.2	Hasil Prapemrosesan Data.....	62
6.3	Hasil Ekstraksi Fitur.....	64
<b>BAB VII KESIMPULAN DAN SARAN .....</b>		<b>88</b>
7.1	Kesimpulan .....	88
7.2	Saran.....	88
<b>DAFTAR PUSTAKA .....</b>		<b>90</b>
<b>LAMPIRAN.....</b>		<b>93</b>

## DAFTAR GAMBAR

Gambar 3. 1 Sistem Koordinat yang Dipergunakan untuk Mewakili Citra (Andono et al., 2017).....	16
Gambar 3. 2 Citra Warna dengan Komponen Warna R ( <i>Red</i> ), G ( <i>Green</i> ), dan B ( <i>Blue</i> ) (Andono et al., 2017) .....	17
Gambar 3. 3 Citra <i>Grayscale</i> dengan Nilai Piksel Antara 0 Sampai dengan 255 (Andono et al., 2017) .....	18
Gambar 3. 4 Citra Biner dengan Nilai Piksel 0 atau 1 (Andono et al., 2017).....	18
Gambar 3. 5 Visualisasi Klasifikasi Multi-Kelas SVM .....	27
Gambar 4. 1 Tahapan Penelitian .....	30
Gambar 4. 2 Sampel Gambar Wajah dari Dataset FG-NET .....	32
Gambar 4. 3 Rancangan Model Penelitian.....	33
Gambar 4. 4 Arsitektur Pra-pemrosesan dan Ekstraksi Fitur.....	34
Gambar 4. 5 Tahapan Prapemrosesan .....	35
Gambar 4. 6 Ekstraksi Fitur .....	36
Gambar 4. 7 Alur Ekstraksi Fitur LBPH.....	38
Gambar 4. 8 Alur Ekstraksi Fitur HOG .....	39
Gambar 4. 9 Representasi Skema <i>Facial Landmarks</i> .....	40
Gambar 4. 10 Contoh Deteksi Wajah dan Landmark Wajah: (a) Input Gambar ( <i>frontal face</i> ), (b) Wajah dan Landmark Wajah yang Terdeteksi .....	41
Gambar 4. 11 Facial Animation Parameter Units (Pard & Bonafonte, 2002).....	42
Gambar 4. 12 (a.) <i>Hybrid Feature</i> LBPH dan HOG (b) LBPH dan <i>Facial Landmarks</i> , (c.) HOG dan <i>Facial Landmarks</i> , (d.) LBPH, HOG dan <i>Facial Landmarks</i> .....	43
Gambar 4. 13 Dataset yang Digunakan Selama Proses Pelatihan dan Pengujian. 46	
Gambar 5. 1 Potongan Kode Mengakses dan Membaca Dataset.....	50
Gambar 5. 2 Potongan Kode Pembagian Data Menjadi 82 Kelas.....	50
Gambar 5. 3 Potongan Kode Prapemrosesan Citra .....	51
Gambar 5. 4 Potongan Kode Mengubah dari RGB menjadi <i>Grayscale</i> .....	52
Gambar 5. 5 Potongan Kode Deteksi Wajah.....	52
Gambar 5. 6 Potongan Kode <i>Crop</i> Wajah.....	53
Gambar 5. 7 Citra Hasil Prapemrosesan .....	53
Gambar 5. 8 Potongan Kode LBPH.....	54
Gambar 5. 9 Potongan Kode HOG .....	55
Gambar 5. 10 Potongan Kode <i>Facial Landmarks</i> dan FAP.....	57
Gambar 5. 11 Potongan Kode Penggabungan Fitur .....	58
Gambar 5. 12 Potongan Kode PCA .....	59
Gambar 5. 13 Potongan Kode Menggunakan SVM.....	60
Gambar 6. 1 Hasil Prapemrosesan Gambar .....	63
Gambar 6. 2 Hasil Evaluasi Parameter LBPH Menggunakan Classifier SVM.....	65
Gambar 6. 3 Classification Report dan Confusion Matrix Model 1 LBPH Menggunakan classifier SVM.....	66
Gambar 6. 4 Hasil Evaluasi Parameter HOG Menggunakan <i>Classifier</i> SVM.....	68

Gambar 6. 5 <i>Classification Report</i> dan <i>Confusion Matrix</i> Model 2 HOG Menggunakan <i>classifier</i> SVM.....	69
Gambar 6. 6 <i>Classification Report</i> dan <i>Confusion Matrix</i> Model 3 <i>Facial Landmarks</i> Menggunakan <i>classifier</i> SVM.....	71
Gambar 6. 7 <i>Classification Report</i> dan <i>Confusion Matrix</i> Model 4 LBPH+ HOG Menggunakan <i>classifier</i> SVM.....	74
Gambar 6. 8 <i>Classification Report</i> dan <i>Confusion Matrix</i> Model 5 LBPH+ <i>Facial Landmarks</i> , FAP Menggunakan <i>classifier</i> SVM .....	76
Gambar 6. 9 <i>Classification Report</i> dan <i>Confusion Matrix</i> Model 6 HOG+ <i>Facial Landmarks</i> , FAP Menggunakan <i>Classifier</i> SVM .....	78
Gambar 6. 10 <i>Classification Report</i> dan <i>Confusion Matrix</i> Model 7 LBP+ HOG+ <i>Facial Landmarks</i> , FAP Menggunakan <i>Classifier</i> SVM.....	80
Gambar 6. 11 Evaluasi Perbandingan Model <i>Hybrid Feature</i> Menggunakan <i>Classifier</i> SVM.....	82
Gambar 6. 12 Perbandingan Performa Model Pengenalan Wajah dengan Progresi Usia Menggunakan <i>Classifier</i> SVM .....	84
Gambar 6. 13 Contoh Prediksi Model (a) Kelas yang Benar (b) Kelas yang Salah .....	85

## DAFTAR TABEL

Tabel 2. 1 Tinjauan Pustaka .....	12
Tabel 2. 1 Tinjauan Pustaka (Lanjutan) .....	13
Tabel 3. 1 Representasi Confusion Matrix .....	28
Tabel 4. 1 Deskripsi Dataset .....	32
Tabel 4. 2 Facial Animation Parameter (FAP).....	42
Tabel 4. 3 Penggabungan Fitur .....	45
Tabel 4. 4 Rencana Pengujian Sistem .....	48
Tabel 6. 1 Daftar Model Ekstraksi Fitur .....	61
Tabel 6. 2 Hasil Pembagian Data .....	62
Tabel 6. 3 Pengaruh Parameter LBP Menggunakan Classifier SVM .....	65
Tabel 6. 4 Hasil Evaluasi Parameter HOG Menggunakan Classifier SVM.....	67
Tabel 6. 5 Hasil Evaluasi Ekstraksi Fitur <i>Facial Landmarks</i> dan FAP Menggunakan <i>Classifier SVM</i> .....	70
Tabel 6. 6 Hasil Evaluasi <i>Hybrid Feature</i> LBPH dan HOG Menggunakan <i>Classifier SVM</i> .....	72
Tabel 6. 7 Hasil Evaluasi <i>Hybrid Feature</i> LBPH dan <i>Facial Landmarks</i> + FAP Menggunakan <i>Classifier SVM</i> .....	74
Tabel 6. 8 Hasil Evaluasi <i>Hybrid Feature</i> HOG dan <i>Facial Landmarks</i> , FAP Menggunakan <i>Classifier SVM</i> .....	76
Tabel 6. 9 Hasil Evaluasi <i>Hybrid Feature</i> LBP, HOG dan <i>Facial Landmarks</i> , FAP Menggunakan <i>Classifier SVM</i> .....	79
Tabel 6. 10 Hasil Evaluasi <i>Hybrid Feature</i> Menggunakan <i>Classifier SVM</i> .....	81
Tabel 6. 11 Pengujian Model Pengenalan Wajah dengan Progresi Usia Menggunakan SVM .....	83
Tabel 6. 12 Hasil Pengujian Model Menggunakan SVM .....	86

## INTISARI

### Pengenalan Wajah dengan Progresi Usia Menggunakan Metode *Hybrid Feature* pada Fitur Tekstur dan Fitur Geometri Wajah

Oleh

Diah Septiani

22/509181/PPA/06451

Pengenalan wajah merupakan teknologi penting dalam keamanan dan identifikasi personal, namun menghadapi tantangan unik saat mempertimbangkan progresi usia karena perubahan dinamis pada tekstur dan geometri wajah. Penelitian ini berfokus pada pengenalan wajah dengan progresi usia, menggunakan *Local Binary Pattern Histogram* (LBPH) dan *Histogram of Oriented Gradients* (HOG) untuk fitur tekstur serta *Facial Landmarks* dan *Facial Animation Parameters* (FAP) untuk fitur geometri wajah. Dataset yang digunakan mencakup variasi progresi usia tanpa mempertimbangkan perubahan gaya rambut.

Penelitian ini terdiri dari empat tahap utama: prapemrosesan, ekstraksi fitur, penggabungan fitur, dan klasifikasi. Tahap prapemrosesan mencakup konversi citra ke grayscale, deteksi wajah, pemotongan wajah, dan mengubah ukuran citra agar berukuran seragam. Ekstraksi fitur difokuskan pada kombinasi berbagai jenis fitur, seperti LBPH dengan HOG, LBPH dengan *landmarks* wajah, HOG dengan *landmarks* wajah, serta gabungan ketiganya (LBPH, HOG, dan *landmarks* wajah). Dataset FGNET yang terdiri dari 82 subjek atau kelas digunakan sebagai landasan evaluasi komprehensif untuk pengujian metode ini.

Tujuan utama penelitian ini adalah mengusulkan pendekatan hibrid guna meningkatkan akurasi pengenalan wajah berdasarkan progresi usia dengan mengintegrasikan fitur tekstur dan geometri wajah. Hasil penelitian menunjukkan bahwa kombinasi fitur HOG dan *facial landmarks* mencapai performa terbaik dengan akurasi 64%, presisi 69%, *recall* 64%, dan *F1-score* 63%. Integrasi fitur ini dapat meningkatkan performa sistem dalam menghadapi variasi usia yang kompleks.

Penelitian ini memberikan kontribusi signifikan terhadap pengenalan wajah yang lebih akurat dengan memanfaatkan dataset FGNET dan *Support Vector Machine* (SVM). Pendekatan hibrid ini mampu menangkap perubahan wajah yang terjadi seiring bertambahnya usia, sehingga meningkatkan performa sistem pengenalan wajah.

**Kata Kunci:** Pengenalan Wajah, Progresi Usia, *Hybrid Feature*, Tekstur Wajah, Geometri Wajah, *Super Vector Machine* (SVM)

## ABSTRACT

### ***FACE AGE PROGRESSION USING HYBRID METHOD OF FACE TEXTURE AND GEOMETRIC FEATURES***

By

Diah Septiani

22/509181/PPA/06451

*Facial recognition is a crucial technology in security and personal identification, but it faces unique challenges when considering age progression due to the dynamic changes in facial texture and geometry. This research focuses on age progression in facial recognition, utilizing Local Binary Pattern Histogram (LBPH) and Histogram of Oriented Gradients (HOG) for texture features, and Facial Landmarks and Facial Animation Parameters (FAP) for geometric features. The dataset is meticulously curated to include age progression variations while intentionally excluding factors such as hairstyle changes.*

*This study comprises four main stages: pre-processing, feature extraction, feature fusion, and classification. The pre-processing stage includes converting images to grayscale, face detection, face cropping, and resizing. Feature extraction focuses on combining various feature types, such as LBPH with HOG, LBPH with facial landmarks, HOG with facial landmarks, and the combination of all three (LBPH, HOG, and facial landmarks). The FGNET dataset, consisting of 82 subjects or classes, is used as a comprehensive evaluation basis for testing these methods.*

*The primary goal of this research is to propose a hybrid approach to improve facial recognition accuracy based on age progression by integrating texture and geometric features. The results show that the combination of HOG and facial landmarks achieves the best performance with an accuracy of 64%, a precision of 69%, recall of 64%, and an F1-score of 63%. This feature integration is expected to enhance system performance in handling complex age variations.*

*This study makes a significant contribution to more accurate facial recognition by leveraging the FGNET dataset and Support Vector Machine (SVM). The hybrid approach effectively captures facial changes that occur with aging, thereby improving the performance of facial recognition systems.*

**Keywords:** *Face Recognition, Age Progression, Hybrid Feature, Facial Texture, Facial Geometry, Support Vector Machine (SVM)*

# BAB I

## PENDAHULUAN

### 1.1 Latar Belakang Masalah

Pengenalan wajah telah menjadi salah satu teknologi yang semakin penting dalam bidang kecerdasan buatan dan pengenalan pola. Aplikasi pengenalan wajah telah meluas dan digunakan dalam berbagai bidang, seperti biometrik, sistem keamanan, pengawasan, manajemen pengguna, dan komunikasi antarmanusia. Meskipun telah ada kemajuan yang signifikan dalam teknologi ini, pengenalan wajah pada berbagai tahap usia tetap merupakan tantangan yang kompleks di mana penampilan wajah seseorang dapat berubah secara signifikan seiring bertambahnya usia (Mehrabi & Boroujeni, 2021). Perubahan ini melibatkan pergeseran fitur geometri dan tekstur pada wajah, yang membuat tugas pengenalan semakin kompleks. Oleh karena itu, diperlukan pendekatan yang inovatif dan efisien untuk mengatasi masalah pengenalan wajah dengan progresi usia. Pengenalan wajah dengan akurasi tinggi pada berbagai rentang usia menjadi krusial mengingat pertumbuhan populasi lanjut usia (Munasinghe *et al.*, 2018).

Data statistik menunjukkan bahwa usia merupakan faktor penting dalam mengenali wajah dengan akurasi tinggi. Berdasarkan studi dari Badan Pusat Statistik (BPS) pada tahun 2020, pertumbuhan populasi di banyak negara semakin menuju pola penuaan penduduk. Sebagai contoh, di Indonesia, persentase populasi lanjut usia (di atas usia 60 tahun) diperkirakan mencapai 9,8% dari total populasi pada tahun 2020, dan diperkirakan akan terus meningkat di masa depan.

Dalam pembuatan e-KTP, gambar wajah yang diambil pada usia muda mungkin tidak lagi mewakili penampilan aktual individu saat mereka bertambah usia. Oleh karena itu, integrasi suatu sistem estimasi usia yang mampu mengenali perubahan wajah seiring bertambahnya usia dapat memiliki dampak positif pada validitas dan keamanan e-KTP. Penggunaan dokumen foto KTP sebagai *dataset* akan menghasilkan dampak *age progression* yang berbeda dibandingkan dengan dokumen foto lain dalam pemanfaatannya. Sebagai contohnya, saat digunakan dalam sistem pengenalan wajah berbasis absensi perkantoran, data dapat diperbarui

secara berkala. Namun, ketika berbicara tentang penggunaan KTP, foto KTP diambil sekali dan digunakan selama rentang waktu berlaku KTP tersebut. Oleh karena itu, ketika kita memanfaatkan foto KTP sebagai *dataset*, *age progression* akan berpengaruh saat mencoba memprediksi identitas berdasarkan foto saat ini (Usgan et al., 2021).

Perbedaan tampilan wajah seiring bertambahnya usia menjadi tantangan serius dalam sistem pengenalan wajah. Faktor progresi usia menyebabkan perubahan yang kompleks pada tekstur dan geometri wajah, yang mengakibatkan variasi dalam ciri-ciri visualnya. Sebagai contoh, kerutan, garis wajah, dan distribusi tekstur kulit berubah seiring dengan penuaan, sehingga mempengaruhi kemampuan sistem pengenalan untuk mengenali wajah dengan akurat (Sharifisoraki et al., 2023).

Salah satu pendekatan yang menarik adalah yang menggabungkan fitur-fitur hibrida dan optimisasi *Particle Swarm Optimization* (PSO). Penelitian oleh Mehrabi et al., 2021, menyajikan sebuah metode untuk estimasi usia berbasis citra wajah yang mengintegrasikan informasi dari berbagai metode ekstraksi fitur. Fitur-fitur tersebut meliputi *Gabor wavelets*, *Local Binary Pattern*, *Local Phase Quantization*, dan *Histogram of Oriented Gradients*. Integrasi fitur-fitur ini bertujuan untuk meningkatkan ketepatan estimasi usia dengan memperoleh informasi yang lebih komprehensif dari wajah.

Selain itu, penelitian tersebut menggunakan *Particle Swarm Optimization* (PSO) sebagai algoritma optimasi untuk memilih fitur-fitur yang paling relevan dan informatif dalam estimasi usia. Hasil penelitian menunjukkan bahwa model dapat mengekstraksi fitur-fitur yang paling signifikan untuk estimasi usia, sehingga dapat meningkatkan akurasi dan mencapai *Mean Absolute Error* (MAE) yang lebih baik dalam estimasi usia berbasis citra wajah dengan mempertimbangkan progresi usia (Mehrabi & Boroujeni, 2021).

Berdasarkan referensi sebelumnya, di mana penelitian menggunakan pendekatan hibrida dengan menggabungkan fitur-fitur dari beberapa metode ekstraksi fitur dan algoritma optimasi PSO, menghasilkan kinerja yang lebih unggul.

Dalam mencapai MAE yang lebih baik, penelitian ini dapat mengoptimalkan pilihan fitur-fitur yang paling relevan dan informatif dalam estimasi usia. Model *machine learning SVM hybrid* yang digunakan juga dapat diperbaiki dengan mempertimbangkan pendekatan yang lebih canggih dalam memadukan fitur tekstur dan fitur geometri wajah. Selain itu, penelitian ini dapat mengevaluasi berbagai teknik pra-pemrosesan dan normalisasi data untuk meningkatkan akurasi dan mengurangi efek *noise* yang mungkin muncul dalam dataset (Bhavani et al., 2023).

Fitur tekstur wajah melibatkan analisis pola dan tekstur pada permukaan wajah, sementara fitur geometri wajah berfokus pada struktur geometris seperti posisi titik-titik kunci pada wajah. Integrasi fitur-fitur ini diharapkan dapat meningkatkan kinerja sistem pengenalan wajah, khususnya dalam mengenali wajah yang mengalami perubahan akibat progresi usia (N.P. Gopalan, 2018).

Pendekatan *hybrid* ini diharapkan juga dapat mengurangi angka *false acceptance* dan *false rejection* dalam pengenalan wajah, yang merupakan masalah umum dalam sistem pengenalan wajah tradisional. Dengan demikian, metode ini dapat meningkatkan tingkat keandalan dan akurasi dalam mengenali identitas individu dengan progresi usia (Hu et al., 2017).

## 1.2 Rumusan Masalah

Pengenalan wajah dengan progresi usia memiliki tantangan yang kompleks yaitu perubahan tekstur dan geometri wajah yang dapat menyebabkan variasi visual yang signifikan sehingga dapat menyebabkan performa tidak optimal.

## 1.3 Batasan Masalah

Penelitian ini memiliki beberapa batasan masalah yaitu:

1. Penelitian hanya berfokus pada pengenalan wajah dengan progresi usia, tidak mempertimbangkan faktor lain seperti perubahan gaya rambut atau penampilan fisik lainnya.
2. Data yang digunakan untuk penelitian ini terbatas pada dataset yang mencakup variasi progresi usia, yaitu menggunakan dataset FG-NET.
3. Dataset yang digunakan merupakan dataset wajah tampak depan (*frontal face*)

4. Algoritma klasifikasi yang digunakan yaitu *Support Vector Machine* (SVM)
5. Evaluasi model yang digunakan adalah akurasi, presisi, *recall* dan *f1-score*.

#### 1.4 Tujuan Penelitian

Penelitian ini bertujuan untuk mencapai beberapa tujuan berikut:

1. Mengusulkan pendekatan hybrid untuk mengatasi masalah pengenalan wajah dengan progresi usia.
2. Meningkatkan performa pengenalan wajah berdasarkan progresi usia dengan menggabungkan fitur tekstur (*Local Binary Pattern Histogram* (LBPH) dan *Histogram of Oriented Gradients* (HOG)) dan fitur geometri wajah (*Facial Landmarks*).

#### 1.5 Manfaat Penelitian

Manfaat dari penelitian ini diharapkan dapat meliputi:

1. Kontribusi dalam pengembangan teknologi pengenalan wajah yang lebih akurat dengan mempertimbangkan progresi usia.
2. Penggunaan pendekatan *hybrid feature* dengan memadukan fitur tekstur dan fitur geometri wajah untuk meningkatkan kinerja sistem pengenalan.

#### 1.6 Keaslian Penulisan

Penelitian sebelumnya telah menunjukkan potensi dari metode pengenalan wajah, tetapi sedikit yang membahas secara khusus mengenai pengaruh perubahan progresi usia dan yang menggunakan *hybrid feature*. Oleh karena itu, penelitian ini memberikan kontribusi baru dalam memahami dan mengatasi masalah tersebut.

#### 1.7 Sistematika Penulisan

Garis besar penulisan laporan penelitian ini terdiri dari tujuh bab, yaitu:

##### BAB I: PENDAHULUAN

Bab ini berisi uraian latar belakang penelitian, rumusan masalah yang akan diselesaikan, batasan masalah penelitian, tujuan dilakukannya penelitian, manfaat penelitian, dan sistematika penulisan laporan penelitian.

##### BAB II. TINJAUAN PUSTAKA

Bab ini berisi penelitian-penelitian terkait pengenalan wajah dengan menggunakan beberapa model pada fitur tekstur dan fitur geometri wajah.

### BAB III. LANDASAN TEORI

Bab ini berisi teori-teori terkait semua metode yang digunakan untuk menyelesaikan permasalahan dalam penelitian ini.

### BAB IV. METODE PENELITIAN

Bab ini berisi tentang deskripsi umum penelitian, proses akuisisi data, rancangan algoritma atau pemodelannya, dan rancangan pengujian yang dilakukan dalam penelitian ini.

### BAB V. IMPLEMENTASI SISTEM

Implementasi sistem membahas tentang implementasi sistem menggunakan bahasa pemrograman yang telah dilakukan

### BAB VI. HASIL DAN PEMBAHASAN

Bab VI mencakup hasil dan pembahasan dari implementasi sistem yang telah dilakukan. Di dalamnya terdapat analisis hasil yang diperoleh dari sistem tersebut.

### BAB VII. KESIMPULAN DAN SARAN

Pada bab VII atau bab terakhir memuat kesimpulan dari hasil penelitian yang dilakukan dan memuat saran-saran yang dapat dikembangkan untuk penelitian selanjutnya.

## **BAB II**

### **TINJAUAN PUSTAKA**

Dalam literatur terkait, banyak penelitian telah menggambarkan dampak penuaan atau progresi usia terhadap kinerja algoritma pengenalan wajah. Sejumlah penelitian sebelumnya menyoroiti variasi akurasi pengenalan wajah berdasarkan kelompok usia, mengindikasikan bahwa perubahan morfologis wajah seiring bertambahnya usia dapat menjadi tantangan bagi algoritma (Boussaad & Boucetta, 2021).

Penelitian (Boussaad & Boucetta, 2021) memiliki kelebihan signifikan dalam pendekatannya yang membandingkan dua metode berbeda, yaitu 2D-DCT dan KFA dibandingkan dengan CNN dan SVM, memberikan wawasan mendalam tentang dampak teknik deskripsi dan klasifikasi wajah terhadap akurasi algoritma pengenalan. Selain itu, kegunaan database wajah FG-NET yang dapat diakses publik menambah reliabilitas temuan, memfasilitasi generalisasi hasil pada populasi yang lebih luas. Meskipun demikian, penelitian ini tidak terlepas dari kelemahan yaitu perbandingan antara dua pendekatan memberikan wawasan berharga, penelitian ini tidak melibatkan eksplorasi lebih lanjut terhadap parameter khusus dari masing-masing metode.

Penelitian (Baruni et al., 2021) membahas tentang *Age-Invariant Face Recognition* (AIFR), teknologi biometrik yang digunakan dalam surveilans dan penegakan hukum. Tantangan dalam pengenalan wajah timbul dari perubahan penampilan wajah yang signifikan akibat penuaan, memengaruhi aplikasi seperti verifikasi paspor dan SIM, serta pencarian individu yang hilang setelah waktu yang lama. Tujuan utama AIFR adalah mengekstrak fitur usia-invariant diskriminatif untuk identifikasi yang akurat pada berbagai rentang usia.

Tiga metode utama dieksplorasi untuk mengatasi variasi penampilan wajah akibat penuaan: generatif (menggunakan simulasi penuaan), diskriminatif (berbasis fitur), dan jaringan saraf tiruan. Studi ini meninjau dan membandingkan metode AIFR terkini, dengan fokus pada tahap pra-pemrosesan dan ekstraksi fitur.

Keunikannya terletak pada analisis upaya untuk mengurangi perbedaan antara gambar wajah permintaan dan terdaftar yang diambil selama perkembangan usia.

Hasil penelitian menunjukkan kemajuan dalam metode AIFR, namun tantangan masih ada. Metode generatif mensimulasikan penuaan, metode diskriminatif berfokus pada ekstraksi fitur usia-invariant, dan jaringan saraf tiruan berkontribusi pada peningkatan pengenalan. Kelemahan meliputi potensi ketidakakuratan dalam simulasi penuaan, keterbatasan dalam ekstraksi fitur diskriminatif, dan kompleksitas komputasional dalam pendekatan pembelajaran mendalam. Meskipun ada tantangan, AIFR perlu untuk meningkatkan keandalan pengenalan wajah di berbagai kelompok usia, dengan penelitian terus dilakukan untuk mengatasi keterbatasan saat ini dan meningkatkan kinerja (Baruni et al., 2021).

Dalam sistem komputer, identitas individu manusia dapat ditetapkan melalui sistem pengenalan wajah. Keefektifan sistem pengenalan wajah memiliki banyak tantangan, salah satunya adalah invariansi usia. Sistem pengenalan wajah dengan invariansi usia membuatnya tangguh tetapi implementasinya sangat menuntut. Penuaan membawa banyak perubahan dalam struktur dan bentuk wajah. Dalam penelitian (Barde & Sinha, 2022), sistem pengenalan wajah invarian usia yang terdiri dari empat tahap yaitu deteksi wajah, pra-pemrosesan gambar, ekstraksi Fitur, dan klasifikasi Fitur. Tahap deteksi wajah mendeteksi wajah dalam gambar. Pemrosesan gambar melibatkan penyesuaian frontal wajah, pemangkasan, dan penghilangan *noise*. Principal Component Analysis (PCA) digunakan untuk mengekstrak fitur wajah dalam gambar. Hasil analisis ini mencapai fitur yang relevan untuk pengenalan wajah invarian usia. Terakhir, untuk klasifikasi digunakan Multi Support Vector Machine. Hasilnya menunjukkan bahwa sistem dapat digunakan secara efisien dalam proses identifikasi individu otomatis dan mengatasi tantangan yang dihadapi oleh penuaan.

Pada pengenalan wajah berdasarkan estimasi usia citra wajah dengan menggunakan pendekatan yang menggabungkan fitur-fitur hibrida dan optimisasi *Particle Swarm Optimization* (PSO) bertujuan untuk meningkatkan akurasi pengenalan wajah berdasarkan estimasi usia dengan menggabungkan informasi dari

beberapa metode ekstraksi fitur, termasuk *Gabor wavelets*, *Local Binary Pattern*, *Local Phase Quantization*, dan *Histogram of Oriented Gradients*. Selain itu, mereka menggunakan PSO sebagai algoritma optimasi untuk memilih fitur-fitur yang paling relevan dan informatif. Dalam pengujian menggunakan dua dataset terkenal, FGNET dan MORPH, hasil eksperimen menunjukkan tingkat akurasi yang memuaskan, dengan *Mean Absolute Error* (MAE) mencapai 3.34 tahun pada dataset FGNET dan 3.21 tahun pada dataset MORPH. Penelitian ini memberikan kontribusi penting dalam pengembangan sistem estimasi usia yang efektif dan dapat diterapkan pada berbagai bidang, termasuk biometrik, keamanan, komersial, militer, dan interaksi dengan komputer (Mehrabi & Boroujeni, 2021).

Penelitian (Hu et al., 2017) bertujuan untuk mengatasi tantangan dalam estimasi usia wajah dalam bidang pengenalan citra dan pola komputer. Masalah utama yang dihadapi adalah ketergantungan pada dataset wajah besar yang sudah berlabel usia, yang terbatas dalam pemanfaatan data pelatihan yang tidak berlabel atau berlabel lemah, seperti gambar-gambar dari jaringan sosial. Untuk meningkatkan akurasi estimasi usia, penelitian ini dengan skema pembelajaran baru memanfaatkan data lemah berlabel melalui jaringan saraf konvolusi mendalam. Dalam pendekatan ini, informasi perbedaan usia dari pasangan gambar orang yang sama digunakan untuk membantu memahami usia wajah secara gradual. Selain itu, penelitian ini juga berkontribusi dengan menciptakan dataset yang terdiri dari lebih dari 100.000 gambar wajah dengan label tanggal pengambilan dan identitas orang. Hasil eksperimen pada dua basis data wajah yang sudah menua menunjukkan keunggulan sistem pembelajaran perbedaan usia, dengan mencapai kinerja terbaik dalam estimasi usia (MAE 2,78) yang mengalahkan hasil pendekatan lain. Penelitian ini menyoroti pentingnya pemanfaatan data berlabel lemah dan informasi perbedaan usia untuk meningkatkan akurasi estimasi usia wajah tanpa harus mengandalkan dataset sepenuhnya berlabel.

Pengembangan model pengenalan wajah menggunakan fitur spasial dengan ekstraksi menggunakan metode *Local Binary Patterns* (LBP) dan pengurangan dimensi dengan *Principal Component Analysis* (PCA) untuk mempermudah visualisasi dan analisis data (Santhosh & Rajashekaradhy, 2023). Selanjutnya,

fitur-fitur hasil PCA diteruskan ke dalam algoritma Optimized Support Vector Machine (OSVM) yang dioptimasi menggunakan algoritma Rat Swarm Optimizer (RSO) untuk melakukan proses pengenalan wajah. Penelitian ini mengumpulkan dataset gambar standar yang telah diolah dengan teknik median filtering untuk mendapatkan gambar yang telah diproses secara optimal. Hasil penelitian menunjukkan bahwa model RSO-OSVM menghasilkan tingkat akurasi yang lebih tinggi daripada pendekatan lain seperti CSO-OSVM, COA-OSVM, MFO-OSVM, dan SOA-OSVM dengan peningkatan akurasi sebesar 7%, 5%, 4%, dan 4% di atas model-model tersebut. Dengan demikian, pendekatan ini berhasil mencapai tingkat pengenalan yang lebih akurat dalam proses pengenalan wajah.

Pengenalan emosi wajah dalam interaksi manusia-komputer dengan tujuan memberikan kemampuan pada komputer untuk memprediksi keadaan emosional manusia melalui observasi ekspresi, perilaku, dan emosi mereka, sehingga memungkinkan komputer berkomunikasi secara emosional dengan manusia (Sun et al., 2021). Untuk mencapai tujuan tersebut, penelitian ini menggunakan dua metode ekstraksi fitur dari gambar wajah, yaitu *Linear Discriminant Analysis* (LDA) dan deteksi *landmark* wajah setelah proses grayscale dan pemangkasan gambar. Setelah dilakukan pengujian, hasil menunjukkan bahwa metode deteksi *landmark* wajah menghasilkan akurasi pengenalan emosi sebesar 84,5%, yang lebih tinggi dibandingkan dengan metode LDA yang mencapai 73,9%. Hal ini menunjukkan bahwa penggunaan *landmark* wajah dapat lebih akurat dalam mengidentifikasi emosi dalam gambar wajah. Dengan demikian, penelitian ini menyajikan potensi aplikasi *landmark* wajah untuk meningkatkan kemampuan pengenalan emosi pada komputer dalam interaksi dengan manusia.

Pada tahun 2023, (Sharifisoraki et al., 2023) melakukan penelitian dengan menyajikan pendekatan baru untuk pengenalan wajah yang inovatif dengan menggunakan nilai-nilai spesifik yang diekstraksi dari *landmark* wajah berbasis *Deep Neural Network*. Selama satu dekade terakhir, deteksi *landmark* wajah telah menjadi subjek penelitian yang terus berkembang karena peran pentingnya dalam aplikasi seperti pengenalan wajah, analisis ekspresi wajah, dan tujuan keamanan. Dalam penelitian ini, algoritma baru dimanfaatkan dengan menggunakan teknik

deteksi landmark wajah berbasis *deep learning* untuk mengambil fitur utama dari gambar wajah. Tiga nilai spesifik (jarak kosinus, sudut, dan luas) dihasilkan dari koordinat *landmark* wajah dan digunakan sebagai fitur dalam proses pengenalan wajah. Penggunaan nilai khusus ini merupakan sumbangan utama penelitian ini dan berbeda dari pendekatan sebelumnya.

Penelitian ini menguji kinerja metode melalui beberapa eksperimen untuk mengevaluasi tingkat pengenalan wajah dengan memanfaatkan fitur-fitur khusus tersebut. Hasil eksperimen menunjukkan bahwa fitur luas memberikan hasil terbaik dalam pengenalan wajah. Selain itu, penelitian ini juga mempertimbangkan pengaruh peningkatan jumlah landmark wajah dalam proses pengenalan dengan menggunakan algoritma *Media Pipe face mesh*. Dengan mempertahankan *landmark* yang sama, penelitian ini melaporkan hasil pengenalan wajah dengan jumlah landmark yang berbeda. Hasil eksperimen menunjukkan bahwa penggunaan sudut sebagai nilai khusus memberikan peningkatan tingkat pengenalan wajah yang lebih baik ketika jumlah *landmark* ditingkatkan. Penemuan ini dapat menjadi langkah maju dalam pengenalan wajah dan memberikan arahan untuk penelitian lebih lanjut dalam mengoptimalkan jumlah landmark dan nilai khusus yang digunakan untuk tujuan pengenalan wajah yang lebih akurat.

Penelitian *Facial Expression Recognition* menggunakan *Geometric Landmark Points* dan *Convolutional Neural Networks* yang dilakukan oleh (N.P. Gopalan, 2018) berfokus pada pengenalan ekspresi wajah (*Facial Expression Recognition/ FER*) dalam interaksi manusia dan komputer. Secara umum, teknik FER mengandung tiga tahap: ekstraksi fitur, reduksi dimensi, dan klasifikasi. Reduksi dimensi dan seleksi fitur merupakan masalah utama dalam FER. Pengolahan gambar secara keseluruhan membutuhkan memori dan pengolahan yang besar. Namun, penelitian ini menawarkan alternatif yang lebih cocok dengan menggunakan fitur geometris. Dalam penelitian ini, deteksi *landmark* wajah digunakan untuk ekstraksi fitur dan Pengklasifikasi Jaringan Saraf Konvolusi. Metode ini diuji pada dataset benchmark yang tersedia secara publik, seperti JAFFE, MUG, CK, dan MMI. Hasil pengujian menunjukkan bahwa metodologi yang tersebut berhasil mengungguli metode-metode yang ada dalam literatur.

Pengenalan Ekspresi Wajah memiliki aplikasi dalam berbagai bidang seperti keamanan, kesehatan, dan lainnya. Penggunaan *landmark* wajah untuk ekstraksi fitur memiliki keunggulan klasifikasi yang sangat kokoh bahkan dengan memori terbatas. Penggunaan Jaringan Saraf Konvolusi (CNN) juga telah meningkatkan kinerja pengenalan secara signifikan dibandingkan dengan metode lain yang terdapat dalam literatur. Metode ini berhasil mencapai tingkat pengenalan rata-rata sebesar 84,00%, 89,19%, 85,42%, dan 84,33% untuk masing-masing dataset yang diuji.

Penelitian yang dilakukan oleh (Xiong et al., 2018) bertujuan untuk mengidentifikasi emosi wajah menggunakan *landmark* wajah dan klasifikasi *random forest*. Metode yang digunakan mencakup identifikasi wajah dengan *histogram of oriented gradients* dan klasifikasi linier, serta identifikasi *landmark* wajah dengan model yang dilatih menggunakan dataset iBUG 300-W. Selanjutnya, dilakukan penghitungan vektor fitur, dengan proses normalisasi untuk menghilangkan variasi ukuran wajah. Pengenalan emosi wajah dilakukan dengan menggunakan klasifikasi *random forest*. Pengujian dilakukan pada database Cohn-Kanade (CK+) dan mencapai akurasi rata-rata sebesar 90%, yang menunjukkan hasil yang lebih baik daripada beberapa metode sebelumnya dengan akurasi antara 80% hingga 100%. Hasil ini menunjukkan bahwa metode tersebut mampu memberikan hasil yang menjanjikan dalam pengenalan emosi wajah berdasarkan *landmark* wajah dan klasifikasi *random forest*.

Penelitian ini berfokus pada pengenalan wajah dengan progresi usia melalui pendekatan *hybrid*, yang menggabungkan fitur tekstur dan fitur geometri, dengan memanfaatkan elemen baru berupa atribut geometri yang sebelumnya belum dieksplorasi dalam penelitian yang ada. Tidak hanya untuk meningkatkan akurasi pengenalan wajah, tetapi juga memperluas wawasan dalam memahami interaksi rumit antara geometri wajah dan progresi usia. Dengan pendekatan yang memanfaatkan baik tekstur maupun geometri diharapkan memberikan hasil yang lebih kuat dan akurat. Beberapa penelitian sebelumnya yang relevan dengan topik ini telah dirangkum pada Tabel 2.1.

Tabel 2. 1 Tinjauan Pustaka

No	Nama	Penelitian	Keterangan
1	Boussaad & Boucetta, 2021	<i>The Aging Effects on Face Recognition Algorithms: The Accuracy According to Age Group and Age Gaps</i>	<ul style="list-style-type: none"> <li>• Peningkatan kinerja menggunakan CNN dan SVM pada pengenalan wajah</li> <li>• Tidak melibatkan eksplorasi lebih lanjut terhadap parameter</li> </ul>
2	Baruni et al., 2021	<i>Age Invariant Face Recognition Methods: A Review</i>	<ul style="list-style-type: none"> <li>• Mengevaluasi metode-metode <i>Age- Invariant Face Recognition</i> (AIFR) yang melibatkan <i>generative methods</i> (simulasi penuaan), <i>discriminative methods</i> (ekstraksi fitur), dan <i>deep neural networks</i>.</li> </ul>
3	Barde & Sinha, 2022	<i>Face Recognition Across Age Progression by Using PCA</i>	<ul style="list-style-type: none"> <li>• Menunjukkan keefisienan dalam identifikasi individu otomatis dan mengatasi tantangan penuaan dengan akurasi 95,77.</li> </ul>
4	Mehrabi & Boroujeni, 2021	<i>Age Estimation Based on Facial Images Using Hybrid Features and Particle Swarm Optimization</i>	<ul style="list-style-type: none"> <li>• Ekstraksi Fitur: GW, LBP, LPQ, HOG</li> <li>• Fusi Fitur, PSO, Klasifikasi dengan SVM dan Regresi SVR.</li> <li>• Hasil evaluasi pada basis data: FG-NET: MAE= 3,34 tahun, akurasi klasifikasi= 75,69%; MORPH: MAE= 3,21 tahun, Akurasi Klasifikasi= 81,66%.</li> </ul>
5	Hu et al., 2017	<i>Facial Age Estimation with Age Difference</i>	<ul style="list-style-type: none"> <li>• <i>Deep Convolutional Neural Networks, Kullback- Leibler Divergence, Entropy Loss, Cross Entropy Los</i></li> <li>• <i>Mean Absolute Error</i> (MAE) pada dataset berlabel usia berkurang dari 3,13 menjadi 2,78, yang merupakan hasil terbaik yang diketahui.</li> </ul>

Tabel 2. 2 Tinjauan Pustaka (Lanjutan)

No	Nama	Penelitian	Keterangan
6	Santhosh & Rajashekarar adhya, 2023	<i>A Design of Face Recognition Model with Spatial Feature Extraction using Optimized Support Vector Machine</i>	<ul style="list-style-type: none"> <li>• PCA</li> <li>• LBP</li> <li>• SVM dengan RSO Tingkat pengenalan lebih akurat dibandingkan dengan pendekatan lain.</li> </ul>
7	Sun <i>et al.</i> , 2021	Analisis Diskriminan Linier (LDA) dan Deteksi Landmark	<ul style="list-style-type: none"> <li>• Akurasi= 73,9% dengan metode LDA, dan 84,5% dengan metode Deteksi Landmark Wajah</li> </ul>
8	Sharifisoraki <i>et al.</i> , 2023	<i>A Novel Face Recognition Using Specific Values from Deep Neural Network-based Landmarks</i>	<ul style="list-style-type: none"> <li>• Hasil tingkat pengenalan wajah dengan menggunakan luas sebagai fitur khusus mencapai hasil terbaik.</li> </ul>
9	N.P. Gopalan, 2018	<i>Facial Expression Recognition using Geometric Landmark Points and Convolutional Neural Networks</i>	<ul style="list-style-type: none"> <li>• Hasilnya mengungguli metode-metode yang sudah ada dalam literatur.</li> </ul>
10	Xiong <i>et al.</i> , 2018	<i>Facial Expression Recognition Using Facial Landmarks and Random Forest Classifier</i>	<ul style="list-style-type: none"> <li>• Database Cohn-Kanade (CK+).</li> <li>• Akurasi= 90% pada pengujian.</li> <li>• Lebih baik dibandingkan dengan beberapa metode sebelumnya dengan akurasi 80% hingga 100%.</li> </ul>

## **BAB III**

### **LANDASAN TEORI**

#### **3.1 Pengenalan Wajah**

Pengenalan wajah merupakan suatu teknik penting dalam pengolahan citra yang bertujuan untuk mengidentifikasi atau memverifikasi individu berdasarkan fitur-fitur unik yang terdapat pada wajah manusia (Usgan et al., 2021). Wajah adalah salah satu bagian paling khas dari tubuh manusia yang membawa sejumlah besar informasi penting. Wajah merupakan salah satu atribut manusia yang digunakan dalam proses identifikasi (Guo & Zhang, 2019). Setiap individu memiliki ciri dan struktur wajah yang unik, sehingga penggunaan pengenalan wajah sebagai metode autentikasi biometrik menjadi sangat menarik (Kortli et al., 2020). Dalam konteks pengenalan wajah, terdapat serangkaian tahapan yang perlu dijalani oleh sistem agar dapat mengenali wajah individu dengan efektif. Manusia secara alamiah memiliki kemampuan untuk mengenali dan membedakan wajah-wajah yang berbeda, dan pengenalan wajah berupaya mereplikasi proses kognitif ini melalui teknologi. Pengenalan wajah memegang peranan penting dalam berbagai aspek kehidupan modern, termasuk keamanan, identifikasi, dan otentikasi (Guo & Zhang, 2019).

Proses umum dalam sistem pengenalan wajah terdiri dari tiga tahap, yaitu pendeteksian wajah, ekstraksi fitur, dan akhirnya, pengenalan wajah. Tahap pertama, pendeteksian wajah, bertujuan untuk menentukan keberadaan fitur wajah dalam sebuah gambar. Jika sebuah gambar ditemukan mengandung fitur wajah, langkah berikutnya adalah ekstraksi fitur. Pada tahap ini, ciri-ciri wajah seperti struktur, ukuran, dan bentuk individu diekstraksi dari gambar tersebut. Setelah tahap ekstraksi fitur selesai, langkah terakhir adalah pengenalan wajah. Pada tahap ini, sistem membandingkan ciri-ciri yang telah diekstraksi dengan data wajah yang telah disimpan sebelumnya, sehingga sistem dapat mengidentifikasi pemilik wajah berdasarkan ciri-ciri yang telah diekstraksi tersebut (Adjabi et al., 2020).

Menurut penelitian (Adjabi et al., 2020), pengenalan wajah dapat dibagi menjadi dua mode operasi yang berbeda, yaitu verifikasi wajah dan identifikasi wajah. Dalam mode operasi verifikasi wajah, sistem melakukan perbandingan antara wajah individu dengan wajah yang sudah ada dalam basis data wajah, dengan tujuan untuk memverifikasi apakah wajah individu tersebut sesuai dengan wajah yang telah terdaftar dalam basis data. Dengan kata lain, verifikasi wajah beroperasi dalam mode 1 lawan 1 untuk memastikan apakah wajah individu tersebut merupakan benar atau salah identitasnya, terhindari adanya banyak orang dengan identitas yang sama dalam basis data wajah.

Dalam konteks yang lebih spesifik, pengenalan wajah diterapkan untuk mengidentifikasi individu berdasarkan progresi usia. Pemahaman mengenai bagaimana wajah manusia berubah seiring bertambahnya usia memiliki implikasi penting dalam berbagai bidang, seperti keamanan, kesehatan, dan kebijakan sosial. Pengenalan wajah dengan mempertimbangkan progresi usia memungkinkan pemisahan dan klasifikasi wajah berdasarkan tahap-tahap perubahan yang terjadi pada struktur wajah, tekstur kulit, dan ekspresi wajah. Oleh karena itu, metode-metode pengenalan wajah yang mempertimbangkan progresi usia menjadi fokus utama untuk mengembangkan sistem yang akurat dan efektif dalam mengidentifikasi individu sepanjang rentang usia.


### **3.2 Progresi Usia pada Wajah**

Progresi usia pada wajah mencakup perubahan visual yang alami dan tak terhindarkan, seperti kerutan, perubahan warna kulit, dan kehilangan elastisitas (Baruni et al., 2021b). Setiap tahap penuaan membawa perubahan unik dalam fitur wajah, dan memahami progresi ini penting untuk membangun model pengenalan wajah yang efektif. Oleh karena itu, penelitian tentang pengenalan wajah dengan mempertimbangkan progresi usia menggabungkan pengetahuan tentang proses penuaan dengan teknologi pengolahan citra untuk mencapai tujuan identifikasi yang akurat. Dengan demikian, pengenalan wajah yang mempertimbangkan progresi usia memiliki implikasi yang luas dan relevan dalam pengembangan

sistem keamanan modern serta bidang-bidang lain yang memerlukan identifikasi individu yang andal (Parate et al., 2022).

### 3.3 Representasi Citra Digital

Citra dapat dicirikan sebagai suatu fungsi dua dimensi  $f(x, y)$ , di mana  $x$  dan  $y$  mewakili koordinat dalam bidang. Komponen amplitudo dari fungsi  $f$  pada tiap pasangan koordinat mencerminkan intensitas atau tingkat keabuan citra pada lokasi tersebut. Apabila  $x$ ,  $y$ , dan intensitas citra bersifat terbatas dan diskrit, maka citra tersebut dapat diklasifikasikan sebagai citra digital. Unit terkecil dalam citra digital, yang dikenal sebagai piksel atau elemen gambar, menjadi elemen dasar penyusun citra. Citra digital biasanya dibentuk dalam bentuk matriks dengan  $M$  baris dan  $N$  kolom. Umumnya, citra ini terdiri dari persegi panjang yang tersusun secara teratur, menjadikan jarak horizontal dan vertikal antara piksel konsisten di seluruh citra. Penyajian koordinat dalam bentuk matriks  $M \times N$  untuk citra digital biasanya diilustrasikan dalam Gambar 3.1 (Andono et al., 2017).




**Gambar 3. 1 Sistem Koordinat yang Dipergunakan untuk Mewakili Citra**

(Andono et al., 2017)

#### 3.3.1 Citra Warna

Citra berwarna, juga dikenal sebagai citra RGB, adalah tipe citra yang menggambarkan informasi warna dalam tiga komponen utama, yakni R (merah), G (hijau), dan B (biru). Setiap komponen warna menggunakan representasi 8 bit. Format file grafis menyimpan citra warna sebagai citra 24 bit, yang berasal dari


komponen merah, hijau, dan biru masing-masing 8 bit. Hal ini menyebabkan citra warna mempunyai 24 juta kemungkinan warna (Andono et al., 2017). Penyajian citra berwarna dapat dilihat dalam Gambar 3.2.



**Gambar 3. 2 Citra Warna dengan Komponen Warna R (Red), G (Green), dan B (Blue) (Andono et al., 2017)**

### 3.3.2 Citra *Grayscale*


Citra *grayscale* merupakan suatu kumpulan data matriks di mana nilai-nilainya mencerminkan tingkat intensitas setiap piksel, dengan rentang nilai berkisar antara 0 hingga 255. Untuk merepresentasikan setiap piksel, digunakan alokasi memori sebanyak 8 bit. Gambar 3.3 menggambarkan citra *grayscale* yang dilihat secara dekat, dengan menunjukkan beberapa nilai intensitas pikselnya. (Andono et al., 2017).



**Gambar 3. 3** Citra *Grayscale* dengan Nilai Pixel Antara 0 Sampai dengan 255 (Andono et al., 2017)

### 3.3.3 Citra Biner

Dalam citra biner, setiap piksel membutuhkan hanya 1 bit memori. Oleh karena itu, setiap piksel hanya memiliki 2 opsi nilai intensitas, yang adalah 1 atau 0. Gambar 3.4 mengilustrasikan citra biner yang diperiksa secara detail, menunjukkan sejumlah nilai intensitas piksel yang berbeda (Andono et al., 2017).



**Gambar 3. 4** Citra Biner dengan Nilai Pixel 0 atau 1 (Andono et al., 2017)

## 3.4 Pra-Pemrosesan

Pra-pemrosesan merupakan tahap krusial dalam pemrosesan data, khususnya citra digital, yang bertujuan untuk memastikan bahwa data tersebut dapat digunakan secara efektif dan sesuai untuk langkah-langkah berikutnya. Diperlukan tahap ini karena hasil citra digital yang diperoleh dari proses akuisisi seringkali terdampak oleh berbagai masalah, seperti *noise* atau kehadiran objek-

objek yang mengganggu. Beberapa masalah ini seringkali muncul akibat ketidakakuratan sensor yang digunakan dalam proses akuisisi citra. Selain untuk mengatasi masalah ini, pra-pemrosesan juga bertujuan untuk mengadaptasi citra digital agar sesuai dengan persyaratan dan kebutuhan ekstraksi fitur yang akan dilakukan (Andono et al., 2017).

Di bawah ini terdapat beberapa metode pra-pemrosesan yang digunakan untuk mencapai tujuan tersebut:

1. Melakukan Konversi ke *Grayscale*

Metode ini mengubah citra menjadi citra *grayscale* yang hanya memiliki satu saluran warna (*grayscale*), berbeda dengan tiga saluran warna (RGB). Proses ini dapat diterapkan untuk mengurangi tingkat kompleksitas data dan meningkatkan efisiensi dalam pemrosesan.

2. Menggunakan *Filter*

Teknik ini dimanfaatkan untuk mengurangi noise yang mungkin muncul dalam citra serta untuk mempertajam fitur-fitur penting. Beberapa jenis filter yang sering dipakai meliputi *median filter*, *gaussian filter*, dan *bilateral filter*.

3. Melakukan *Cropping*

Pendekatan ini berguna untuk memotong bagian citra yang tidak relevan atau menghilangkan elemen yang mengganggu dalam citra.

4. Menggunakan *Resizing*

Metode ini digunakan untuk merubah dimensi citra sesuai dengan ukuran yang diinginkan. Hal ini berguna untuk mengurangi kompleksitas data atau mempermudah proses pemrosesan citra.

### 3.5 Ekstraksi Fitur

Ekstraksi fitur adalah proses pengambilan dan representasi informasi penting atau ciri-ciri khusus dari suatu data mentah atau sumber data. Tujuannya adalah untuk mengurangi kompleksitas data, mengidentifikasi pola, dan mempertahankan informasi yang relevan untuk tugas analisis atau pengolahan selanjutnya. Dalam konteks pemrosesan gambar dan pengenalan pola, ekstraksi

fitur melibatkan identifikasi dan pemodelan ciri-ciri yang penting dalam gambar, seperti tepi, tekstur, warna, atau bentuk, yang dapat digunakan untuk mengklasifikasikan atau mengidentifikasi objek dalam gambar (Patel & Macwan, 2021).

### 3.5.1 Ekstraksi Fitur Tekstur

Ekstraksi fitur tekstur adalah proses mengidentifikasi dan mewakili ciri-ciri yang berkaitan dengan pola atau struktur tekstur dalam data gambar atau citra. Ini melibatkan analisis elemen-elemen seperti frekuensi, keteraturan, dan konsistensi tekstur pada gambar (Kumar H N et al., 2023). Hasil dari ekstraksi fitur tekstur dapat digunakan untuk berbagai tujuan dalam pengolahan gambar dan pengenalan pola, termasuk klasifikasi objek, segmentasi gambar, dan deteksi anomali dalam citra (Prakasa, 2021).

#### a. *Local Binary Pattern Histogram*

*Local Binary Pattern Histogram* (LBPH) adalah sebuah operator tekstur yang mengkonversi gambar dengan resolusi kecil menjadi sebuah *array* atau citra dengan label bilangan bulat (Najafi Khanbebin & Mehrdad, 2021). *Local Binary Pattern Histogram* (LBP) adalah metode ekstraksi fitur yang menggambarkan tekstur dengan membandingkan intensitas piksel pada suatu piksel dengan intensitas piksel tetangganya. LBPH menghasilkan pola biner yang merepresentasikan tekstur lokal pada citra. Proses analisis citra yang dilakukan oleh LBPH umumnya menghasilkan histogram. LBPH memiliki kemampuan untuk mengekstraksi informasi tekstur dalam citra dan menggabungkan seluruh fitur citra tersebut (Chater et al., 2023). Keunggulan LBPH meliputi kesederhanaan cara kerja, kinerja komputasi yang efisien, invarian terhadap perubahan skala intensitas, serta ketahanan terhadap variasi pencahayaan (Tang et al., 2020).

LBPH beroperasi pada blok citra berukuran 3x3 dengan jarak radius satu (Ojala et al., 2002). Cara kerjanya melibatkan perbandingan nilai kecerahan piksel tengah dengan 8 piksel tetangganya. Jika nilai kecerahan piksel tetangga lebih besar atau sama dengan nilai piksel tengah, maka piksel tetangga tersebut diubah menjadi 1.

Sebaliknya, jika nilai piksel tetangga lebih rendah dari nilai piksel tengah, maka piksel tetangga tersebut diatur sebagai 0. Selanjutnya, 8 nilai piksel tetangga ini diatur secara searah jarum jam untuk membentuk bilangan biner, yang kemudian diubah menjadi nilai desimal. Nilai desimal ini digunakan sebagai nilai baru untuk menggantikan piksel tengah dalam proses transformasi LBP.

$$S'g_p - g_c^* = \begin{cases} 1, & \text{if } g_p \geq g_c \\ 0, & \text{if } g_p < g_c \end{cases} \quad (3.1)$$

Pada persamaan 3.1, di mana piksel p termasuk dalam tetangga  $3 \times 3$  dengan tingkat abu-abu  $g_p$ ,  $p=0,1,\dots,7$ . Kode LBPH akhir dari piksel c dihitung dengan menjumlahkan nilai yang telah diambil ambang batasnya  $S'g_p - g_c^*$  diboboti oleh faktor binomial seperti yang dinyatakan sebagai  $2^k$ .

Piksel-piksel yang membentuk piksel p merupakan bagian dari tetangga berukuran  $3 \times 3$  yang memiliki nilai-nilai piksel sebagai berikut:  $g_p$ ,  $p=0,1,\dots,7$ . Dengan cara menambahkan nilai-nilai ambang batas yang sesuai,  $S'g_p - g_c^*$  yang diboboti dengan faktor binomial sebagaimana yang dijelaskan, maka kode LBP akhir dari piksel c dapat ditentukan. Sehingga diperoleh persamaan 3.2 sebagai berikut:

$$LBP = \sum_{k \neq 0} S'g_p - g_c^* 2^k \quad (3.2)$$

Diperoleh persamaan 3.3 dianggap sebagai  $M_\$$ .

$$M_\$ = LBP \quad (3.3)$$

Nilai-nilai biner yang dihasilkan oleh respons LBPH dalam situasi ini mengodekan hubungan timbal balik antara piksel inti dan piksel-piksel di sekitarnya. Dalam proses ekstraksi fitur LBPH untuk metode yang diusulkan, berbagai parameter seperti ukuran filter dan radius filter gambar diambil menjadi pertimbangan. Dalam metode yang diusulkan, ukuran filter adalah 8, dan radius filter adalah 1. Ini memengaruhi cara LBPH mengevaluasi dan mengkodekan piksel dalam hubungannya dengan tetangganya untuk tujuan pengenalan pola dalam gambar.

### b. *Histogram of Oriented Gradients (HOG)*

*Histogram of Oriented Gradients (HOG)* adalah suatu teknik ekstraksi fitur yang berguna untuk menggambarkan tekstur dalam citra. HOG memanfaatkan distribusi gradien orientasi piksel pada berbagai bagian citra untuk membentuk vektor fitur yang merepresentasikan tekstur suatu obyek.

Ekstraksi fitur tekstur menggunakan *Histogram of Oriented Gradients (HOG)* adalah sebuah metode untuk menganalisis tekstur dalam gambar atau citra dengan fokus pada distribusi orientasi gradien. Berikut adalah penjelasan langkah-langkah utama dalam ekstraksi fitur tekstur menggunakan HOG:

#### 1. Menghitung Gradien Gambar

Langkah pertama dalam metode HOG adalah menghitung gradien gambar. Gradien ini menunjukkan perubahan intensitas pada gambar, yang membantu dalam mendeteksi tepi dan tekstur. Gradien dihitung menggunakan operator diferensiasi seperti Sobel operator. Rumus untuk gradien dalam arah horizontal ( $G_x$ ) dan vertikal ( $G_y$ ) adalah:

$$G_x = \frac{*I}{*x} \text{ dan } G_y = \frac{*I}{*y} \quad (3.4)$$

Di mana  $I$  adalah intensitas piksel pada gambar.

#### 2. Menghitung Magnitudo dan Orientasi Gradien

Setelah gradien horizontal dan vertikal diperoleh, magnitudo ( $M$ ) dan orientasi ( $\theta$ ) dari gradien dapat dihitung dengan rumus berikut:

$$M = \sqrt{G_x^2 + G_y^2} \quad (3.5)$$

$$\theta = \arctan \frac{G_x}{G_y} \quad (3.6)$$

#### 3. Membagi Gambar menjadi Sel

Gambar kemudian dibagi menjadi sel-sel kecil (misalnya, 8x8 piksel). Untuk setiap sel, histogram orientasi gradien dibuat. Histogram ini menghitung jumlah kemunculan sudut orientasi gradien dalam sel tersebut.

#### 4. Normalisasi Blok

Untuk meningkatkan ketahanan terhadap perubahan pencahayaan dan kontras, sel-sel digabungkan menjadi blok yang lebih besar (misalnya, 2x2 sel). Histogram dari sel-sel dalam satu blok kemudian dinormalisasi. Normalisasi dapat dilakukan dengan beberapa metode, salah satunya adalah metode L2-norm:

$$v_{norm} = \frac{v}{\sqrt{\|v\|_2^2 + \epsilon^2}} \quad (3.7)$$

Di mana  $v$  adalah vektor fitur yang tidak dinormalisasi,  $\|v\|_2$  adalah norma L2 dari vektor tersebut, dan  $\epsilon$  adalah konstanta kecil untuk menghindari pembagian dengan nol.

#### 5. Membuat Vektor Fitur

Vektor fitur HOG dibentuk dengan menggabungkan semua histogram yang dinormalisasi dari setiap blok dalam gambar. Vektor fitur ini kemudian dapat digunakan dalam algoritma pembelajaran mesin untuk tugas-tugas pengenalan objek.

Hasil akhir dari ekstraksi fitur menggunakan HOG adalah vektor fitur yang menggambarkan pola tekstur dalam ROI, dengan berbagai orientasi gradien yang dihitung. Vektor fitur ini dapat digunakan untuk berbagai tugas dalam pengolahan gambar, seperti deteksi objek, pengenalan wajah, atau identifikasi tekstur (Vaidya et al., 2023).

### 3.5.2 Ekstraksi Fitur Geometri

Ekstraksi fitur geometri adalah proses mengidentifikasi dan mengekstraksi ciri-ciri yang berkaitan dengan geometri atau bentuk objek dalam data gambar atau citra. Ini mencakup aspek-aspek seperti ukuran, bentuk, orientasi, dan posisi objek dalam gambar. Dalam ekstraksi fitur geometri, ciri-ciri seperti panjang sisi, rasio aspek, lingkaran melingkar, atau pusat berat objek dapat dihitung. Hasil dari ekstraksi fitur geometri digunakan untuk tujuan pengenalan objek, segmentasi gambar, atau analisis bentuk (Vasanthi & Seetharaman, 2022).

Ekstraksi fitur geometri menggunakan *facial landmarks* dan *facial animation parameters* melibatkan penggunaan titik-titik khusus pada wajah (*facial landmarks*) sebagai dasar untuk mengambil ciri-ciri geometris dari wajah seseorang. Berikut ini merupakan proses ekstraksi fitur menggunakan *facial landmarks*:

### 1. Pendeteksian *Facial Landmarks*

Langkah awal dalam ekstraksi fitur geometri adalah mendeteksi dan mengidentifikasi *facial landmarks* pada wajah dalam gambar. Ini dapat dilakukan menggunakan algoritma khusus yang secara otomatis menentukan lokasi titik-titik penting seperti sudut mata, hidung, bibir dan lain-lain. Titik-titik ini disimpan sebagai koordinat  $(x, y)$  dalam gambar.

Persamaan rumus terkait dengan *facial landmarks* dan *Facial Animation Parameters* (FAP) digunakan dalam pengenalan wajah, berikut adalah penjelasan lebih rinci tentang rumus-rumus yang terlibat:

- Jarak Euclidean

Untuk menghitung jarak antara dua titik landmark adalah jarak Euclidean.

Jarak ini dapat dihitung menggunakan persamaan 3.8

$$\text{dist}(P_8, P_9) = \sqrt{(x_8 - x_9)^2 + (y_8 - y_9)^2} \quad (3.8)$$

Di mana  $P_8$  dan  $P_9$  adalah dua titik *landmark* dengan koordinat  $(x_8, y_8)$  dan  $(x_9, y_9)$  masing-masing.

### 2. Perhitungan Fitur Geometri

Setelah *facial landmarks* terdeteksi, dapat dihitung berbagai ciri geometris dengan menggunakan informasi ini. Sebagai contoh, dapat mengukur jarak antara dua *landmark* untuk mendapatkan panjang jari atau lebar wajah, juga dapat mengukur sudut antara dua garis yang didefinisikan oleh *landmark*, misalnya, sudut antara mata atau sudut mulut.

- Rasio Lebar dan Tinggi Wajah

Untuk menghitung rasio lebar terhadap tinggi wajah, menggunakan persamaan 3.9.

$$Ratio = \frac{dBst(P_{\$}, P_{1\&})}{dBst(P_{B}, P_{2C})} \quad (3.9)$$

Di mana:

$P_0$  dan  $P_{\$A}$  adalah titik *landmarks* pada sudut luar kiri dan kanan wajah.

$P_B$  adalah titik *landmarks* pada dagu.

$P_{2C}$  adalah titik *landmarks* pada jembatan hidung.

### 3. Analisis Geometri

Hasil dari perhitungan fitur geometri ini dapat digunakan untuk berbagai tujuan analisis. Misalnya, jika mengukur rasio aspek bibir terhadap lebar wajah, ini bisa digunakan untuk mengevaluasi proporsi bibir. Jika mengukur sudut antara mata, ini bisa digunakan untuk mengidentifikasi orientasi mata. Hasil analisis ini dapat memberikan wawasan tentang struktur dan geometri wajah seseorang.

Ekstraksi fitur geometri menggunakan *facial landmarks* sangat berguna dalam berbagai aplikasi seperti pengenalan wajah, identifikasi ekspresi wajah, dan penyesuaian wajah dalam teknologi hiburan seperti filter wajah dalam aplikasi media sosial. Hal ini memungkinkan sistem untuk menggambarkan ciri-ciri geometris wajah secara tepat dan mendetail (Vasanthi & Seetharaman, 2022).

### 3.6 *Support Vector Machine*

Klasifikasi multi-kelas menggunakan Support Vector Machine (SVM) adalah sebuah metode yang digunakan untuk mengklasifikasikan data ke dalam lebih dari dua kelas. Dalam konteks ini, SVM yang pada awalnya dikembangkan untuk klasifikasi dua kelas diperluas untuk menangani masalah multi-kelas.

Penting untuk dicatat bahwa SVM tidak hanya berfokus pada pemisahan data secara linear, melainkan juga memiliki kemampuan untuk mengubah data ke dalam bentuk yang nonlinear, sehingga data yang semula tidak dapat dipisahkan dengan garis lurus dapat dipecahkan. Ini menciptakan ruang di antara batas pemisahan dan titik data terdekat yang disebut “*vectors* pendukung.” *Vectors* pendukung ini adalah kunci untuk menentukan *hyperplane* pemisah.

Selain itu, SVM juga menggunakan teknik kernel, seperti kernel linear, kernel polinomial, kernel sigmoid, dan kernel radial bias (RBF), yang

memungkinkan SVM untuk mengadaptasi pemrosesan data sesuai dengan karakteristiknya. Ini membuat SVM sangat fleksibel dalam menangani berbagai jenis data dan permasalahan klasifikasi.

Konsep dasar SVM menunjukkan bagaimana SVM mencari *hyperplane* terbaik untuk memisahkan dua kelas data dengan lebar maksimum. Teknik ini telah menjadi salah satu alat yang populer dalam analisis data, pengenalan pola, dan klasifikasi dalam berbagai aplikasi.

$$0 \leq \alpha_i, i = 1, \dots, N \quad (3.10)$$

$$\sum_{i=1}^N \alpha_i y_i = 0 \quad (3.11)$$

Dimana  $i$  mewakili kasus pelatihan (*training*), yang masing-masing memiliki input  $x_i$  dan label kelas  $y_i \in \{-1, 1\}$ . Vektor bobot ( $w$ ) dan parameter bias ( $c$ ) untuk setiap hiperplane diberikan dalam persamaan berikut ini:

$$w \cdot x + c = 0 \quad (3.12)$$


$$f(x) = \text{sign}(w \cdot x + c) \quad (3.13)$$

$$f(x) = \text{sign} \left( \sum_{i=1}^N \alpha_i y_i k(x_i, x) + C \right) \quad (3.14)$$

$$0 \leq \alpha_i, i = 1, \dots, N \quad (3.15)$$

$$\sum_{i=1}^N \alpha_i y_i = 0 \quad (3.16)$$

*Support Vector Machine* (SVM) adalah algoritma pembelajaran mesin yang digunakan dalam konteks pengenalan pola dan klasifikasi. Dalam penelitian ini, SVM digunakan sebagai *classifier*, yaitu komponen yang bertanggung jawab untuk memutuskan identitas individu berdasarkan fitur-fitur yang telah diekstraksi. SVM bertugas untuk membuat keputusan apakah fitur-fitur yang diberikan sesuai dengan progresi usia seseorang atau bukan (Vaidya et al., 2023).



**Gambar 3. 5 Visualisasi Klasifikasi Multi-Kelas SVM**

Dalam Gambar 3.5 beberapa elemen penting dari klasifikasi multi-kelas SVM dijelaskan:

- **Simbol dan Representasi Kelas:** Kelas 1, 2, dan 3 diwakili oleh lingkaran, persegi panjang, dan segitiga masing-masing. Ini membantu dalam visualisasi bagaimana kelas-kelas yang berbeda dipisahkan dalam ruang fitur.
- **Garis Tebal:** Ini menunjukkan beberapa kemungkinan batas kelas yang dapat digunakan untuk memisahkan data dari berbagai kelas.
- **Garis Putus-putus:** Ini menunjukkan margin positif untuk kelas pertama. Margin adalah jarak antara data kelas tersebut dengan batas keputusan, yang SVM coba maksimalkan untuk meningkatkan generalisasi model.
- **Pelanggaran Margin Berpasangan:**  $\xi_{1,2}$  dan  $\xi_{1,3}$  untuk  $x_1$ , serta  $\xi_{2,2}$  dan  $\xi_{2,3}$  untuk  $x_2$  menggambarkan seberapa banyak contoh dari kelas pertama melanggar margin kelas-kelas lainnya. Pelanggaran margin ini adalah salah satu cara untuk mengukur seberapa baik SVM dalam memisahkan data dari berbagai kelas.

Pendekatan SVM multi-kelas bertujuan untuk menemukan hyperplane atau hyperplanes yang dapat memaksimalkan margin antara kelas-kelas yang berbeda, sehingga model dapat mengklasifikasikan data baru dengan akurasi tinggi.

### 3.7 Confusion Matrix

Confusion Matrix adalah suatu tampilan dalam bentuk matriks yang digunakan untuk mengevaluasi performa model pembelajaran. Tabel 3.1 menggambarkan representasi dari *confusion matrix*.

**Tabel 3. 1 Representasi Confusion Matrix**

		Kelas Predodokiksi	
		Positif	Negatif
Kelas Aktual	Positif	TP	FN
	Negatif	FP	TN

Berdasarkan Tabel 3.1, terdapat dua jenis kelas, yaitu kelas *actual* yang mewakili data asli, dan kelas prediksi yang mencerminkan hasil klasifikasi oleh model pembelajaran. *True Negative* (TN) adalah data yang benar-benar diklasifikasikan sebagai *actual*, *True Positive* (TP) adalah data yang benar-benar diklasifikasikan sebagai positif, *False Positive* (FP) adalah data yang keliru diklasifikasikan sebagai positif, dan *False Negative* (FN) adalah data yang keliru diklasifikasikan sebagai *actual*. Untuk mengukur performa sistem klasifikasi, kita memiliki sejumlah metrik penting, yaitu:

#### c. Akurasi (*Accuracy*)

Akurasi mengukur sejauh mana sistem mendekati nilai yang seharusnya diperoleh. Ini dapat dihitung dengan persamaan (3.17) berikut:

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \quad (3.17)$$

#### d. Presisi (*Precision*)

Presisi adalah perbandingan prediksi positif yang benar dengan total sampel positif yang digunakan, dan dapat dihitung dengan persamaan (3.18) berikut:

$$Precision = \frac{TP}{TP+FP} \times 100\% \quad (3.18)$$

#### e. Sensitivitas (*Recall*)

Sensitivitas mengukur probabilitas prediksi positif terhadap jumlah total kasus yang masuk ke dalam kelas tersebut, dan dapat dihitung dengan persamaan (3.19) seperti berikut ini:

$$Recall = \frac{TP}{TP+FN} \times 100\% \quad (3.19)$$

**f. Skor F1 (F1 Score)**

Skor F1 merupakan nilai gabungan yang mencakup nilai sensitivitas dan presisi secara harmonis, dihitung sebagai berikut:

$$F_1Score = 2 \cdot \frac{Presisi \cdot Sensitivitas}{Presisi + Sensitivitas} \times 100\% \quad (3.20)$$


## BAB IV

### METODOLOGI PENELITIAN

#### 4.1 Deskripsi Umum Penelitian

Penelitian ini bertujuan untuk mengembangkan sebuah model pengenalan wajah dengan progresi usia menggunakan pendekatan *hybrid* yang menggabungkan fitur tekstur (*Local Binary Pattern Histogram/ LBPH* dan *Histogram of Oriented Gradients/ HOG*) dengan fitur geometri wajah (*facial landmark* dan *facial animation parameters*). Model ini diharapkan mampu meningkatkan akurasi pengenalan pada wajah dengan mempertimbangkan informasi tekstur dan geometri wajah pada progresi usia.

Penelitian ini melibatkan serangkaian tahapan yang terstruktur untuk mencapai tujuan tersebut. Berikut adalah tahapan-tahapan yang dilakukan dalam penelitian ini, sebagaimana ditunjukkan pada Gambar 4.1.



**Gambar 4. 1 Tahapan Penelitian**

1. **Studi Literatur:** Dalam studi literatur mengenai pengenalan wajah dengan progresi usia menggunakan model *hybrid* pada fitur tekstur dan fitur geometri wajah, terdapat serangkaian penelitian yang relevan untuk dijadikan dasar bagi pendekatan yang diusulkan dalam penelitian ini.
2. **Akuisisi Data:** Mengumpulkan dataset wajah dengan label usia dari sumber-sumber seperti dataset FGNET. Data ini akan digunakan untuk melatih dan menguji model.
3. **Ekstraksi Fitur:** Fitur tekstur (LBPH dan HOG) akan diekstraksi dari gambar wajah untuk menggambarkan pola tekstur lokal dan distribusi gradien. Fitur geometri wajah (*facial landmark* dan *facial animation parameters*) akan diekstraksi untuk merepresentasikan bentuk wajah.

4. **Penggabungan Fitur:** Fitur-fitur yang diekstraksi akan digabungkan dalam model *hybrid feature*. Informasi dari fitur tekstur dan fitur geometri akan disatukan untuk meningkatkan kemampuan model dalam mengenali pola perubahan wajah seiring bertambahnya usia.
5. **Pemodelan:** Model akan melibatkan *Support Vector Machine (SVM) Classifier*. SVM akan digunakan untuk pengenalan wajah berdasarkan progresi usia berdasarkan fitur-fitur yang diekstraksi.
6. **Validasi dan Evaluasi:** Model akan diuji menggunakan matrik evaluasi seperti akurasi klasifikasi, dan metrik lain yang relevan. Pengujian akan dilakukan pada dataset FGNET untuk mengukur kinerja model dalam memprediksi wajah dengan progresi usia.
7. **Penulisan Laporan:** Peneliti menyusun laporan yang berisi hasil penelitian, analisis, dan kesimpulan yang dapat diambil dari penelitian yang telah dilakukan.

Melalui tahapan-tahapan ini, penelitian ini menghasilkan model pengenalan wajah yang mampu mengintegrasikan informasi fitur tekstur dan fitur geometri wajah untuk estimasi usia yang lebih akurat.

#### 4.2 Akuisisi Data

Proses akuisisi data pada dataset FG-Net melibatkan pengumpulan gambar-gambar wajah dengan fokus pada posisi frontal. Pengumpulan gambar ini dilakukan dengan memastikan bahwa wajah subjek berada dalam orientasi yang tepat dan menghadap kamera. Setelah pengumpulan data, selanjutnya dilakukan *filtering* data untuk menentukan data yang sesuai untuk digunakan atau tidak.

Dataset FG-NET (*Face and Gesture Recognition Research Network*) menyimpan 1002 gambar wajah dari 82 orang yang berbeda, diambil pada berbagai usia mulai dari bayi hingga usia 69 tahun, dan setiap orang memiliki sekitar 8 hingga 16 gambar. Gambar 4.2 menunjukkan contoh gambar dengan perbedaan usia dari basis data FG-NET. Untuk penelitian pengenalan wajah dengan progresi usia menggunakan metode *hybrid* pada fitur tekstur dan fitur geometri wajah,

dataset FG-Net perlu dibagi menjadi data training dan data testing dengan proporsi 80:20.



**Gambar 4. 2 Sampel Gambar Wajah dari Dataset FG-NET**

**Tabel 4. 1 Deskripsi Dataset**

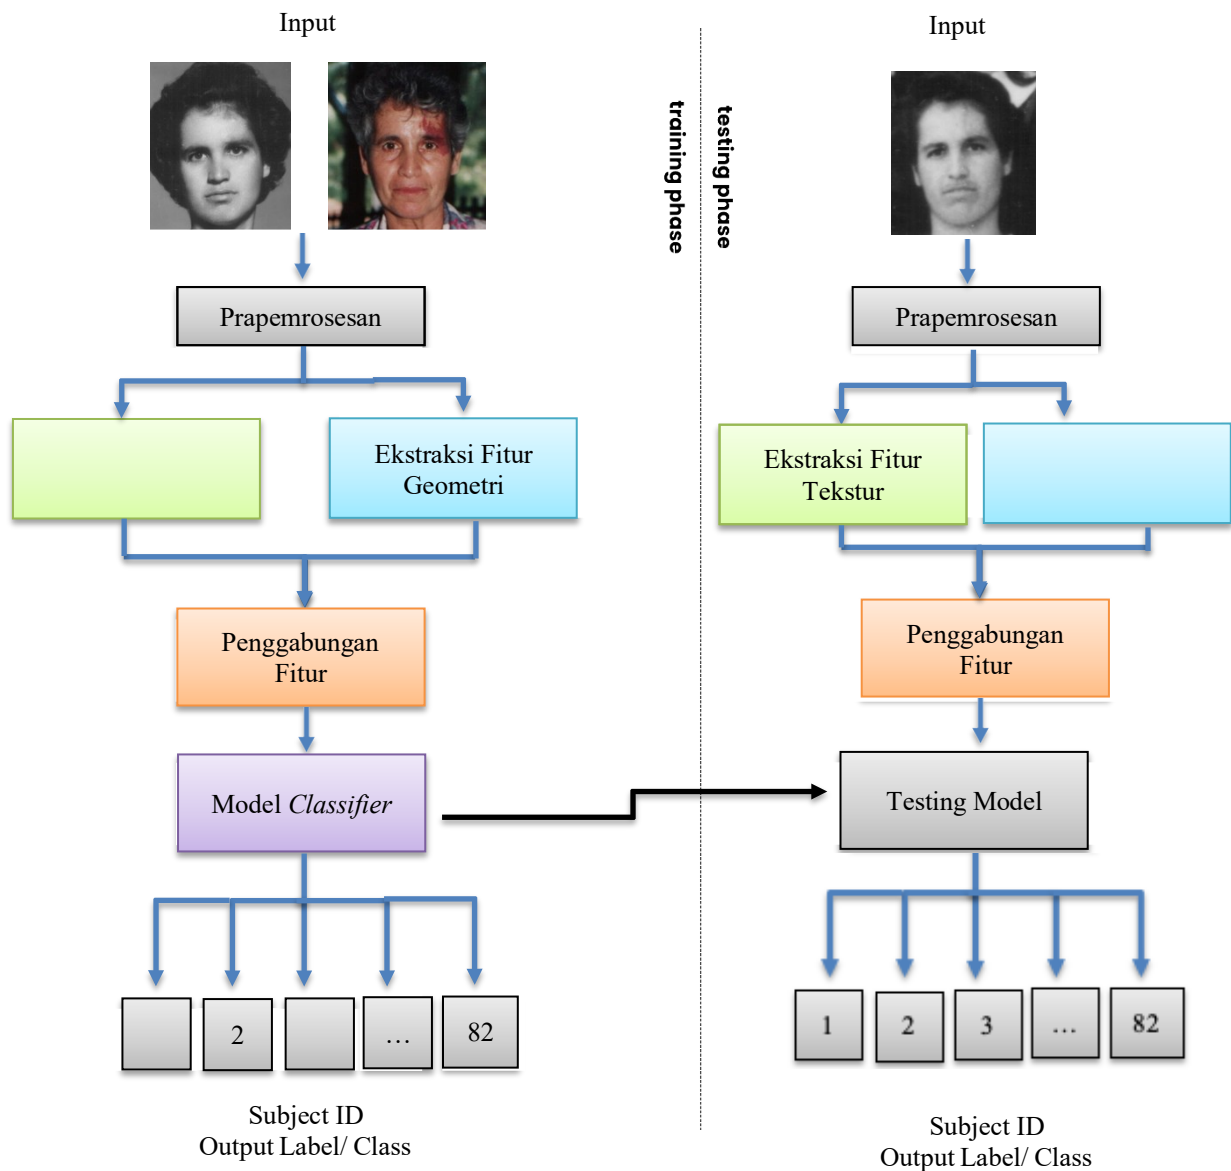
Subject_ID (Kelas)	001	002	003	004	005	006	007	008	009	010	011
Jumlah	15	16	12	12	11	12	9	15	13	12	14
Subject_ID (Kelas)	012	013	014	015	016	017	018	019	020	021	022
Jumlah	15	12	10	13	13	13	11	10	13	12	13
Subject_ID (Kelas)	023	024	025	026	027	028	029	030	031	032	033
Jumlah	12	11	12	11	11	11	13	11	13	12	11
Subject_ID (Kelas)	034	035	036	037	038	039	040	041	042	043	044
Jumlah	13	14	13	12	14	14	14	10	13	11	10
Subject_ID (Kelas)	045	046	047	048	049	050	051	052	053	054	055
Jumlah	13	13	14	16	10	8	11	11	13	13	8
Subject_ID (Kelas)	056	057	058	059	060	061	062	063	064	065	066
Jumlah	8	10	11	9	12	13	12	10	6	15	12
Subject_ID (Kelas)	067	068	069	070	071	072	073	074	075	076	077
Jumlah	10	10	11	11	13	14	16	16	10	18	16
Subject_ID (Kelas)	078	079	080	081	082	Total					
Jumlah	16	14	14	12	11	1002					

Dengan menggunakan dataset FG-Net pada Tabel 4.1 penelitian ini membangun model yang dapat mengenali wajah dengan progresi usia pada wajah secara akurat dalam posisi frontal, dengan memadukan fitur tekstur dan fitur geometri wajah.

### 4.3 Rancangan Model

#### 4.3.1 Algorithm Overview

Rancangan model ini melalui beberapa tahapan, yakni pra-pemrosesan, ekstraksi fitur tekstur dan fitur geometri, penggabungan fitur melalui model *hybrid feature*, serta penggunaan *Support Vector Machines* (SVM) untuk pengenalan wajah.



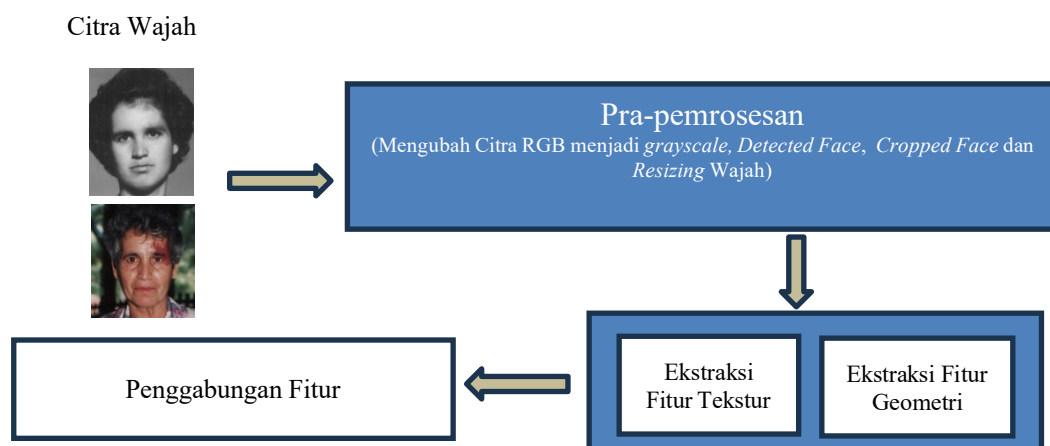
**Gambar 4. 3 Rancangan Model Penelitian**

Penelitian ini memanfaatkan data gambar sebagai input utama. Namun, sebelum data gambar tersebut dapat digunakan, kumpulan dataset gambar pertama-tama menjalani proses pra-pemrosesan untuk mengatur format gambar. Proses pra-pemrosesan ini melibatkan beberapa tahap, seperti mengubah citra dari RGB menjadi *grayscale*, menerapkan deteksi wajah, *cropping* wajah dan *resizing* wajah.

Langkah selanjutnya adalah ekstraksi fitur. Fitur-fitur dari gambar wajah diekstraksi menggunakan metode *Local Binary Pattern Histogram* (LBPH), ekstraksi fitur *Histogram of Oriented Gradients* (HOG), serta ekstraksi fitur geometri menggunakan landmark wajah. Ekstraksi fitur LBPH, ekstraksi fitur HOG, dan ekstraksi *landmark* wajah kemudian digabungkan menggunakan prosedur penggabungan fitur.

Klasifikasi menggunakan *Support Vector Machine* (SVM) digunakan untuk mengkategorikan gambar yang telah digabungkan fitur-fiturnya. SVM bekerja dengan menemukan *hyperplane* terbaik yang memisahkan data dari berbagai kelas. Dalam konteks ini, SVM digunakan untuk menghasilkan arsitektur model yang akan digunakan untuk mengkategorikan pengenalan wajah manusia dalam perubahan usia. Proses ini memastikan bahwa model yang dihasilkan mampu mengenali wajah dengan akurasi tinggi, bahkan dengan adanya variasi usia.

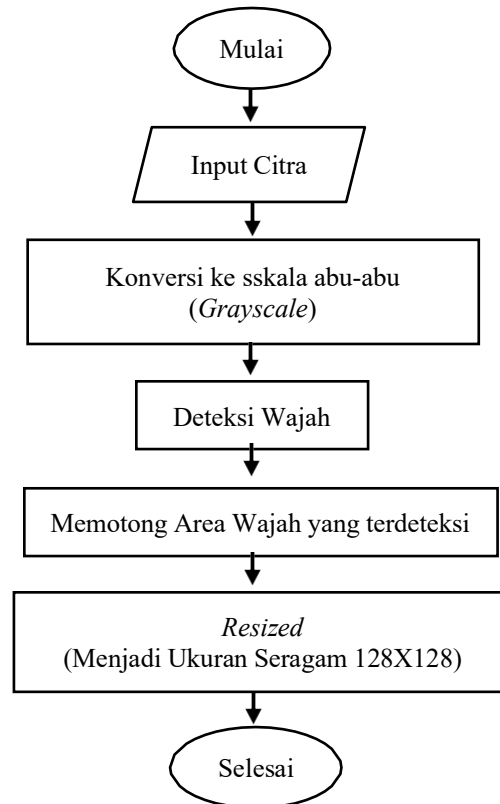
Dengan metode ini mampu pengenalan wajah yang lebih akurat dan andal ketika menghadapi perubahan usia. Arsitektur metode yang dirancang dalam penelitian ini dapat dilihat dalam Gambar 4.4.



**Gambar 4. 4 Arsitektur Pra-pemrosesan dan Ekstraksi Fitur**

### 4.3.2 Pra-Pemrosesan

Dalam tahap ini, dilakukan serangkaian langkah untuk meningkatkan kualitas dan kontras gambar wajah dengan mengurangi *noise*.



**Gambar 4.5 Tahapan Prapemrosesan**

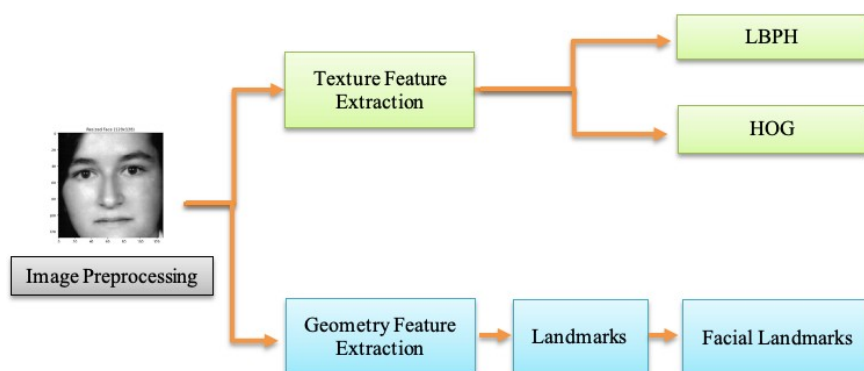
Pada Gambar 4.5 Tahapan prapemrosesan untuk pengenalan wajah dengan progresi usia dimulai dengan input citra FGNET di mana gambar wajah yang akan diproses dimasukkan ke dalam sistem. Langkah berikutnya adalah *resize* citra di mana gambar diubah ukurannya menjadi seragam untuk memastikan konsistensi dalam pemrosesan selanjutnya. Setelah itu, gambar diubah menjadi skala abu-abu pada tahap *grayscale* untuk mengurangi kompleksitas data dan fokus pada informasi tekstur.

Pada tahap *detected face*, wajah pada gambar dideteksi dan dipisahkan dari latar belakang serta elemen lainnya yang tidak relevan. Setelah wajah terdeteksi, area yang sesuai dipotong untuk mengisolasi wajah dari bagian lain gambar.

Terakhir, wajah yang dipotong diubah ukurannya menjadi dimensi standar 128x128 piksel, memastikan keseragaman di seluruh dataset dan memungkinkan ekstraksi fitur dan analisis yang konsisten. Rangkaian langkah ini memastikan bahwa gambar diproses dengan tepat dan siap untuk metode ekstraksi fitur seperti LBPH, HOG, dan *facial landmarks*.

### 4.3.3 Ekstraksi Fitur

Ekstraksi fitur dalam pengenalan wajah dengan progresi usia adalah tahap yang sangat penting. Tujuannya adalah untuk menggambarkan dan mengekstrak informasi yang relevan dari gambar wajah sehingga dapat membantu mengenali individu seiring perubahan usia. Proses ekstraksi fitur dalam pengenalan wajah dengan progresi usia memainkan peran krusial dalam pemahaman dan pemodelan perubahan usia dalam gambar wajah. Fitur-fitur yang diperoleh harus mampu mengidentifikasi perubahan dalam tekstur dan geometri, yang terkait dengan progresi usia, sehingga pengenalan yang akurat dapat dihasilkan. Rancangan ekstraksi fitur yang digunakan pada penelitian ini ditunjukkan pada Gambar 4.6.



**Gambar 4. 6 Ekstraksi Fitur**

#### 4.3.4.1 Ekstraksi Fitur Tekstur

Ekstraksi fitur tekstur dalam pengenalan wajah (*face recognition*) adalah proses untuk menggambarkan pola tekstur yang terdapat pada wajah manusia. Ini adalah langkah penting dalam mempersiapkan gambar wajah untuk analisis lebih lanjut dan pengenalan individu. Tujuan utama dari ekstraksi fitur tekstur dalam *face*

*recognition* adalah untuk menggambarkan pola tekstur unik yang ada pada wajah individu. Pola tekstur ini mencakup fitur-fitur seperti garis-garis, titik-titik, bayangan, dan detail-detail halus yang ada pada wajah. Ada berbagai metode ekstraksi fitur tekstur yang dapat digunakan dalam *face recognition*. Dua metode yang digunakan pada penelitian ini adalah *Local Binary Pattern Histogram* (LBPH) dan *Histogram of Oriented Gradients* (HOG).

#### **a. Ekstraksi Fitur Tekstur *Local Binary Pattern Histogram* (LBPH)**

Metode *Local Binary Pattern Histogram* (LBPH) adalah algoritma yang digunakan untuk klasifikasi tekstur, analisis wajah, analisis gerakan, deskripsi wajah, serta identifikasi kelompok usia. Pada kulit yang mengalami penuaan, terdapat banyak detail yang dapat diekstraksi menggunakan metode LBPH. Metode LBPH dapat mendeteksi pola mikrostruktur seperti bintik-bintik, garis-garis, tepi, dan area datar pada kulit (A. S. Al-Shannaq, 2019).

LBPH merupakan metode ekstraksi fitur yang mengambil fokus pada pola tekstur dalam gambar. Proses ekstraksi fitur LBPH melibatkan langkah-langkah berikut:

##### **1. Pembagian Gambar**

Gambar wajah dibagi menjadi sel-sel kecil atau blok piksel, yang biasanya berukuran beberapa piksel.

##### **2. Perhitungan LBP**

Untuk setiap sel atau blok, LBP mengambil titik acuan (piksel tengah) dan membandingkannya dengan intensitas piksel tetangganya. Jika intensitas piksel tetangga lebih besar atau sama dengan intensitas piksel tengah, hasilnya adalah 1; jika kurang, hasilnya adalah 0. Hasil perbandingan ini diubah menjadi bilangan biner.

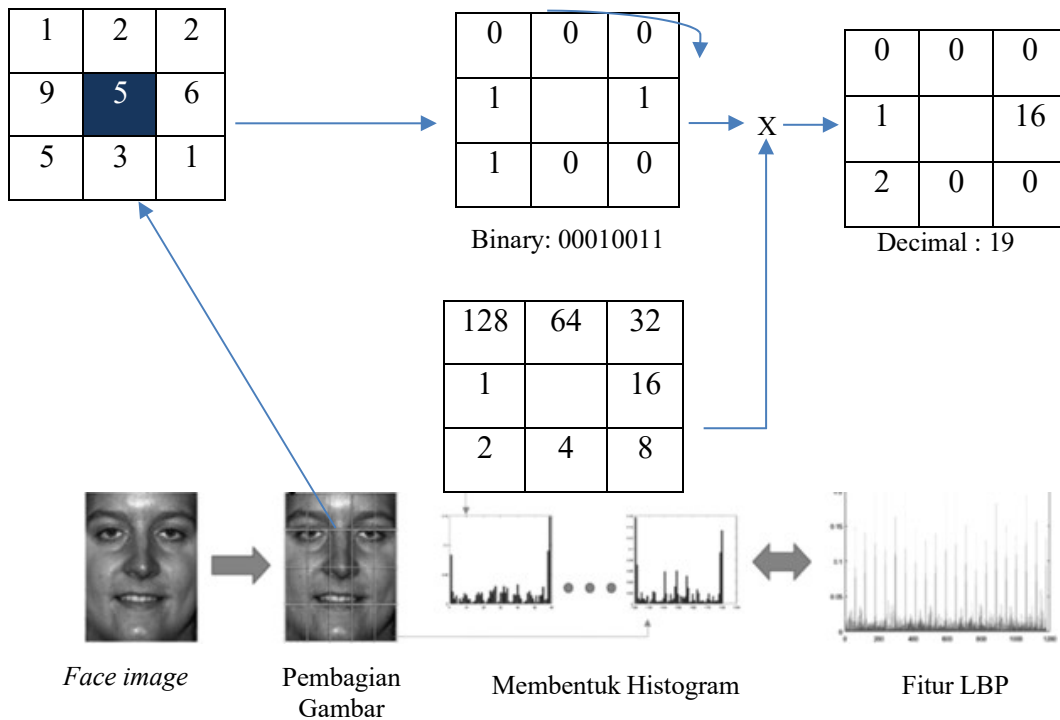
##### **3. Membentuk Histogram**

Untuk setiap sel atau blok, sejumlah besar bilangan biner LBP yang dihasilkan digunakan untuk membentuk histogram. Histogram ini mencerminkan sebaran pola tekstur dalam sel atau blok tersebut.

##### **4. Penggabungan Histogram**

Histogram dari semua sel atau blok digabungkan untuk membentuk vektor fitur LBP yang mencerminkan seluruh gambar wajah.

Hasil akhir ekstraksi fitur LBPH adalah vektor fitur yang menggambarkan pola tekstur dalam gambar wajah, dengan setiap nilai dalam vektor mencerminkan sebaran pola tekstur khusus dalam gambar.



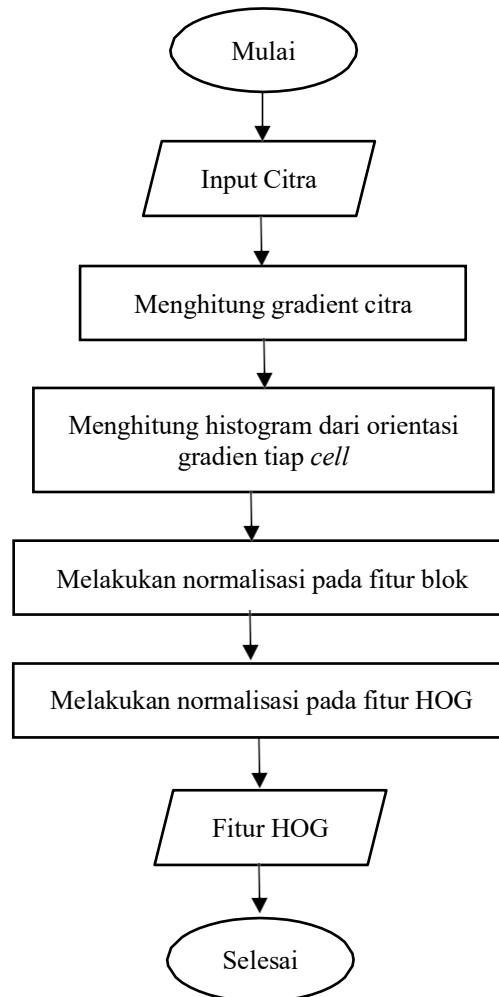
**Gambar 4. 7 Alur Ekstraksi Fitur LBPH**

#### b. Ekstraksi Fitur dengan *Histogram of Oriented Gradients* (HOG)

*Histogram of Oriented Gradients* (HOG) adalah metode ekstraksi fitur yang mengukur distribusi gradien intensitas piksel dalam gambar untuk menggambarkan tekstur. Berikut adalah langkah-langkah ekstraksi fitur menggunakan HOG:

1. **Pembagian Gambar:** Gambar wajah dibagi menjadi sel-sel kecil atau blok piksel, serupa dengan LBP.
2. **Perhitungan Gradien:** Untuk setiap piksel dalam setiap sel atau blok, HOG menghitung gradien intensitas, yaitu perubahan intensitas piksel dalam berbagai arah (orientasi).

3. Mengukur Orientasi: HOG mengukur orientasi gradien untuk setiap piksel dan memasukkannya ke dalam histogram orientasi gradien yang sesuai.
4. Penggabungan Histogram: Histogram orientasi gradien dari semua sel atau blok digabungkan untuk membentuk vektor fitur HOG yang mencerminkan tekstur dalam gambar wajah.



**Gambar 4. 8 Alur Ekstraksi Fitur HOG**


Hasil akhir ekstraksi fitur HOG adalah vektor fitur yang menggambarkan distribusi gradien intensitas dan orientasi dalam gambar, menciptakan deskripsi tekstur yang kuat.

#### 4.3.4.2 Ekstraksi Fitur Geometri

##### Ekstraksi Fitur Geometri *Facial Landmarks* dan *Facial Animation Parameter* (FAP)

Ekstraksi fitur geometri menggunakan *landmarks* dilakukan dengan mengambil posisi dan bentuk dari *landmark* wajah yang terdeteksi. *Landmark* ini mencakup titik-titik yang terletak pada mata, alis, hidung, mulut, dan garis rahang. Setelah *landmark* wajah terdeteksi, posisi dan bentuk dari setiap *landmark* akan diekstraksi. Posisi *landmark* dapat diwakili oleh koordinat x dan y pada citra wajah, sedangkan bentuk *landmark* dapat diwakili oleh jarak relatif antara *landmark* yang satu dengan yang lain. Matriks deskriptor geometri wajah dengan dimensi  $\text{len}(L) \times D_{\text{Geo}}$  diperoleh sebagai hasil ekstraksi fitur geometri. Matriks ini akan digunakan sebagai fitur untuk pelatihan model pengenalan wajah.

Fungsi `extract_facial_landmarks` dirancang untuk mengekstraksi titik-titik penting wajah (*facial landmarks*) dan parameter animasi wajah (*Facial Animation Parameters*, FAP) dari gambar. Setelah wajah terdeteksi, prediktor bentuk digunakan untuk mengekstraksi titik-titik penting pada wajah, yang kemudian digunakan untuk menghitung berbagai FAP. FAP ini mengukur jarak antara berbagai titik penting pada wajah, seperti mata, hidung, dan mulut, yang dirancang untuk menangkap informasi penting tentang struktur wajah dan perubahan yang terjadi seiring bertambahnya usia. Langkah terakhir adalah normalisasi FAP untuk memastikan distribusi data yang seragam, yang membantu meningkatkan kinerja model pembelajaran mesin yang digunakan.



Gambar 4. 9 Representasi Skema *Facial Landmarks*

Persamaan rumus terkait dengan *facial landmarks* dan *Facial Animation Parameters* (FAP) digunakan dalam pengenalan wajah, berikut adalah penjelasan lebih rinci tentang rumus-rumus yang terlibat:

- Jarak *Euclidean*

Untuk menghitung jarak antara dua titik *landmark* adalah jarak *Euclidean*.

Jarak ini dapat dihitung menggunakan persamaan 4.1

$$\text{dist}(P_8, P_9) = \sqrt{(x_8 - x_9)^2 + (y_8 - y_9)^2} \quad (4.1)$$

Di mana  $P_8$  dan  $P_9$  adalah dua titik *landmark* dengan koordinat  $(x_8, y_8)$  dan  $(x_9, y_9)$  masing-masing.

- Rasio Lebar dan Tinggi Wajah

Untuk menghitung rasio lebar terhadap tinggi wajah, menggunakan persamaan 4.2.


$$\text{Ratio} = \frac{\text{dist}(P_0, P_{1\&})}{\text{dist}(P_8, P_{2c})} \quad (4.2)$$

Di mana:


$P_0$  dan  $P_{1\&}$  adalah titik *landmarks* pada sudut luar kiri dan kanan wajah.

$P_B$  adalah titik *landmarks* pada dagu.

$P_{2c}$  adalah titik *landmarks* pada jembatan hidung.



**Gambar 4. 10 Contoh Deteksi Wajah dan Landmark Wajah: (a) Input Gambar (*frontal face*), (b) Wajah dan Landmark Wajah yang Terdeteksi**



**Gambar 4. 11 Facial Animation Parameter Units (Pard & Bonafonte, 2002)**

Berikut adalah tabel yang menunjukkan berbagai FAP yang dihitung dalam fungsi ini, beserta deskripsi dan nilai yang digunakan untuk setiap FAP:

FAP1 (Jarak antara mata kiri dan kanan):

$$FAP1 = dist (P_{JA}, P_{KL})$$

FAP2 (Jarak antara ujung hidung dan pusat bibir atas):

$$FAP2 = dist (P_{JJ}, P_{A2})$$

FAP3 (Jarak antara ujung hidung dan titik antara alis kiri)

$$FAP3 = dist (P_{JJ}, P_{SM})$$

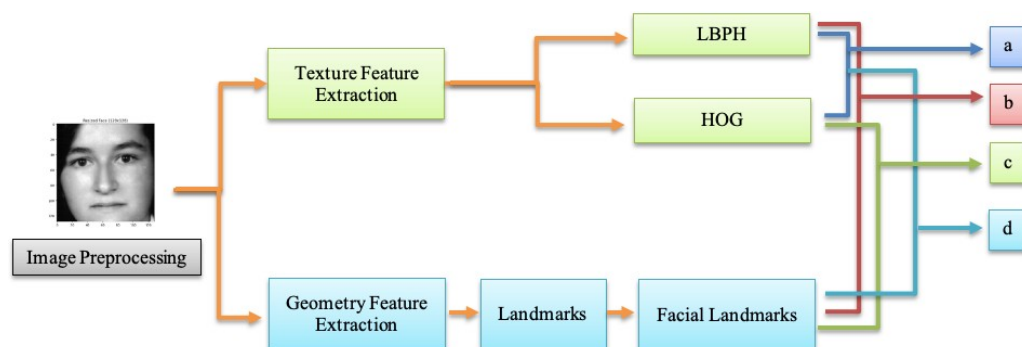
**Tabel 4. 2 Facial Animation Parameter (FAP)**

FAP	Deskripsi	Nilai FAP
FAP1	Jarak antara mata kiri dan kanan	36-45
FAP2	Jarak antara ujung hidung dan pusat bibir atas	33-62
FAP3	Jarak antara ujung hidung dan titik antara alis kiri	33-19
FAP4	Jarak antara sudut mulut	48-54
FAP5	Jarak antara mata kiri dan ujung hidung	36-33
FAP6	Jarak antara mata kanan dan ujung hidung	45-33
FAP7	Jarak antara titik antara alis kiri dan pusat bibir atas	19-62
FAP8	Jarak antara titik dagu dan pusat bibir atas	8-62
FAP9	Jarak antara titik antara alis kanan dan ujung hidung	24-33
FAP10	Jarak antara ujung hidung dan titik terendah pada bibir bawah	33-57
FAP11	Jarak antara ujung hidung dan titik antara kedua alis	33-27
FAP12	Rasio lebar wajah terhadap tinggi wajah	0-16/8-27
FAP13	Jarak antara ujung hidung dan dagu	33-8
FAP14	Jarak antara jembatan hidung dan dagu	0-8
FAP15	Jarak antara sudut dalam mata dan sudut mulut	4-48
FAP16	Jarak antara sudut luar mata dan alis	2-14

Tabel 4.2 menyajikan deskripsi FAP dan nilai titik koordinat yang digunakan untuk menghitung setiap FAP, yang membantu dalam menangkap informasi penting tentang struktur wajah dan perubahan yang terjadi seiring bertambahnya usia.

#### 4.3.4 Penggabungan Fitur

Penggabungan fitur akan menggabungkan informasi dari fitur tekstur (LBPH dan HOG) dan fitur geometri (*facial landmark*), seperti yang ditunjukkan pada Gambar 4.11. Konsep penggabungan fitur LBPH dan *facial landmark* adalah dengan menggabungkan informasi dari kedua fitur tersebut untuk meningkatkan kinerja sistem pengenalan wajah berdasarkan progresi usia. LBPH (*Local Binary Pattern*) digunakan untuk mendeteksi pola mikrostruktur pada kulit yang mengalami penuaan. Sedangkan *Facial Landmark* adalah titik-titik khusus pada wajah manusia yang digunakan untuk menggambarkan struktur wajah, seperti posisi mata, hidung, mulut, dan dagu.



**Gambar 4. 12 (a.) Hybrid Feature LBPH dan HOG (b) LBPH dan Facial Landmarks, (c.) HOG dan Facial Landmarks, (d.) LBPH, HOG dan Facial Landmarks**

Dalam penggabungan fitur LBPH dan *facial landmark*, informasi tentang pola mikrostruktur kulit yang dihasilkan dari LBPH dapat digabungkan dengan informasi tentang struktur wajah yang dihasilkan dari *facial landmark*. Hal ini dapat memberikan informasi yang lebih lengkap dan komprehensif tentang kondisi kulit dan struktur wajah seseorang, yang dapat digunakan untuk pengenalan wajah.

HOG (*Histogram of Oriented Gradients*) juga dapat digabungkan dengan *Facial Landmark* untuk meningkatkan kinerja sistem pengenalan wajah atau estimasi usia. HOG digunakan untuk menghitung magnitudo dan orientasi tepi pada gambar, sementara *Facial Landmark* digunakan untuk menggambarkan struktur wajah.

Dalam penggabungan fitur (LBPH, HOG) dan *Facial Landmark*, informasi tentang pola mikrostruktur kulit dari LBP, informasi tentang orientasi tepi dari HOG, dan informasi tentang struktur wajah dari *Facial Landmark* dapat digabungkan untuk memberikan informasi yang lebih lengkap dan komprehensif tentang kondisi kulit, orientasi tepi, dan struktur wajah seseorang. Hal ini dapat digunakan untuk pengenalan wajah dengan tingkat akurasi yang lebih tinggi.

Adapun langkah implementasi penggabungan fitur sebagai berikut:

***Flattening Data:***

- **Landmarks and FAP** : Data landmark wajah dan FAP (*Facial Animation Parameters*) berupa (jumlah sampel, 1, jumlah fitur). Data ini di-*flatten* menggunakan *np.vstack* dan *reshape*, untuk facial landmarks menghasilkan vektor berdimensi 136 dan vektor berdimensi 16 untuk FAP.
- **HOG (*Histogram of Oriented Gradients*)** : Data HOG sudah dalam bentuk (jumlah sampel, jumlah fitur) sehingga hanya perlu digabungkan menggunakan *np.vstack*. HOG menghasilkan vektor berdimensi 15.876.
- **LBPH (*Local Binary Pattern Histogram*)** : Data LBPH sudah dalam bentuk (jumlah sampel, jumlah fitur) sehingga hanya perlu digabungkan menggunakan *np.vstack*. LBP menghasilkan vektor berdimensi 90.

Semua fitur yang diekstraksi (LBPH, HOG, *facial landmarks*, FAP) di-*flatten* untuk membentuk vektor fitur yang panjang. Sehingga pada penelitian ini, LBPH menghasilkan vektor berdimensi 90, HOG 15.876, *facial landmarks* 136, dan FAP 16, maka vektor fitur gabungan ( $90 + 15.876 + 136 + 16$ ) akan memiliki dimensi 16.118 untuk *hybrid feature* secara keseluruhan. Tabel 4.3 merupakan tabel penggabungan fitur untuk setiap model yang digunakan pada penelitian ini:

**Tabel 4. 3 Penggabungan Fitur**

Gabungan Fitur	Ekstraksi Fitur Tekstur		Ekstraksi Fitur Geometri		Hasil
	LBPH	HOG	<i>Facial Landmarks</i>	FAP	
LBPH + HOG	90	15.876			15.966
LBP + <i>Facial Landmarks</i> , FAP	90		136	16	242
HOG + <i>Facial Landmarks</i> , FAP		15.876	136	16	16.028
LBP + HOG + <i>Facial Landmarks</i> , FAP	90	15.876	136	16	16.118

**Normalisasi:**


*StandardScaler* agar memiliki distribusi dengan rata-rata nol dan standar deviasi satu. Normalisasi ini dilakukan untuk meningkatkan kinerja PCA dan SVM

**PCA (*Principal Component Analysis*):**

- *Principal Component Analysis* (PCA) dapat digunakan untuk mereduksi dimensi dari vektor fitur gabungan.
- PCA membantu menghilangkan fitur yang kurang informatif dan mempertahankan fitur yang paling bervariasi, sehingga mengurangi dimensi tanpa kehilangan informasi penting.

**4.3.5 Pemodelan (Pengenalan Wajah)**

Dalam penelitian ini, SVM digunakan sebagai model untuk mengenali wajah berdasarkan fitur-fitur yang diekstraksi, yaitu LBPH, HOG, dan *Facial Landmark*. SVM akan dilatih menggunakan data latih yang terdiri dari fitur-fitur dan label-label yang sesuai dengan identitas wajah. Setelah dilatih, SVM dapat digunakan untuk pengenalan wajah berdasarkan progresi usia berdasarkan fitur-fiturnya.



**Gambar 4. 13 Dataset yang Digunakan Selama Proses Pelatihan dan Pengujian**

Dalam desain model *classifier* untuk penelitian ini, menggunakan metode *Support Vector Machine* (SVM) untuk mengevaluasi akurasi pengenalan wajah berdasarkan interval perbedaan usia. Sebagaimana dijelaskan dalam referensi (Boussaad & Boucetta, 2021), mengadopsi skema yang telah terbukti efektif sebelumnya. Database yang digunakan dalam penelitian ini terdiri dari 82 kelas, di mana setiap kelas diwakili oleh satu gambar dengan usia sekitar 18 tahun yang dipilih sebagai representasi database. Sementara itu, 920 gambar wajah lainnya dari kelas-kelas tersebut akan digunakan sebagai set pengujian.

SVM akan diimplementasikan sebagai model *classifier* untuk menjalankan pengujian dan evaluasi akurasi pengenalan wajah dalam kerangka perbedaan usia. Dengan pendekatan ini, diharapkan mendapatkan wawasan mendalam mengenai kinerja SVM dalam konteks perbedaan usia, yang dapat memberikan kontribusi signifikan pada pemahaman praktis dan pengembangan sistem pengenalan wajah yang lebih baik.

## 4.4 Rancangan Pengujian

### 4.4.1 Strategi Validasi

Strategi validasi yang diterapkan dalam penelitian ini bertujuan untuk menguji kehandalan dan kinerja sistem pengenalan wajah dengan progresi usia menggunakan metode *hybrid feature*. Metode ini mencakup kombinasi fitur LBP (*Local Binary Pattern*), HOG (*Histogram of Oriented Gradients*), dan fitur geometri berdasarkan *landmark* wajah, yang kemudian diklasifikasikan menggunakan *classifier* SVM.

Berikut adalah rancangan strategi validasi yang digunakan:

#### 1. Pembagian Data (*Train-Test Split*)

Data dibagi secara acak dengan komposisi 80:20 untuk *training* dan *testing*.

*Training Set* (80%) : digunakan untuk melatih model pada kombinasi fitur yang telah diekstraksi.

*Testing Set* (20%) : digunakan untuk menguji kinerja model yang telah dilatih pada data yang belum pernah dilihat sebelumnya.

#### Evaluasi Kinerja

Kinerja sistem dievaluasi berdasarkan metrik yang relevan seperti akurasi, presisi, *recall*, dan *F1-score*.

Akurasi : Persentase jumlah data yang terklasifikasi dengan benar terhadap total data uji.

Presisi : Persentase data yang benar terklasifikasi positif dari semua data yang diklasifikasikan positif.

*Recall* : Persentase data yang benar terklasifikasi positif dari semua data yang sebenarnya positif.

*F1-score* : Ukuran rata-rata harmonis presisi dan *recall*.

Dengan menerapkan strategi ini, memberikan evaluasi yang komprehensif terhadap sistem pengenalan wajah dengan progresi usia menggunakan metode *hybrid feature* pada fitur tekstur dan fitur geometri wajah.

#### 4.4.2 Tahap Pengujian dan Evaluasi

Tahapan pengujian dan evaluasi dalam penelitian tesis pengenalan wajah dengan progresi usia menggunakan fitur hybrid (LBPH, HOG, dan facial landmarks) dengan penggunaan *classifier* SVM menggabungkan serangkaian langkah metodologis yang komprehensif. Dataset gambar wajah yang mencakup perubahan usia akan dikumpulkan. Setelah itu, fitur-fitur tekstur LBPH (*Local Binary Pattern*) dan HOG (*Histogram of Oriented Gradients*), serta fitur geometri berdasarkan *facial landmarks* akan diekstraksi dari gambar wajah. Proses pemilihan fitur akan memastikan bahwa hanya fitur yang paling informatif digunakan dalam analisis selanjutnya.

Dataset akan dibagi menjadi *training set* dan *testing set*. Dalam fase pelatihan, model SVM dilatih menggunakan *training set*, sementara parameter SVM dioptimalkan. Pengujian model akan dilakukan menggunakan *testing set*, di mana metrik evaluasi seperti akurasi, presisi, *recall*, dan *F1-score* dihitung untuk mengukur kinerja model

Selanjutnya, evaluasi fitur *hybrid* (LBPH, HOG, *facial landmarks*) membantu mengidentifikasi kontribusi relatif dari setiap fitur terhadap kemampuan pengenalan wajah dengan progresi usia. Hasil eksperimen dianalisis secara cermat, dan temuan serta kesimpulan dirangkum dalam laporan penelitian, memberikan wawasan yang berharga tentang penggunaan teknik pengenalan wajah dengan progresi usia dengan fitur *hybrid*.

**Tabel 4. 4 Rencana Pengujian Sistem**

Model	Rencana Pengujian Sistem
Model 1	Ekstraksi fitur menggunakan LBPH
Model 2	Ekstraksi fitur menggunakan HOG
Model 3	Ekstraksi fitur menggunakan <i>Facial Landmarks</i> , FAP
Model 4	Ekstraksi fitur menggunakan LBPH dan HOG
Model 5	Ekstraksi fitur menggunakan LBPH dan <i>Facial Landmarks</i> , FAP
Model 6	Ekstraksi fitur menggunakan HOG dan <i>Facial Landmarks</i> , FAP
Model 7	Ekstraksi fitur menggunakan LBP, HOG dan <i>Facial Landmarks</i> , FAP

## BAB V

### IMPLEMENTASI

#### 5.1 Deskripsi Implementasi

Implementasi dari sistem ini dilakukan dengan menggunakan *Python 3.9* sebagai bahasa pemrograman utama. Dalam proses implementasi ini, perangkat keras yang terlibat melibatkan processor berkecepatan 1,8 GHz Dual-Core Intel Core i5 dan RAM sebesar 8 GB.

Adapun spesifikasi perangkat lunak yang digunakan dalam proses implementasi Pengenalan Wajah dengan Progresi Usia Menggunakan *Hybrid Feature* pada Fitur Tekstur dan Fitur Geometri Wajah mencakup beberapa komponen, antara lain:

2. Sistem Operasi (OS) : macOS Big Sur, versi 11.6.8 (20G730)
3. Perangkat Lunak Utama : Kaggle
4. *Library* yang terlibat, seperti cv2, numpy, os, sklearn, joblib, skimage, scipy.io, math, dan glob.

Semua komponen tersebut berperan penting dalam menyelenggarakan proses pengenalan wajah dengan menggunakan pendekatan progresi usia, dengan fokus pada pemanfaatan fitur tekstur dan fitur geometri wajah secara hibrid.

##### 5.1.1 Citra Masukan

Sebelum melangkah ke tahap-tahap *preprocessing* yang diperlukan untuk memproses gambar, langkah awal yang esensial dilakukan adalah melakukan pembacaan terhadap dataset citra yang akan menjadi fokus dalam seluruh proses ini.

Gambar 5.1 merupakan potongan kode yang dirancang untuk mengakses dan mengumpulkan informasi dari file citra data yang telah disediakan. Langkah ini menjadi fundamental karena memastikan ketersediaan data yang diperlukan untuk diolah dalam tahap selanjutnya, di mana proses *preprocessing* gambar akan dilakukan dengan memanfaatkan dataset yang telah berhasil dibaca sebelumnya.

```

import os
import numpy as np
import cv2
import dlib
from skimage import io, transform, feature
from skimage.feature import local_binary_pattern
from sklearn.model_selection import train_test_split
from tqdm import tqdm

# Path to your image directory
image_dir = "/kaggle/input/fgnet/FGNET/images"

```

**Gambar 5. 1 Potongan Kode Mengakses dan Membaca Dataset**

```

data = {'ImageID': [], 'SubjectID': []}

# Iterate through image files
for filename in os.listdir(data_folder):
    if filename.endswith(".JPG") and "A" in filename:
        # Print for debugging
        print(f"Processing image: {filename}")

        # Load image using OpenCV
        image_path = os.path.join(data_folder, filename)
        image = cv2.imread(image_path)

        if image is None:
            print(f"Unable to load image: {image_path}")
            continue

        # Extract information from the filename
        parts = filename[:-4].split('A')
        if len(parts) == 2 and parts[0].isdigit() and
parts[1].isdigit():
            subject_id = parts[0]

            # Append data to lists
            data['ImageID'].append(filename)
            data['SubjectID'].append(subject_id)

# Create DataFrame
df = pd.DataFrame(data)
csv_filename = "/kaggle/input/dataset.csv"
df.to_csv(csv_filename, index=False)

# Print summary
print(f"CSV file saved with {len(df)} entries.")

```

**Gambar 5. 2 Potongan Kode Pembagian Data Menjadi 82 Kelas**

Setelah itu pembagian data menjadi 82 kelas berdasarkan `SubjectID` yang ada dalam dataset, setiap `SubjectID` merepresentasikan satu kelas, yang ditampilkan pada potongan kode Gambar 5.2.

### 5.1.2 Prapemrosesan Citra/ *Preprocessing*

Dalam langkah prapemrosesan ini, terlibat dua tahapan khusus pada citra wajah, yang pertama adalah konversi citra wajah dari format warna RGB (*Red, Green, Blue*) ke format skala abu-abu. Mengubah representasi warna menjadi skala abu-abu, memudahkan analisis fitur-fitur wajah tanpa memperhatikan warna spesifik.

Pada potongan kode Gambar 5.3 ini merupakan implementasi dua fungsi yang bertujuan untuk pemrosesan citra. Pertama, fungsi `resize_image(image_path, target_size)` dirancang untuk mengubah ukuran citra. Fungsi ini menerima dua parameter, yakni `image_path`, yang merupakan jalur file citra yang akan diubah ukurannya, dan `target_size`, yang berisi dimensi target untuk citra yang diubah ukurannya. Dengan menggunakan modul PIL (*Python Imaging Library*), fungsi membuka citra dari jalur yang ditentukan dan mengaplikasikan proses pengubahan ukuran dengan memanfaatkan metode `resize`.

Sementara itu, fungsi `give_gray_image(col_img)` untuk mengonversi citra berwarna menjadi citra skala abu-abu. Fungsi ini menerima satu parameter, yaitu `col_img`, yang merupakan citra berwarna dalam format BGR (*Blue, Green, Red*). Dengan menggunakan modul OpenCV, khususnya fungsi `cv2.cvtColor`, citra berwarna BGR dikonversi ke citra skala abu-abu. Hasil konversi tersebut selanjutnya dikembalikan sebagai output dari fungsi.

```
def resize_image(image, size=(128, 128)):
    # Resize gambar
    resized_image = image.resize(size)
    return resized_image
```

**Gambar 5.3** Potongan Kode Prapemrosesan Citra

```

def give_gray_image(col_img):
    col_img_np = np.array(col_img)

    if col_img_np.ndim == 2:
        gray_img_pil = Image.fromarray(col_img_np)
    elif col_img_np.ndim == 3 and col_img_np.shape[2] == 3:
        gray_img = cv2.cvtColor(col_img_np, cv2.COLOR_BGR2GRAY)
        gray_img_pil = Image.fromarray(gray_img)
    else:
        raise ValueError(f"Unsupported image format:
{col_img_np.shape}")

    return gray_img_pil

```

**Gambar 5. 4 Potongan Kode Mengubah dari RGB menjadi *Grayscale***

Proses selanjutnya adalah mendeteksi wajah dalam citra grayscale tersebut dengan menggunakan detektor yang telah diinisialisasi sebelumnya. Hasil deteksi berupa objek-objek yang merepresentasikan kotak pembatas (bounding boxes) wajah dalam citra.

```

def detect_faces_dlib(image):
    # Initialize dlib's face detector
    detector = dlib.get_frontal_face_detector()

    # Convert image to grayscale
    gray = cv2.cvtColor(np.array(image), cv2.COLOR_BGR2GRAY)

    # Detect faces in the grayscale image
    faces = detector(gray)

    # Convert dlib rectangle to tuple (x, y, w, h)
    faces = [(face.left(), face.top(), face.width(),
face.height()) for face in faces]

    return faces

```

**Gambar 5. 5 Potongan Kode Deteksi Wajah**

Selanjutnya yaitu dilakukan rotasi gambar wajah dalam preprocessing, terutama ketika gambar yang dikumpulkan memiliki orientasi yang bervariasi. Dengan memutar gambar ke sudut yang seragam, algoritma pengenalan wajah dapat lebih mudah mendeteksi dan mengenali fitur wajah secara konsisten, meningkatkan akurasi dan keandalan model.

Dalam *preprocessing* gambar untuk pengenalan wajah, memotong area wajah sangat penting untuk fokus pada bagian gambar yang relevan, yaitu wajah

itu sendiri. Dengan menggunakan fungsi `crop_face` pada Gambar 5.6 bertujuan untuk mengekstrak area wajah dari gambar yang lebih besar, menghilangkan latar belakang atau elemen lain yang tidak relevan. Ini membantu meningkatkan akurasi model pengenalan wajah dengan memastikan bahwa input yang diberikan adalah wajah yang terisolasi dengan koordinat yang konsisten. Hal ini juga membantu dalam normalisasi data dan pengurangan dimensi gambar, sehingga mempercepat proses pelatihan dan meningkatkan kinerja model.

```
def crop_face(image, face):
    # Extract face region
    x, y, w, h = face
    cropped_face = image.crop((x, y, x + w, y + h))
    return cropped_face
```

**Gambar 5. 6 Potongan Kode Crop Wajah**

Pada Gambar 5.7 menampilkan citra-citra hasil prapemrosesan yang telah menjalani serangkaian langkah pengolahan. Langkah-langkah prapemrosesan ini termasuk pengubahan ukuran citra agar memiliki dimensi yang seragam dan konversi dari citra berwarna menjadi citra skala abu-abu. Citra-citra ini kini menampilkan karakteristik yang diperoleh melalui transformasi tersebut, menciptakan citra yang optimal untuk tahapan analisis dan pemodelan selanjutnya. Dimensi seragam dan representasi skala abu-abu mempermudah pemahaman terhadap informasi yang terkandung dalam citra-citra tersebut dan pengolahan lebih lanjut terhadap fitur-fitur yang relevan.



**Gambar 5. 7 Citra Hasil Prapemrosesan**

### 5.1.3 Ekstraksi Fitur

Setelah melalui fase prapemrosesan, langkah selanjutnya adalah melakukan ekstraksi fitur. Dalam penelitian ini, fokus ekstraksi fitur dititikberatkan pada

karakteristik tekstur, seperti *Local Binary Pattern Histogram* (LBPH) dan *Histogram of Oriented Gradients* (HOG), serta ekstraksi fitur geometri melalui identifikasi facial landmarks. Tujuan dari proses ekstraksi fitur ini adalah untuk menghasilkan vektor fitur unik dari setiap citra, yang akan digunakan dalam langkah analisis yang lebih mendalam. Pendekatan ini memungkinkan identifikasi dan pemahaman yang lebih baik terhadap fitur-fitur spesifik dalam citra, menciptakan landasan yang esensial untuk analisis dan pemodelan citra berikutnya.

### 5.1.3.1 *Local Binary Pattern Histogram* (LBPH)

Dalam konteks pengenalan wajah dengan mempertimbangkan perubahan usia, *Local Binary Pattern Histogram* (LBPH) menjadi salah satu metode ekstraksi fitur yang diterapkan. Tahapan ini melibatkan proses ekstraksi fitur yang dilakukan dengan menghitung nilai piksel secara berurutan pada setiap citra yang menjadi objek pengolahan. Metode LBPH yang diimplementasikan dalam proses ekstraksi fitur ini mencakup serangkaian langkah rinci, di mana nilai piksel dari citra dievaluasi satu per satu dengan memperhatikan konteks tetangga piksel sekitarnya. Pendekatan ini bertujuan untuk mengidentifikasi dan merepresentasikan pola tekstur khusus yang ada dalam citra, memperkaya fitur-fitur yang relevan dan penting untuk analisis lanjutan dalam pengenalan wajah dengan mempertimbangkan faktor progresi usia.

```
# Fungsi ekstraksi fitur LBP
def extract_lbp_feature(image):
    radius = 3
    n_points = 8 * radius
    lbp = local_binary_pattern(image, n_points, radius,
method="uniform")
    hist, _ = np.histogram(lbp.ravel(), bins=np.arange(0,
n_points + 3), range=(0, n_points + 2))
    hist = hist.astype("float")
    hist /= (hist.sum() + 1e-7)
    return hist
```

**Gambar 5. 8 Potongan Kode LBPH**

Fungsi yang didefinisikan dalam Gambar 5.8 Potongan Kode LBPH, yaitu *extract\_lbp\_feature*, berfungsi untuk mengekstrak fitur menggunakan metode *Local Binary Pattern Histogram* (LBPH). Dalam konteks ini, variabel radius

ditetapkan sebagai 1, yang menentukan jarak dari pusat piksel yang akan digunakan dalam perhitungan LBPH. Jumlah titik tetangga (*n\_points*) dihitung sebagai hasil perkalian 8 dengan nilai radius, yang menunjukkan bahwa 8 titik tetangga digunakan dalam proses perhitungan LBPH. Selanjutnya, fungsi *local\_binary\_pattern* dari modul *scikit-image* (*skimage*) digunakan untuk menghitung nilai LBPH pada setiap piksel citra skala abu-abu. Parameter-parameter seperti *n\_points*, *radius*, dan metode *uniform* diteruskan ke fungsi untuk mengonfigurasi perhitungan LBPH.

Hasil perhitungan LBPH disimpan dalam variabel *lbp*, dan kemudian nilai LBPH tersebut diubah menjadi array satu dimensi menggunakan metode *flatten()*. Langkah ini dilakukan untuk menghasilkan vektor fitur, yang merepresentasikan informasi LBPH dari citra. Terakhir, vektor fitur tersebut dikembalikan sebagai output dari fungsi. Dengan adanya fungsi ini, dapat dengan mudah mengekstrak fitur LBPH dari citra skala abu-abu untuk digunakan dalam langkah-langkah analisis atau pemodelan selanjutnya, terutama dalam konteks pengenalan wajah yang memanfaatkan informasi tekstur citra.

### 5.1.3.2 Histogram of Oriented Gradients (HOG)

Fitur tekstur diekstraksi menggunakan HOG untuk menangkap pola tekstur dan orientasi gradien pada wajah. HOG memberikan representasi yang kuat terhadap distribusi tekstur halus atau garis-garis halus yang mungkin mengalami perubahan seiring waktu. Ini membantu sistem untuk tetap responsif terhadap perubahan-perubahan halus pada wajah yang terjadi selama progresi usia.

```
# Fungsi ekstraksi fitur HOG
def extract_hog_feature(image):
    hog_feature = feature.hog(image, orientations=9,
pixels_per_cell=(8, 8), cells_per_block=(2, 2), block_norm="L2-
Hys")
    return hog_feature
```

**Gambar 5. 9 Potongan Kode HOG**

Fungsi yang didefinisikan pada Gambar 5.9 Potongan Kode HOG, yaitu *extract\_hog\_feature*, bertujuan untuk mengekstrak fitur menggunakan metode

*Histogram of Oriented Gradients* (HOG) dari citra skala abu-abu. Fungsi menerima citra skala abu-abu (*gray\_img*) sebagai parameter input. Dalam implementasinya, metode HOG diaplikasikan pada citra menggunakan fungsi *hog* dari modul *scikit-image* (*feature*). Parameter-parameter seperti *orientations* (jumlah orientasi), *pixels\_per\_cell* (piksel per sel), *cells\_per\_block* (sel per blok), dan *block\_norm* (normalisasi blok).

Hasil perhitungan HOG dan visualisasi blok HOG disimpan dalam variabel *hog\_feature*. Namun, yang dikembalikan sebagai output fungsi hanya vektor fitur HOG itu sendiri. Proses ini memberikan vektor fitur yang merepresentasikan distribusi orientasi dari gradient piksel pada citra.

### 5.1.3.3 *Facial Landmarks dan FAP*

Pada tahap eksplorasi fitur geometri wajah, fungsi *extract\_facial\_landmarks* seperti pada potongan kode Gambar 5.10 memberikan kemampuan untuk mengidentifikasi dan mengekstrak titik-titik kunci penting pada wajah dari suatu citra. Hal ini bertujuan untuk memfasilitasi deteksi wajah dengan menggunakan algoritma deteksi wajah frontal dari *dlib*, sebuah *toolkit* yang menggabungkan teknologi pengolahan citra dan machine learning. Fungsi ini juga memanfaatkan *predictor* yang telah dilatih sebelumnya dengan file *shape\_predictor\_68\_face\_landmarks.dat* dari *dlib* untuk menentukan lokasi persis dari 68 titik kunci pada wajah.

Dengan menggunakan predictor ini, fungsi mampu menentukan lokasi yang tepat dari 68 titik kunci pada wajah, mencakup area seperti mata, hidung, mulut, dan bentuk wajah. Hasil ekstraksi berupa kumpulan koordinat titik-titik kunci ini tidak hanya memberikan representasi visual dari struktur wajah, tetapi juga berpotensi memberikan informasi geometri untuk digunakan dalam tugas analisis wajah.

```

# Function to calculate distance between two points
def calculate_distance(point1, point2):
    return np.linalg.norm(np.array(point1) - np.array(point2))

# Function to extract facial landmarks and FAP from an image
def extract_facial_landmarks(image_path):
    img = cv2.imread(image_path)
    gray = cv2.cvtColor(img, cv2.COLOR_BGR2GRAY)
    rects = detector(gray, 1)

    if len(rects) == 0:
        return None, None

    landmarks = []
    faps = []
    for rect in rects:
        shape = predictor(gray, rect)
        shape = np.array([[p.x, p.y] for p in shape.parts()])

        # Calculate FAP based on relevant points
        if len(shape) > 0:
            fap1 = calculate_distance(shape[36], shape[45]) #
            Distance between left and right eye
            fap2 = calculate_distance(shape[33], shape[62]) #
            Distance between nose tip and upper lip center
            fap3 = calculate_distance(shape[33], shape[19]) #
            Distance between nose tip and point between left eyebrow
            fap4 = calculate_distance(shape[48], shape[54])

    faps.append([fap1, fap2, fap3, fap4, fap5, fap6, fap7, fap8,
fap9, fap10, fap11, fap12, fap13, fap14, fap15, fap16])
        landmarks.append(shape.flatten())

    if len(landmarks) == 0:
        return None, None

    # Normalize FAPs if possible
    faps = np.array(faps)
    if np.any(np.std(faps, axis=0) == 0):
        # Handle case where standard deviation is zero
        faps_normalized = np.zeros_like(faps)
    else:
        faps_normalized = (faps - faps.mean(axis=0)) /
faps.std(axis=0)

    return np.array(landmarks), faps_normalized

```

**Gambar 5. 10 Potongan Kode *Facial Landmarks* dan FAP**

Pada Gambar 5.11 merupakan Ekstraksi fitur `facial_landmarks`, fitur HOG (*Histogram of Oriented Gradients*) dan fitur LBPH (*Local Binary Patterns Histogram*) digabungkan menjadi satu array fitur gabungan.

```
# Flatten the facial landmarks arrays
features_train_flat = np.vstack([np.array(faces).reshape(-1,
136) for faces in features_train])
features_test_flat = np.vstack([np.array(faces).reshape(-1, 136)
for faces in features_test])

# Flatten the FAP arrays
faps_train_flat = np.vstack([np.array(faps).reshape(-1, 16) for
faps in faps_train])
faps_test_flat = np.vstack([np.array(faps).reshape(-1, 16) for
faps in faps_test])

# Flatten the HOG arrays
hog_train_flat = np.vstack(hog_train)
hog_test_flat = np.vstack(hog_test)

# Flatten the LBP arrays
lbp_train_flat = np.vstack(lbp_train)
lbp_test_flat = np.vstack(lbp_test)

# Normalize the features
scaler = StandardScaler()
features_train_scaled =
scaler.fit_transform(features_train_flat)
features_test_scaled = scaler.transform(features_test_flat)

# Normalize the LBP features
lbp_scaler = StandardScaler()
lbp_train_scaled = lbp_scaler.fit_transform(lbp_train_flat)
lbp_test_scaled = lbp_scaler.transform(lbp_test_flat)
```

**Gambar 5. 11 Potongan Kode Penggabungan Fitur**

```
# Define PCA component number for facial landmarks + FAP
n_components_landmarks_fap = 70
pca_landmarks_fap = PCA(n_components=n_components_landmarks_fap)
features_train_pca_landmarks_fap =
pca_landmarks_fap.fit_transform(features_train_scaled)
features_test_pca_landmarks_fap =
pca_landmarks_fap.transform(features_test_scaled)

# Define PCA component number for HOG
n_components_hog = 110
pca_hog = PCA(n_components=n_components_hog)
hog_train_pca = pca_hog.fit_transform(hog_train_flat)
```

```

hog_test_pca = pca_hog.transform(hog_test_flat)

# Define PCA component number for LBP
n_components_lbp = 60
pca_lbp = PCA(n_components=n_components_lbp)
lbp_train_pca = pca_lbp.fit_transform(lbp_train_scaled)
lbp_test_pca = pca_lbp.transform(lbp_test_scaled)

# Combine PCA components of all types of features
features_train_combined =
np.hstack([features_train_pca_landmarks_fap, hog_train_pca,
lbp_train_pca])
features_test_combined =
np.hstack([features_test_pca_landmarks_fap, hog_test_pca,
lbp_test_pca])

```

**Gambar 5. 12 Potongan Kode PCA**

Pada Gambar 5.12 merupakan potongan kode untuk menunjukkan langkah-langkah untuk mengurangi dimensi fitur menggunakan *Principal Component Analysis* (PCA) pada tiga jenis fitur yang berbeda: facial landmarks + FAP, HOG, dan LBPH, serta menggabungkan hasilnya menjadi satu set fitur gabungan untuk pelatihan dan pengujian model pengenalan wajah. Kode ini bertujuan untuk menggabungkan berbagai jenis fitur yang telah direduksi dimensinya untuk digunakan dalam pelatihan dan pengujian model pengenalan wajah, sehingga model dapat memanfaatkan informasi dari berbagai sumber fitur secara efisien.

#### 5.1.4 *Support Vector Machine*

Kode Gambar 5.13 merupakan implementasi dari beberapa model menggunakan metode *Support Vector Machine* (SVM) sebagai classifier untuk pengenalan wajah berdasarkan fitur-fitur yang telah diekstraksi sebelumnya. Pertama, fitur-fitur wajah seperti *Local Binary Pattern Histogram* (LBPH), *Histogram of Oriented Gradients* (HOG), dan *facial landmarks* dibaca dari file yang telah disimpan sebelumnya. Selanjutnya, data dibagi menjadi set pelatihan dan pengujian, memastikan jumlah sampel yang sesuai. Kemudian, model SVM dilatih untuk setiap kombinasi fitur, seperti LBPH, HOG, dan facial landmarks. Setelah model dilatih, performanya dievaluasi menggunakan metrik akurasi dan dicetak untuk setiap model. Dengan demikian, kode ini memungkinkan untuk melatih dan mengevaluasi beberapa model berbeda dengan menggunakan metode SVM,

memungkinkan analisis yang mendalam terhadap performa masing-masing model dalam pengenalan wajah.

```
# Initialize SVM model in a Pipeline with StandardScaler
model = Pipeline([
    ("scaler", StandardScaler()),
    ("svm", SVC(kernel='linear', C=0.1, random_state=42))
])

# Train the model
model.fit(features_train_combined, labels_train)

# Predict labels for the test set
y_pred = model.predict(features_test_combined)

# Evaluate the model
accuracy = accuracy_score(labels_test, y_pred)
print(f"Accuracy: {accuracy:.2f}")

# Print classification report for more detailed evaluation
print(classification_report(labels_test, y_pred))
```

**Gambar 5. 13 Potongan Kode Menggunakan SVM**

## BAB VI

### HASIL DAN PEMBAHASAN

Pada bab ini, dipaparkan hasil implementasi yang dirancang untuk menilai pengaruh pendekatan *hybrid feature* terhadap kinerja prediksi model pengenalan wajah seiring bertambahnya usia subjek. Penelitian ini mencakup serangkaian eksperimen yang melibatkan pembangunan tujuh model pengenalan wajah, di mana setiap model menggunakan pendekatan *classifier* SVM. Model-model ini dirancang untuk mengenali wajah dengan mempertimbangkan progresi usia subjek. Untuk mengevaluasi kinerja setiap model, digunakan berbagai metrik yang mencakup akurasi, presisi, *recall*, dan *f1-score*. Metrik-metrik ini memberikan gambaran komprehensif tentang seberapa baik pendekatan *hybrid feature* dapat meningkatkan keandalan dan akurasi prediksi dalam konteks pengenalan wajah dengan variasi usia dengan melakukan mengevaluasi pengujian model pengenalan wajah dengan progresi usia yang terdapat pada Tabel 6.1.

**Tabel 6. 1 Daftar Model Ekstraksi Fitur**

Model	Deskripsi
Model 1	Ekstraksi fitur menggunakan LBPH
Model 2	Ekstraksi fitur menggunakan HOG
Model 3	Ekstraksi fitur menggunakan <i>Facial Landmarks</i> + FAP
Model 4	Ekstraksi fitur menggunakan LBPH dan HOG
Model 5	Ekstraksi fitur menggunakan LBPH dan <i>Facial Landmarks</i> + FAP
Model 6	Ekstraksi fitur menggunakan HOG dan <i>Facial Landmarks</i> + FAP
Model 7	Ekstraksi fitur menggunakan LBPH, HOG dan <i>Facial Landmarks</i> + FAP

Berikut ini adalah uraian mendetail mengenai hasil-hasil yang diperoleh dari penelitian yang telah dilakukan:

#### 6.1 Hasil Pembagian Data

Pada dataset FGNET, pembagian kelas didasarkan pada subjek yang diwakili oleh setiap gambar wajah dalam dataset tersebut. Setiap subjek atau

individu dalam dataset dianggap sebagai satu kelas yang unik. Dataset FGNET mencakup 82 subjek atau kelas yang berbeda, di mana setiap subjek direpresentasikan oleh serangkaian gambar wajah yang menunjukkan perubahan usia mereka. Tabel 6.2 menampilkan pembagian kelas dari dataset FGNET ini. Misalnya, pada gambar dengan ID 001A05.JPG, tiga digit pertama (001) menunjukkan kelas atau *SubjectID*, yang dalam contoh ini adalah Kelas 1 atau Subjek 1. Dua digit terakhir (05) menunjukkan label usia atau *AgeLabel*, yang dalam contoh ini menunjukkan bahwa subjek berusia 5 tahun pada saat gambar diambil.

**Tabel 6. 2 Hasil Pembagian Data**

<i>ImageID</i>	<i>SubjectID (Class)</i>	<i>AgeLabel</i>
001A02.JPG	1	2
001A05.JPG	1	5
001A08.JPG	1	8
001A10.JPG	1	10
001A14.JPG	1	14
001A16.JPG	1	16
....	....	....
082A00.JPG	82	0
082A03.JPG	82	3
082A16.JPG	82	16
082A18.JPG	82	18
082A20.JPG	82	20
082A21.JPG	82	21
082A22.JPG	82	22
082A23.JPG	82	23
082A25.JPG	82	25
082A27.JPG	82	27
082A31.JPG	82	31

## 6.2 Hasil Prapemrosesan Data

Hasil tahap prapemrosesan citra yang ditampilkan pada Gambar 6.1 dimulai dengan konversi gambar asli menjadi citra *grayscale*. Langkah ini penting untuk mengurangi kompleksitas gambar dengan menghilangkan informasi warna, sehingga setiap piksel hanya merepresentasikan nilai kecerahan atau intensitas. Prapemrosesan ini bertujuan untuk mempermudah tahap-tahap analisis citra

selanjutnya, karena citra *grayscale* tetap mempertahankan informasi penting seperti kontur dan tekstur.

Setelah konversi ke *grayscale*, tahap berikutnya adalah deteksi wajah pada citra tersebut. Deteksi wajah ini melibatkan proses identifikasi dan lokalisasi wajah manusia dalam gambar. Hasil dari deteksi wajah ini ditandai dengan adanya kotak pembatas (*bounding box*) yang mengelilingi wajah-wajah yang terdeteksi. Proses ini sangat penting untuk memfokuskan analisis hanya pada area wajah, mengabaikan bagian gambar lainnya yang tidak relevan.



**Gambar 6. 1 Hasil Prapemrosesan Gambar**

Setelah wajah berada dalam orientasi yang benar, tahap berikutnya adalah Cropping Face. Pada langkah ini, area wajah yang relevan dipotong dari gambar asli, memastikan bahwa hanya bagian wajah yang digunakan untuk analisis lebih lanjut. Proses pemotongan ini biasanya menggunakan deteksi landmark untuk menentukan batas-batas wajah yang akan dipotong. Hasil dari tahap ini adalah gambar wajah yang hanya mencakup wajah tanpa latar belakang atau elemen yang tidak relevan. Dengan menghilangkan latar belakang dan elemen-elemen yang tidak relevan, gambar wajah menjadi lebih bersih dan bebas dari gangguan, yang memudahkan proses analisis lebih lanjut. Selain itu, wajah dalam gambar yang dipotong sekarang memiliki ukuran yang lebih konsisten, yang penting untuk memastikan bahwa fitur-fitur wajah dapat diekstraksi dengan cara yang seragam.

Secara keseluruhan, prapemrosesan citra ini merupakan rangkaian langkah yang penting untuk memastikan bahwa data yang digunakan dalam analisis adalah data yang berkualitas tinggi dan relevan, yang pada akhirnya akan meningkatkan akurasi dan efektivitas dari sistem pengenalan wajah.

### 6.3 Hasil Ekstraksi Fitur

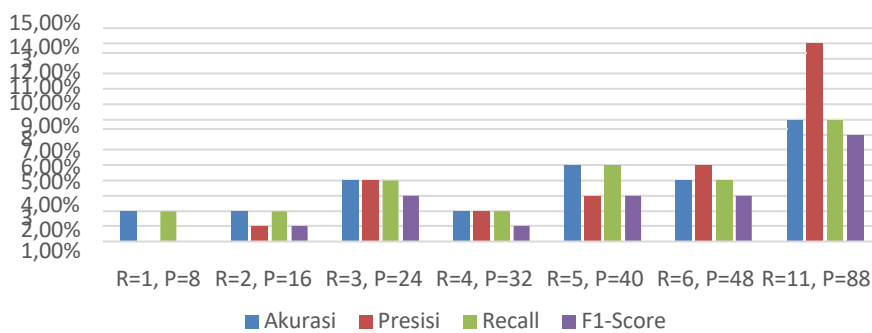
#### 6.3.1 Hasil Ekstraksi Fitur LBPH

Pada ekstraksi fitur menggunakan LBPH terdapat dua parameter yang mempengaruhi yaitu parameter radius dan juga jumlah titik dalam lingkaran. Radius merupakan parameter penting dalam perhitungan LBPH, yang menentukan jarak antara pixel pusat dengan pixel-pixel yang berada di sekelilingnya. Dalam penelitian ini, berbagai nilai radius telah digunakan untuk mengevaluasi pengaruhnya terhadap hasil ekstraksi fitur. Radius yang diterapkan pada penelitian ini meliputi nilai-nilai 1, 2, 3, 4, 5, 6 hingga 11. Setiap nilai radius tersebut memberikan konteks lokal yang berbeda, mempengaruhi bagaimana pola tekstur di sekitar pixel pusat dihitung dan direpresentasikan dalam bentuk kode biner. Selain radius, jumlah titik dalam lingkaran juga merupakan parameter penting dalam LBPH. Parameter ini menentukan jumlah pixel yang digunakan di sekitar pixel pusat untuk membentuk pola biner. Dalam penelitian ini, jumlah titik yang digunakan bervariasi, yaitu 8, 16, 24, 32, 40, 48, hingga 88 seperti pada Lampiran 1. Setiap konfigurasi jumlah titik ini mempengaruhi kompleksitas dan kekayaan informasi tekstur yang dapat diekstraksi dari citra. Semakin banyak titik yang digunakan, semakin rinci pola yang dapat diidentifikasi, namun juga menambah kompleksitas perhitungan.

Hasil evaluasi pada Tabel 6.3 dan Gambar 6.2 menampilkan kinerja classifier SVM berdasarkan kombinasi-kombinasi parameter LBPH yang berbeda, yaitu radius dan jumlah titik dalam lingkaran. Kinerja ini diukur menggunakan beberapa metrik evaluasi utama: Akurasi, Presisi, *Recall*, dan *F1-Score*. Dari tabel hasil evaluasi ini, dapat disimpulkan bahwa kombinasi parameter LBPH dengan radius 11 dan jumlah titik 88 menghasilkan kinerja terbaik untuk classifier SVM, dengan akurasi sebesar 9%, presisi 14%, *recall* 9%, dan *F1-Score* 8%. Hal ini menunjukkan bahwa pemilihan parameter LBP yang tepat dapat secara signifikan mempengaruhi efektivitas dan akurasi dalam proses klasifikasi menggunakan SVM.

Tabel 6. 3 Pengaruh Parameter LBP Menggunakan Classifier SVM


LBP	Metrik Evaluasi			
	Akurasi	Presisi	Recall	F1-Score
R=1, P=8	3%	1%	3%	1%
R=2, P=16	3%	2%	3%	2%
R=3, P=24	5%	5%	5%	4%
R=4, P=32	3%	3%	3%	2%
R=5, P=40	6%	4%	6%	4%
R=6, P=48	5%	6%	5%	4%
R=11, P=48	9%	14%	9%	8%



Gambar 6. 2 Hasil Evaluasi Parameter LBPH Menggunakan Classifier SVM

Kulit anak-anak cenderung lebih halus dan memiliki lebih sedikit detail tekstur dibandingkan dengan orang dewasa. Hal ini dapat menyebabkan LBPH kurang mampu menangkap fitur-fitur yang berbeda dan penting untuk pengenalan wajah. Wajah anak-anak mengalami perubahan signifikan dalam waktu yang relatif singkat karena pertumbuhan. Perubahan ini meliputi perubahan dalam bentuk wajah, ukuran fitur wajah, dan tekstur kulit, yang membuatnya sulit untuk mempertahankan konsistensi dalam ekstraksi fitur. Seiring bertambahnya usia, tekstur kulit mengalami perubahan, seperti munculnya kerutan dan perubahan pigmentasi. LBPH yang didasarkan pada pola tekstur mungkin tidak dapat menangkap perubahan ini secara efektif, yang dapat mengurangi akurasi model.

	precision	recall	f1-score	support		precision	recall	f1-score	support
001	0.20	1.00	0.33	1	044	0.00	0.00	0.00	0
002	0.00	0.00	0.00	1	045	0.00	0.00	0.00	0
003	0.00	0.00	0.00	2	046	0.00	0.00	0.00	4
004	0.00	0.00	0.00	1	047	0.00	0.00	0.00	3
005	0.00	0.00	0.00	2	048	0.00	0.00	0.00	2
006	0.17	1.00	0.29	1	049	0.00	0.00	0.00	2
007	0.00	0.00	0.00	1	050	0.00	0.00	0.00	0
008	0.00	0.00	0.00	4	051	0.00	0.00	0.00	4
009	0.33	0.33	0.33	3	052	0.00	0.00	0.00	3
010	0.00	0.00	0.00	1	053	0.00	0.00	0.00	1
011	0.00	0.00	0.00	2	054	0.50	0.25	0.33	4
012	0.00	0.00	0.00	5	055	0.25	1.00	0.40	1
013	0.00	0.00	0.00	2	056	0.00	0.00	0.00	1
014	0.00	0.00	0.00	2	057	0.00	0.00	0.00	2
015	0.00	0.00	0.00	2	058	0.50	0.50	0.50	2
016	0.00	0.00	0.00	6	059	0.00	0.00	0.00	1
017	0.00	0.00	0.00	2	060	0.00	0.00	0.00	1
018	0.00	0.00	0.00	1	061	0.50	0.17	0.25	6
019	0.00	0.00	0.00	0	062	0.00	0.00	0.00	1
020	0.00	0.00	0.00	3	063	0.00	0.00	0.00	1
021	0.00	0.00	0.00	3	064	0.00	0.00	0.00	3
022	0.00	0.00	0.00	3	065	0.00	0.00	0.00	2
023	0.00	0.00	0.00	4	066	0.00	0.00	0.00	2
024	0.00	0.00	0.00	0	067	0.00	0.00	0.00	1
025	0.00	0.00	0.00	5	068	0.00	0.00	0.00	1
026	0.00	0.00	0.00	2	069	0.00	0.00	0.00	0
027	0.20	0.50	0.29	2	070	0.00	0.00	0.00	4
028	0.00	0.00	0.00	0	071	0.00	0.00	0.00	3
029	0.00	0.00	0.00	3	072	0.00	0.00	0.00	1
030	0.50	0.67	0.57	3	073	1.00	0.14	0.25	7
031	0.00	0.00	0.00	1	074	0.00	0.00	0.00	3
032	0.25	1.00	0.40	1	075	0.00	0.00	0.00	2
033	0.00	0.00	0.00	2	076	0.00	0.00	0.00	3
034	0.25	0.25	0.25	4	077	0.00	0.00	0.00	4
035	0.00	0.00	0.00	2	078	0.00	0.00	0.00	5
036	0.00	0.00	0.00	3	079	0.00	0.00	0.00	2
037	0.00	0.00	0.00	3	080	1.00	0.25	0.40	4
038	0.00	0.00	0.00	3	081	0.25	0.50	0.33	2
039	0.40	0.50	0.44	4	082	0.00	0.00	0.00	2
040	0.00	0.00	0.00	7					
041	0.00	0.00	0.00	2	accuracy			0.09	194
042	0.00	0.00	0.00	4	macro avg	0.08	0.10	0.07	194
043	0.00	0.00	0.00	1	weighted avg	0.12	0.09	0.08	194



**Gambar 6.3 Classification Report dan Confusion Matrix Model 1  
LBPH Menggunakan classifier SVM**

### 6.3.2 Hasil Ekstraksi Fitur HOG

Pengaturan parameter pada ekstraksi fitur menggunakan *Histogram of Oriented Gradients* (HOG) memiliki dampak yang signifikan dalam konteks pengenalan wajah dengan progresi usia. Untuk meningkatkan akurasi dalam ekstraksi fitur HOG, dapat dilakukan penyesuaian lebih lanjut pada beberapa parameter. Beberapa pengaturan parameter yang diterapkan pada penelitian ini:

1. *Orientations* (Orientasi)

Ini mengacu pada jumlah bin atau arah gradien yang dihitung dalam setiap sel. Dalam penelitian ini terdapat dua pengaturan untuk jumlah orientasi: 9 dan 12. Orientasi yang lebih tinggi dapat membantu dalam menangkap detail yang lebih halus dari orientasi gradien dalam gambar.

2. *Pixels Per Cell* (Piksel per Sel)

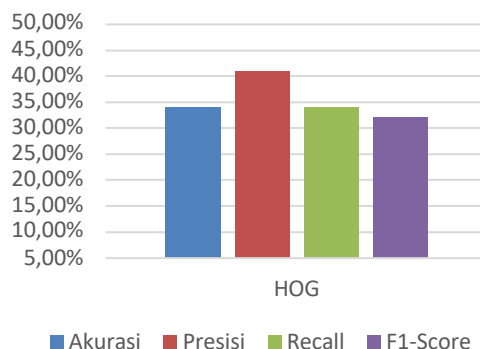
Menentukan ukuran dari setiap sel grid yang digunakan untuk menghitung histogram gradien. Nilai 8x8 pada pengaturan pertama dan 4x4 pada pengaturan kedua menunjukkan ukuran piksel yang diambil dalam setiap sel.

3. *Cells Per Block* (Sel per Blok)

Blok adalah area yang lebih besar dari sel-sel yang digunakan untuk normalisasi histogram lokal. Dalam penelitian ini, pengaturan pertama menggunakan blok 2x2, sementara yang kedua menggunakan blok 3x3. Pemilihan ukuran blok yang lebih besar dapat membantu dalam mengurangi sensitivitas terhadap variasi kecil dalam posisi objek.

**Tabel 6. 4 Hasil Evaluasi Parameter HOG Menggunakan Classifier SVM**


Hasil Evaluasi dengan <i>Classifier</i> SVM			
Akurasi	Presisi	<i>Recall</i>	F1-Score
34,00%	41,00%	34,00%	32,00%



**Gambar 6. 4 Hasil Evaluasi Parameter HOG Menggunakan Classifier SVM**

Hasil evaluasi pada Tabel 6.4 dan Gambar 6.5 menunjukkan performa dari penggunaan ekstraksi fitur HOG (*Histogram of Oriented Gradients*) dengan menggunakan *classifier* SVM (Support Vector Machine) untuk dua percobaan yang berbeda. Pada percobaan pertama, akurasi yang dicapai adalah 34,00%, dengan nilai presisi sebesar 41,00%, *recall* sebesar 34,00 %, dan *F1-Score* sebesar 32,00%, *classification report* dan *confusion matrix* model ini ditampilkan pada Gambar 6.8.

	precision	recall	f1-score	support		precision	recall	f1-score	support
001	0.33	1.00	0.50	1	044	0.00	0.00	0.00	0
002	0.09	1.00	0.17	1	046	0.50	0.50	0.50	4
003	0.50	1.00	0.67	2	047	1.00	1.00	1.00	3
004	0.50	1.00	0.67	1	048	0.29	1.00	0.44	2
005	1.00	0.50	0.67	2	049	0.00	0.00	0.00	2
006	1.00	1.00	1.00	1	050	0.00	0.00	0.00	0
007	0.00	0.00	0.00	1	051	0.00	0.00	0.00	4
008	1.00	0.75	0.86	4	052	0.50	0.33	0.40	3
009	0.00	0.00	0.00	3	053	0.33	1.00	0.50	1
010	0.00	0.00	0.00	1	054	0.50	0.25	0.33	4
011	0.40	1.00	0.57	2	055	1.00	1.00	1.00	1
012	1.00	0.20	0.33	5	056	0.00	0.00	0.00	1
013	0.50	0.50	0.50	2	057	0.00	0.00	0.00	2
014	0.00	0.00	0.00	2	058	0.00	0.00	0.00	2
015	0.33	0.50	0.40	2	059	0.00	0.00	0.00	1
016	0.50	0.17	0.25	6	060	0.00	0.00	0.00	1
017	1.00	0.50	0.67	2	061	0.33	0.17	0.22	6
018	0.00	0.00	0.00	1	062	0.00	0.00	0.00	1
020	0.25	0.33	0.29	3	063	0.00	0.00	0.00	1
021	0.50	0.33	0.40	3	064	0.00	0.00	0.00	3
022	1.00	0.33	0.50	3	065	0.50	1.00	0.67	2
023	0.00	0.00	0.00	4	066	0.00	0.00	0.00	2
024	0.00	0.00	0.00	0	067	0.00	0.00	0.00	1
025	0.00	0.00	0.00	5	068	0.00	0.00	0.00	1
026	0.25	0.50	0.33	2	069	0.00	0.00	0.00	0
027	0.25	0.50	0.33	2	070	1.00	0.25	0.40	4
028	0.00	0.00	0.00	0	071	1.00	0.33	0.50	3
029	0.00	0.00	0.00	3	072	0.00	0.00	0.00	1
030	0.67	0.67	0.67	3	073	0.50	0.14	0.22	7
031	0.00	0.00	0.00	1	074	0.25	1.00	0.40	3
032	0.17	1.00	0.29	1	075	0.00	0.00	0.00	2
033	1.00	0.50	0.67	2	076	0.27	1.00	0.43	3
034	1.00	0.75	0.86	4	077	0.50	0.25	0.33	4
035	0.50	0.50	0.50	2	078	1.00	0.40	0.57	5
036	0.12	0.33	0.18	3	079	1.00	0.50	0.67	2
037	1.00	0.33	0.50	3	080	0.60	0.75	0.67	4
038	0.20	0.33	0.25	3	081	0.50	0.50	0.50	2
039	0.33	0.25	0.29	4	082	0.00	0.00	0.00	2
040	0.00	0.00	0.00	7					
041	0.00	0.00	0.00	2	accuracy			0.34	194
042	0.00	0.00	0.00	4	macro avg	0.34	0.34	0.29	194
043	0.00	0.00	0.00	1	weighted avg	0.41	0.34	0.32	194



**Gambar 6.5** *Classification Report* dan *Confusion Matrix* Model 2  
HOG Menggunakan *classifier* SVM

### 6.3.3 Hasil Ekstraksi Fitur Facial Landmarks dan FAP

Hasil evaluasi ekstraksi fitur facial landmarks dan FAP menggunakan *classifier* SVM ditunjukkan dalam Tabel 6.5. Pada tabel tersebut, model yang dikembangkan mencapai akurasi sebesar 52,00%. Selain itu, nilai presisi yang diperoleh adalah 61,00%, yang mencerminkan kemampuan model untuk mengidentifikasi dengan tepat kelas yang relevan dari hasil prediksi. *Recall* sebesar 52,00% menunjukkan kemampuan model dalam mengenali keseluruhan *instance* yang relevan dari kelas yang diinginkan, sedangkan *F1-Score* mencapai 52,00%.

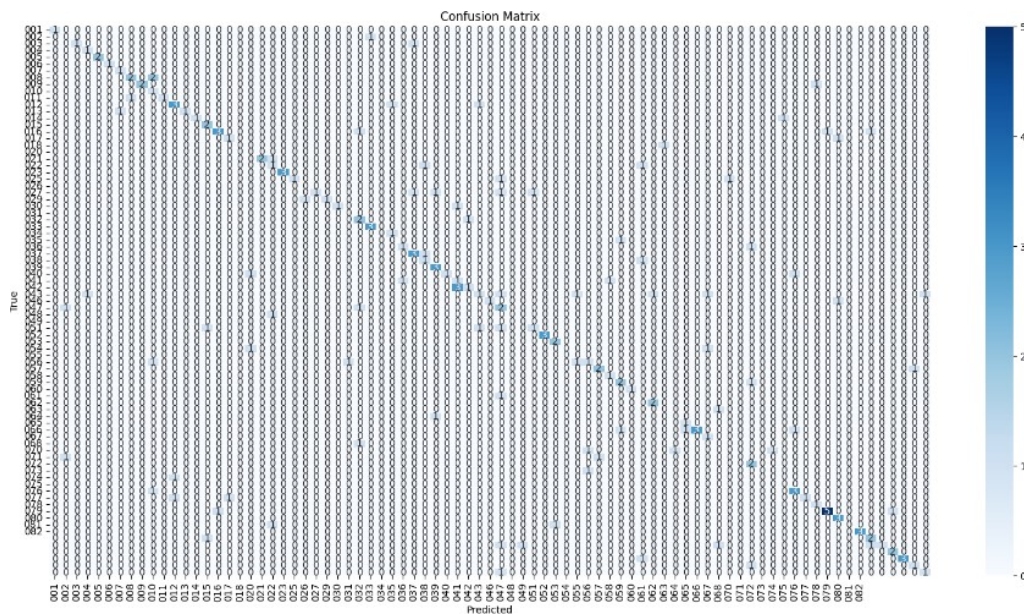
Evaluasi ini penting untuk memahami seberapa baik model dapat menggeneralisasi data baru dan seberapa akurat dalam memprediksi kelas dari fitur-fitur yang diekstraksi dari landmark wajah. Hasil evaluasi ini dapat digunakan sebagai dasar untuk memperbaiki atau meningkatkan kualitas model dalam pengenalan wajah dengan progresi usia.

**Tabel 6. 5 Hasil Evaluasi Ekstraksi Fitur *Facial Landmarks* dan FAP Menggunakan *Classifier SVM***

Model	Metrik Evaluasi			
	Akurasi	Presisi	Recall	F1-Score
<i>Facial Landmarks</i>	52,00%	61,00%	52,00%	52,00%

Accuracy: 0.52

	precision	recall	f1-score	support		precision	recall	f1-score	support
001	1.00	1.00	1.00	1					
002	0.25	1.00	0.40	1					
003	1.00	0.33	0.50	3					
004	1.00	1.00	1.00	1					
005	0.67	1.00	0.80	2					
006	0.50	1.00	0.67	1					
007	1.00	1.00	1.00	1					
008	1.00	0.50	0.67	4					
009	1.00	0.67	0.80	3					
010	0.25	1.00	0.40	1					
011	1.00	0.50	0.67	2					
012	0.67	0.40	0.50	5					
013	0.50	0.50	0.50	2					
014	1.00	0.50	0.67	2					
015	1.00	1.00	1.00	2					
016	0.50	0.33	0.40	6					
017	0.33	1.00	0.50	2					
018	0.67	1.00	0.80	2					
019	0.00	0.00	0.00	0					
020	1.00	0.33	0.50	3					
021	0.25	0.33	0.29	3					
022	0.75	1.00	0.86	3					
023	0.33	0.33	0.33	3					
024	0.00	0.00	0.00	0					
025	1.00	0.40	0.57	5					
026	1.00	0.50	0.67	2					
027	1.00	0.50	0.67	2					
029	0.00	0.00	0.00	3					
030	1.00	1.00	1.00	3					
031	0.00	0.00	0.00	1					
032	0.00	0.00	0.00	1					
033	0.33	0.50	0.40	2					
034	0.40	0.50	0.44	4					
035	0.00	0.00	0.00	2					
036	0.40	0.67	0.50	3					
037	0.50	0.25	0.33	4					
038	0.50	0.67	0.57	3					
039	0.50	0.50	0.50	4					
040	0.33	0.14	0.20	7					
041	0.50	0.50	0.50	2					
042	0.17	0.25	0.20	4					
043	0.00	0.00	0.00	1					
044	0.00	0.00	0.00	0					
					accuracy			0.52	196
					macro avg	0.51	0.50	0.47	196
					weighted avg	0.61	0.52	0.52	196



**Gambar 6. 6** *Classification Report* dan *Confusion Matrix* Model 3  
*Facial Landmarks* Menggunakan *classifier SVM*

### 6.3.4 Hasil Ekstraksi Menggunakan *Hybrid Feature*

#### 6.3.4.1 Hasil Ekstraksi LBPH dan HOG

Pada bagian ini, dibahas hasil dari proses ekstraksi fitur menggunakan kombinasi *Local Binary Pattern Histogram* (LBPH) dan *Histogram of Oriented Gradients* (HOG). Pada metode LBPH, radius optimal yang digunakan adalah 11, yang berarti jarak dari pusat piksel ke piksel tetangga untuk menghitung pola biner lokal adalah 11 piksel. Jumlah titik dalam lingkaran yang optimal adalah 88, menunjukkan bahwa setiap piksel dibandingkan dengan 88 tetangga sekitarnya yang tersebar merata dalam lingkaran dengan radius 11 piksel.

Sedangkan pada metode HOG, jumlah orientasi untuk *gradient* yang digunakan adalah 9, menghasilkan *histogram gradient* dengan 9 bin untuk berbagai arah *gradient*. Ukuran cell yang digunakan adalah 8x8 piksel, di mana setiap cell berisi gradient dari blok piksel berukuran 8x8. Ukuran blok yang digunakan adalah 2x3 cell, sehingga setiap blok terdiri dari 4 cell yang masing-masing berukuran 8x8 piksel.

Setelah fitur diekstraksi menggunakan kedua metode ini, hasilnya kemudian digabungkan untuk membentuk satu vektor fitur gabungan. Kombinasi ini

diharapkan dapat memanfaatkan kekuatan masing-masing metode ekstraksi untuk menghasilkan deskripsi yang lebih kaya dan informatif tentang gambar wajah, sehingga meningkatkan kinerja pada pengenalan wajah.

**Tabel 6. 6 Hasil Evaluasi *Hybrid Feature* LBPH dan HOG Menggunakan *Classifier SVM***

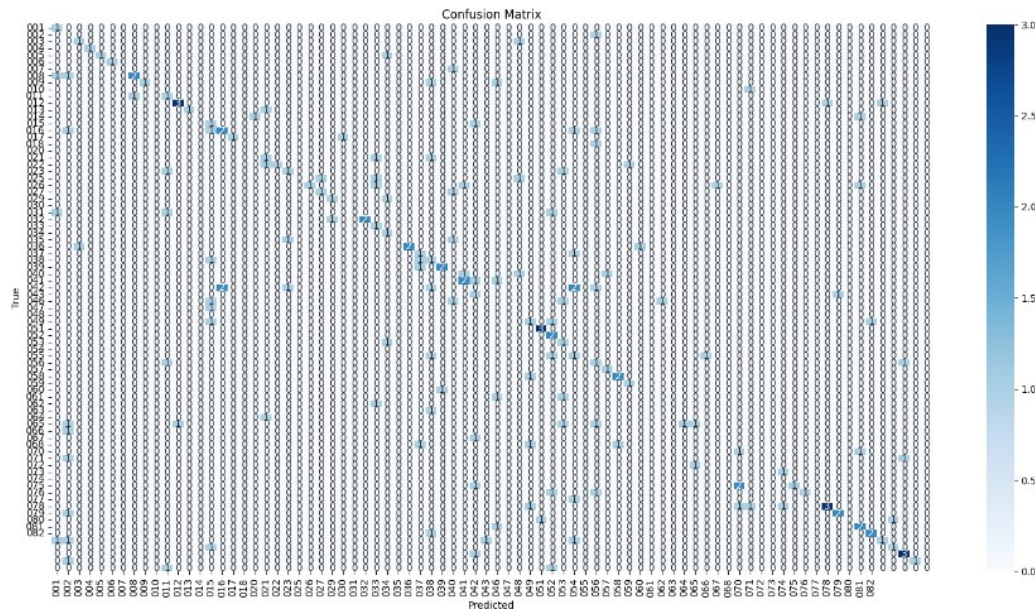
Model	Metrik Evaluasi			
	Akurasi	Presisi	Recall	F1-Score
LBPH + HOG	37,00%	45,00%	37,00%	36,00%

Tabel 6.6 dan Gambar 6.7 menampilkan hasil evaluasi model yang menggunakan kombinasi fitur *Local Binary Pattern Histogram* (LBPH) dan *Histogram of Oriented Gradients* (HOG) dengan *classifier Support Vector Machine* (SVM). Dari tabel, model ini mencapai akurasi sebesar 37,00%, yang menunjukkan proporsi prediksi yang benar terhadap total jumlah prediksi. Presisi model adalah 45,00%, mengindikasikan persentase prediksi positif yang benar dari semua prediksi positif yang dibuat oleh model. *Recall* model berada pada angka 37,00%, yang menunjukkan persentase dari semua data yang sebenarnya positif yang berhasil terdeteksi oleh model dan *F1-Score* model adalah 36,00%.

Gambar 6.7 menampilkan *Classification Report* dan *Confusion Matrix* dari model. *Classification Report* memberikan detail tentang presisi, *recall*, dan *F1-score* untuk setiap kelas yang diprediksi oleh model. Sementara itu, *Confusion Matrix* menggambarkan distribusi prediksi model, dengan sumbu horizontal menunjukkan kelas yang diprediksi dan sumbu vertikal menunjukkan kelas yang sebenarnya. Diagonal dari kiri atas ke kanan bawah menunjukkan jumlah prediksi yang benar (*True Positives*), sementara elemen-elemen di luar diagonal menunjukkan prediksi yang salah (*False Positives* dan *False Negatives*). *Confusion matrix* ini menunjukkan bahwa ada sejumlah prediksi yang benar tersebar di sepanjang diagonal, mengindikasikan bahwa model mampu mengklasifikasikan beberapa gambar wajah dengan benar. Namun, masih terdapat sejumlah prediksi yang salah tersebar di luar diagonal, menandakan bahwa model masih memerlukan peningkatan lebih lanjut untuk mencapai kinerja yang lebih baik.

Secara keseluruhan, hasil evaluasi ini menunjukkan bahwa kombinasi fitur LBPH dan HOG dengan *classifier* SVM memberikan kinerja yang cukup baik, namun masih ada ruang untuk perbaikan terutama dalam meningkatkan akurasi dan *recall*.

Accuracy: 0.37									
	precision	recall	f1-score	support		precision	recall	f1-score	support
001	0.50	1.00	0.67	1					
002	0.12	1.00	0.22	1					
003	0.67	1.00	0.80	2	046	0.17	0.25	0.20	4
004	0.33	1.00	0.50	1	047	0.75	1.00	0.86	3
005	1.00	0.50	0.67	2	048	0.33	1.00	0.50	2
006	1.00	1.00	1.00	1	049	0.00	0.00	0.00	2
007	0.00	0.00	0.00	1	050	0.00	0.00	0.00	0
008	0.67	0.50	0.57	4	051	0.00	0.00	0.00	4
009	0.00	0.00	0.00	3	052	0.33	0.33	0.33	3
010	0.00	0.00	0.00	1	053	0.33	1.00	0.50	1
011	0.25	0.50	0.33	2	054	0.50	0.67	0.57	3
012	0.75	0.60	0.67	5	055	0.25	1.00	0.40	1
013	1.00	0.50	0.67	2	056	0.00	0.00	0.00	1
014	0.00	0.00	0.00	2	057	0.00	0.00	0.00	2
015	0.14	0.50	0.22	2	058	0.00	0.00	0.00	1
016	0.40	0.33	0.36	6	059	0.00	0.00	0.00	1
017	1.00	0.50	0.67	2	060	0.50	1.00	0.67	1
018	0.00	0.00	0.00	1	061	0.50	0.17	0.25	6
020	0.50	0.33	0.40	3	062	0.00	0.00	0.00	1
021	1.00	0.33	0.50	3	063	0.00	0.00	0.00	1
022	0.50	0.33	0.40	3	064	0.00	0.00	0.00	3
023	0.00	0.00	0.00	3	065	0.33	0.50	0.40	2
025	1.00	0.20	0.33	5	066	0.20	0.50	0.29	2
026	1.00	0.50	0.67	2	067	0.00	0.00	0.00	1
027	0.25	0.50	0.33	2	068	0.00	0.00	0.00	1
028	0.00	0.00	0.00	0	069	0.00	0.00	0.00	0
029	0.00	0.00	0.00	3	070	1.00	0.25	0.40	4
030	0.67	0.67	0.67	3	071	1.00	0.33	0.50	3
031	0.00	0.00	0.00	1	072	1.00	1.00	1.00	1
032	0.14	1.00	0.25	1	073	1.00	0.43	0.60	7
033	0.00	0.00	0.00	2	074	0.60	1.00	0.75	3
034	1.00	0.75	0.86	4	075	0.00	0.00	0.00	2
035	0.20	0.50	0.29	2	076	0.67	0.67	0.67	3
036	0.17	0.33	0.22	3	077	1.00	0.33	0.50	3
037	0.00	0.00	0.00	3	078	0.33	0.40	0.36	5
038	0.00	0.00	0.00	3	079	0.50	0.50	0.50	2
039	0.50	0.50	0.50	4	080	0.80	1.00	0.89	4
040	0.50	0.14	0.22	7	081	1.00	0.50	0.67	2
041	0.00	0.00	0.00	2	082	0.00	0.00	0.00	2
042	0.00	0.00	0.00	4					
043	0.00	0.00	0.00	1	accuracy			0.37	190
044	0.00	0.00	0.00	0	macro avg	0.35	0.36	0.31	190
045	0.00	0.00	0.00	0	weighted avg	0.45	0.37	0.36	190



**Gambar 6. 7** *Classification Report* dan *Confusion Matrix* Model 4  
LBPH+ HOG Menggunakan *classifier* SVM

#### 6.3.4.2 Hasil Ekstraksi LBPH dan *Facial Landmarks* serta FAP

Pada bagian ini, hasil dari proses ekstraksi fitur menggunakan metode *hybrid* yang menggabungkan *Local Binary Pattern* (LBP) dan *Facial Landmarks* serta FAP dibahas. LBPH digunakan untuk menangkap informasi tekstur wajah, dengan radius optimal sebesar 11 piksel dan jumlah titik optimal sebanyak 88, menunjukkan bahwa setiap piksel dibandingkan dengan 88 tetangganya yang tersebar dalam lingkaran dengan radius 11 piksel. Sementara itu, *Facial Landmarks* dan FAP digunakan untuk ekstraksi fitur geometri, menangkap struktur wajah. Kedua fitur ini kemudian digabungkan menjadi fitur *hybrid* yang mengandung informasi tekstur dan geometri wajah.


**Tabel 6. 7** Hasil Evaluasi *Hybrid Feature* LBPH dan *Facial Landmarks* + FAP  
Menggunakan *Classifier* SVM

Model	Metrik Evaluasi			
	Akurasi	Presisi	<i>Recall</i>	F1-Score
LBPH + <i>Facial Landmarks</i> , FAP	56,00%	64,00%	56,00%	55,00%

Evaluasi model yang menggunakan fitur *hybrid* LBPH dan *Facial Landmarks* serta FAP dengan *classifier Support Vector Machine* (SVM) menunjukkan hasil sebagai berikut: akurasi sebesar 56,00%, presisi 64,00%, *recall* 56,00%, dan *F1-Score* 55,00%.

Gambar 6.8 yang menampilkan laporan klasifikasi dan confusion matrix untuk model ini memberikan detail lebih lanjut tentang performa model, termasuk distribusi prediksi benar dan salah untuk setiap kelas. Confusion matrix membantu memahami bagaimana kesalahan prediksi model tersebar di antara kelas-kelas yang berbeda. Kesimpulannya, penggunaan fitur *hybrid* dari LBPH dan *Facial Landmarks* serta FAP memberikan hasil yang cukup baik dengan nilai akurasi sebesar 56,00% dan *F1-Score* sebesar 55,00%, meskipun masih terdapat ruang untuk perbaikan dalam hal peningkatan akurasi.

Accuracy: 0.56									
	precision	recall	f1-score	support		precision	recall	f1-score	support
001	1.00	1.00	1.00	1					
002	0.33	1.00	0.50	1	046	0.33	0.25	0.29	4
003	1.00	1.00	1.00	2	047	0.75	1.00	0.86	3
004	1.00	1.00	1.00	1	048	0.67	1.00	0.80	2
005	1.00	1.00	1.00	2	049	0.00	0.00	0.00	2
006	0.50	1.00	0.67	1	050	0.00	0.00	0.00	0
007	0.50	1.00	0.67	1	051	0.00	0.00	0.00	4
008	1.00	0.75	0.86	4	052	0.67	0.67	0.67	3
009	1.00	0.67	0.80	3	053	0.33	1.00	0.50	1
010	0.25	1.00	0.40	1	054	0.40	0.67	0.50	3
011	1.00	1.00	1.00	2	055	1.00	1.00	1.00	1
012	0.75	0.60	0.67	5	056	0.00	0.00	0.00	1
013	1.00	0.50	0.67	2	057	1.00	1.00	1.00	2
014	0.50	0.50	0.50	2	058	0.00	0.00	0.00	1
015	0.50	1.00	0.67	2	059	0.00	0.00	0.00	1
016	0.75	0.50	0.60	6	060	0.33	1.00	0.50	1
017	0.50	0.50	0.50	2	061	1.00	0.50	0.67	6
018	0.00	0.00	0.00	1	062	0.20	1.00	0.33	1
019	0.00	0.00	0.00	0	063	0.00	0.00	0.00	1
020	1.00	0.67	0.80	3	064	0.00	0.00	0.00	3
021	0.50	0.33	0.40	3	065	0.00	0.00	0.00	2
022	0.60	1.00	0.75	3	066	0.50	1.00	0.67	2
023	1.00	0.33	0.50	3	067	0.00	0.00	0.00	1
024	0.00	0.00	0.00	0	068	0.00	0.00	0.00	1
025	0.00	0.00	0.00	5	069	0.00	0.00	0.00	0
026	1.00	0.50	0.67	2	070	0.75	0.75	0.75	4
027	1.00	0.50	0.67	2	071	1.00	0.33	0.50	3
028	0.00	0.00	0.00	0	072	0.50	1.00	0.67	1
029	0.67	0.67	0.67	3	073	1.00	0.71	0.83	7
030	1.00	1.00	1.00	3	074	0.50	1.00	0.67	3
031	0.00	0.00	0.00	1					
032	0.00	0.00	0.00	1	075	0.00	0.00	0.00	2
033	1.00	0.50	0.67	2	076	1.00	1.00	1.00	3
034	0.75	0.75	0.75	4	077	0.67	0.67	0.67	3
035	0.50	0.50	0.50	2	078	1.00	0.40	0.57	5
036	0.33	0.67	0.44	3	079	0.67	1.00	0.80	2
037	1.00	0.33	0.50	3	080	1.00	0.75	0.86	4
038	0.40	0.67	0.50	3	081	0.50	0.50	0.50	2
039	0.50	0.50	0.50	4	082	0.50	0.50	0.50	2
040	1.00	0.14	0.25	7					
041	0.50	0.50	0.50	2					
042	0.22	0.50	0.31	4	accuracy			0.56	190
043	0.00	0.00	0.00	1	macro avg	0.52	0.53	0.48	190
044	0.00	0.00	0.00	1	weighted avg	0.64	0.56	0.55	190
045	0.00	0.00	0.00	0					



**Gambar 6. 8 Classification Report dan Confusion Matrix Model 5  
LBPH+ Facial Landmarks, FAP Menggunakan classifier SVM**

#### 6.3.4.3 Hasil Ekstraksi HOG dan Facial Landmarks serta FAP

Pada penelitian ini, metode HOG (*Histogram of Oriented Gradients*) digunakan untuk ekstraksi fitur dengan jumlah orientasi gradient sebanyak 9. *Histogram gradient* yang dihasilkan memiliki 9 bin untuk berbagai arah *gradient*. Ukuran *cell* yang digunakan adalah 8x8 piksel, di mana setiap *cell* berisi gradient dari blok piksel berukuran 8x8. Blok yang digunakan terdiri dari 2x3 *cell*, sehingga setiap blok berisi 4 *cell* yang masing-masing berukuran 8x8 piksel.

Selain ekstraksi fitur menggunakan HOG, dilakukan juga ekstraksi fitur menggunakan facial landmarks. Kedua metode ekstraksi fitur ini kemudian digabungkan untuk membentuk fitur *hybrid*.

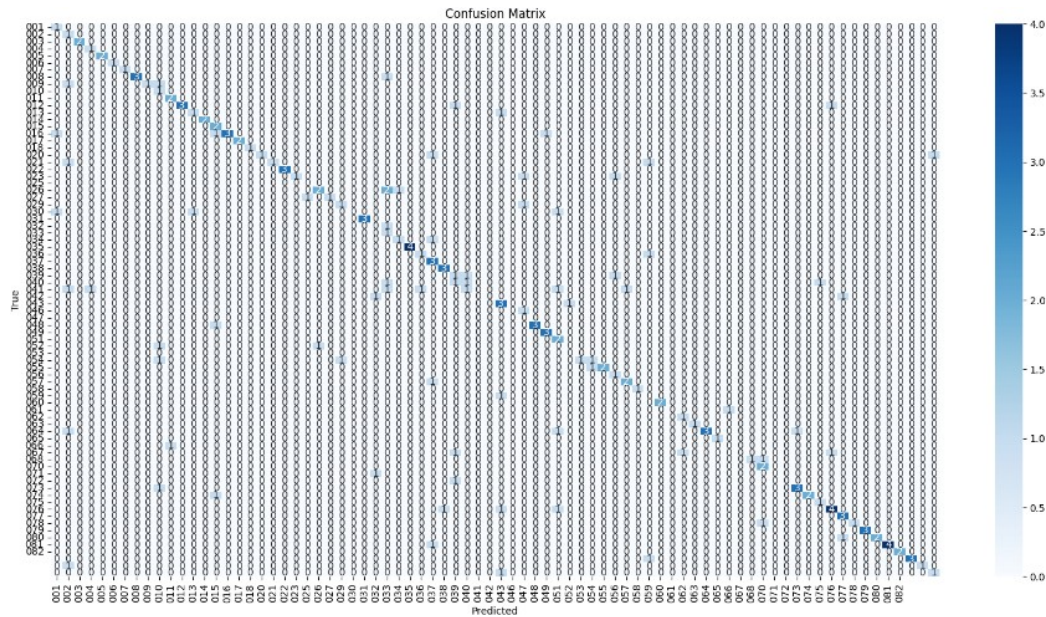
**Tabel 6. 8 Hasil Evaluasi Hybrid Feature HOG dan Facial Landmarks, FAP  
Menggunakan Classifier SVM**

Model	Metrik Evaluasi			
	Akurasi	Presisi	Recall	F1-Score
HOG + Facial Landmarks, FAP	64,00%	69,00%	64,00%	63,00%

Evaluasi performa model dilakukan menggunakan *classifier* SVM (*Support Vector Machine*). Tabel 6.8 menunjukkan hasil evaluasi *hybrid feature* HOG dan *facial landmarks*, FAP dengan menggunakan beberapa metrik evaluasi yaitu akurasi, presisi, *recall*, dan *F1-score*. Model *hybrid* HOG dan *facial landmarks* menghasilkan akurasi sebesar 64,00%, presisi 69,00%, *recall* 64,00%, dan *F1-score* 63,00%.

Gambar 6.9 menunjukkan hasil klasifikasi dan *confusion matrix* dari model yang menggunakan kombinasi fitur HOG, dan *facial landmarks* dengan *classifier* SVM. Matriks menganalisis jumlah prediksi yang benar dan salah untuk setiap kelas yang ada, memberikan gambaran yang lebih detail mengenai kinerja model dalam mengklasifikasikan data.

Accuracy: 0.64									
	precision	recall	f1-score	support		precision	recall	f1-score	support
001	0.50	1.00	0.67	1					
002	0.17	1.00	0.29	1					
003	1.00	0.50	0.67	2					
004	0.50	1.00	0.67	1					
005	1.00	1.00	1.00	2					
006	1.00	1.00	1.00	1					
007	1.00	1.00	1.00	1					
008	1.00	0.75	0.86	4					
009	1.00	0.33	0.50	3					
010	0.33	1.00	0.50	1					
011	0.67	1.00	0.80	2					
012	0.75	0.60	0.67	5					
013	0.50	0.50	0.50	2					
014	1.00	1.00	1.00	2					
015	0.40	1.00	0.57	2					
016	1.00	0.67	0.80	6					
017	0.50	1.00	0.67	2					
018	1.00	1.00	1.00	1					
019	0.00	0.00	0.00	0					
020	1.00	0.33	0.50	3					
021	1.00	0.33	0.50	3					
022	1.00	1.00	1.00	3					
023	0.00	0.00	0.00	3					
024	0.00	0.00	0.00	0					
025	1.00	0.80	0.89	5					
026	1.00	0.50	0.67	2					
027	0.50	0.50	0.50	2					
029	0.50	0.33	0.40	3					
030	1.00	1.00	1.00	3					
031	0.00	0.00	0.00	1					
032	0.17	1.00	0.29	1					
033	0.50	0.50	0.50	2					
034	0.80	1.00	0.89	4					
035	1.00	0.50	0.67	2					
036	0.40	0.67	0.50	3					
037	0.67	0.67	0.67	3					
038	0.25	0.33	0.29	3					
039	0.50	0.50	0.50	4					
040	0.00	0.00	0.00	7					
041	0.00	0.00	0.00	2					
042	0.38	0.75	0.50	4					
043	0.00	0.00	0.00	1					
044	0.00	0.00	0.00	0					
					046	0.75	0.75	0.75	4
					047	1.00	1.00	1.00	3
					048	0.40	1.00	0.57	2
					049	1.00	0.50	0.67	2
					050	0.00	0.00	0.00	0
					051	0.33	0.25	0.29	4
					052	1.00	0.67	0.80	3
					053	0.50	1.00	0.67	1
					054	0.75	1.00	0.86	3
					055	1.00	1.00	1.00	1
					056	0.00	0.00	0.00	1
					057	1.00	1.00	1.00	2
					058	0.00	0.00	0.00	1
					059	1.00	1.00	1.00	1
					060	1.00	1.00	1.00	1
					061	1.00	0.50	0.67	6
					062	1.00	1.00	1.00	1
					063	0.00	0.00	0.00	1
					064	0.00	0.00	0.00	3
					065	1.00	0.50	0.67	2
					066	0.50	1.00	0.67	2
					067	0.00	0.00	0.00	1
					068	0.00	0.00	0.00	1
					070	0.75	0.75	0.75	4
					071	1.00	0.67	0.80	3
					072	0.50	1.00	0.67	1
					073	0.86	0.86	0.86	7
					074	0.60	1.00	0.75	3
					075	0.00	0.00	0.00	2
					076	1.00	1.00	1.00	3
					077	1.00	0.67	0.80	3
					078	0.80	0.80	0.80	5
					079	0.67	1.00	0.80	2
					080	1.00	0.75	0.86	4
					081	1.00	0.50	0.67	2
					082	0.50	0.50	0.50	2
					accuracy			0.64	190
					macro avg	0.61	0.62	0.57	190
					weighted avg	0.69	0.64	0.63	190



**Gambar 6. 9** *Classification Report* dan *Confusion Matrix* Model 6  
HOG+ *Facial Landmarks*, FAP Menggunakan *Classifier* SVM

#### 6.3.4.4 Hasil Ekstraksi LBPH, HOG dan *Facial Landmarks*, FAP

Pada bagian ini, hasil dari proses ekstraksi fitur menggunakan metode *hybrid* yang menggabungkan *Local Binary Pattern Histogram* (LBPH), *Histogram of Oriented Gradients* (HOG), dan *facial landmarks*, FAP.

- **Ekstraksi Fitur LBPH**

*Local Binary Pattern Histogram* (LBPH) digunakan untuk menangkap informasi tekstur wajah. Pada metode ini, radius optimal yang digunakan adalah 11 piksel dengan jumlah titik optimal sebanyak 88. Hal ini berarti setiap piksel dibandingkan dengan 88 tetangganya yang tersebar dalam lingkaran dengan radius 11 piksel.

- **Ekstraksi Fitur HOG**

Metode HOG (*Histogram of Oriented Gradients*) digunakan untuk ekstraksi fitur dengan jumlah orientasi gradient sebanyak 9. Histogram gradient yang dihasilkan memiliki 9 bin untuk berbagai arah gradient. Ukuran cell yang digunakan adalah 8x8 piksel, di mana setiap cell berisi gradient dari blok

piksel berukuran 8x8. Blok yang digunakan terdiri dari 2x3 cell, sehingga setiap blok berisi 4 cell yang masing-masing berukuran 8x8 piksel.

- **Ekstraksi Fitur Menggunakan Facial Landmarks, FAP**

Selain ekstraksi fitur menggunakan LBPH dan HOG, dilakukan juga ekstraksi fitur menggunakan facial landmarks, FAP. Ketiga metode ekstraksi fitur ini kemudian digabungkan untuk membentuk fitur *hybrid*.

Tabel 6.9 menunjukkan hasil evaluasi *hybrid feature* yang menggabungkan LBPH, HOG, dan *facial landmarks* menggunakan *classifier Support Vector Machine* (SVM). Berikut adalah metrik evaluasi yang diperoleh akurasi: 62,00%, presisi: 70,00%, *recall*: 62,00% dan F1-Score: 62,00%.

Gambar 6.13 memperlihatkan *classification report* dan *confusion matrix* dari model yang menggunakan *hybrid feature* LBPH, HOG, dan *facial landmarks* dengan *classifier* SVM. *Classification report* ini mencakup nilai precision, recall, F1-score, dan support untuk setiap kelas. *Confusion matrix* menunjukkan performa model dalam mengklasifikasikan setiap kelas, dengan nilai diagonal yang menunjukkan jumlah prediksi benar untuk masing-masing kelas.


Hasil evaluasi menunjukkan bahwa model *hybrid* yang menggabungkan LBPH, HOG, dan *facial landmarks* memberikan performa yang baik dengan akurasi mencapai 62,00%. Nilai presisi yang tinggi sebesar 70,00% mengindikasikan bahwa model ini efektif dalam mengurangi *false positives*, sementara nilai *recall* sebesar 62,00% menunjukkan kemampuan model dalam mendeteksi *true positives*. F1-score yang diperoleh sebesar 62,00% menunjukkan keseimbangan yang baik antara presisi dan *recall*.

**Tabel 6. 9 Hasil Evaluasi *Hybrid Feature* LBP, HOG dan *Facial Landmarks*, FAP Menggunakan *Classifier* SVM**

Model	Metrik Evaluasi			
	Akurasi	Presisi	<i>Recall</i>	F1-Score
LBP + HOG + <i>Facial Landmarks</i> , FAP	62,00%	70,00%	62,00%	62,00%

Accuracy: 0.62

	precision	recall	f1-score	support		precision	recall	f1-score	support
001	0.50	1.00	0.67	1	046	0.60	0.75	0.67	4
002	0.20	1.00	0.33	1	047	0.75	1.00	0.86	3
003	1.00	1.00	1.00	2	048	0.40	1.00	0.57	2
004	0.50	1.00	0.67	1	049	0.00	0.00	0.00	2
005	1.00	1.00	1.00	2	050	0.00	0.00	0.00	0
006	1.00	1.00	1.00	1	051	0.33	0.25	0.29	4
007	1.00	1.00	1.00	1	052	1.00	0.67	0.80	3
008	1.00	0.75	0.86	4	053	0.33	1.00	0.50	1
009	1.00	0.33	0.50	3	054	1.00	0.67	0.80	3
010	0.33	1.00	0.50	1	055	1.00	1.00	1.00	1
011	0.67	1.00	0.80	2	056	0.00	0.00	0.00	1
012	0.75	0.60	0.67	5	057	1.00	1.00	1.00	2
013	1.00	0.50	0.67	2	058	0.00	0.00	0.00	1
014	1.00	0.50	0.67	2	059	0.50	1.00	0.67	1
015	0.50	1.00	0.67	2	060	0.50	1.00	0.67	1
016	1.00	0.50	0.67	6	061	1.00	0.33	0.50	6
017	1.00	1.00	1.00	2	062	0.50	1.00	0.67	1
018	1.00	1.00	1.00	1	063	0.00	0.00	0.00	1
019	0.00	0.00	0.00	0	064	0.00	0.00	0.00	3
020	1.00	0.67	0.80	3	065	1.00	0.50	0.67	2
021	1.00	0.33	0.50	3	066	0.50	1.00	0.67	2
022	1.00	1.00	1.00	3	067	0.00	0.00	0.00	1
023	1.00	0.33	0.50	3	068	0.00	0.00	0.00	1
024	0.00	0.00	0.00	0	070	1.00	0.75	0.86	4
025	1.00	0.60	0.75	5	071	1.00	0.67	0.80	3
026	1.00	0.50	0.67	2	072	0.50	1.00	0.67	1
027	0.50	0.50	0.50	2	073	0.71	0.71	0.71	7
029	1.00	0.33	0.50	3	074	0.50	1.00	0.67	3
030	1.00	1.00	1.00	3	075	0.00	0.00	0.00	2
031	0.00	0.00	0.00	1					
032	0.17	1.00	0.29	1	076	0.75	1.00	0.86	3
033	0.50	0.50	0.50	2	077	1.00	0.67	0.80	3
034	0.80	1.00	0.89	4	078	1.00	0.80	0.89	5
035	1.00	0.50	0.67	2	079	0.67	1.00	0.80	2
036	0.60	1.00	0.75	3	080	1.00	0.75	0.86	4
037	0.50	0.67	0.57	3	081	1.00	0.50	0.67	2
038	0.17	0.33	0.22	3	082	0.50	0.50	0.50	2
039	0.60	0.75	0.67	4					
040	0.00	0.00	0.00	7	accuracy			0.62	190
041	0.00	0.00	0.00	2	macro avg	0.60	0.60	0.55	190
042	0.40	0.50	0.44	4	weighted avg	0.70	0.62	0.62	190
043	0.00	0.00	0.00	1					
044	0.00	0.00	0.00	0					
045	0.00	0.00	0.00	0					



**Gambar 6. 10 Classification Report dan Confusion Matrix Model 7  
LBP+ HOG+ Facial Landmarks, FAP Menggunakan Classifier SVM**

Setelah membahas metode dan pendekatan yang digunakan dalam pengenalan wajah dengan progresi usia, hasil evaluasi dari penggunaan berbagai kombinasi fitur hibrida. Tabel 6.9 dan Gambar 6.10 memberikan gambaran lengkap tentang performa masing-masing model yang menggabungkan berbagai metode ekstraksi fitur, yaitu *Local Binary Pattern Histogram* (LBPH), *Histogram of Oriented Gradients* (HOG), dan *facial landmarks*.

Model yang menggabungkan LBPH dan HOG menunjukkan performa paling rendah dengan akurasi sebesar 37,00%, presisi 45,00%, recall 37,00%, dan F1-score 36,00%. Sementara itu, model yang menggabungkan LBPH dan *facial landmarks* memiliki peningkatan performa dengan akurasi 56,00%, presisi 64,00%, recall 56,00%, dan F1-score 55,00%.

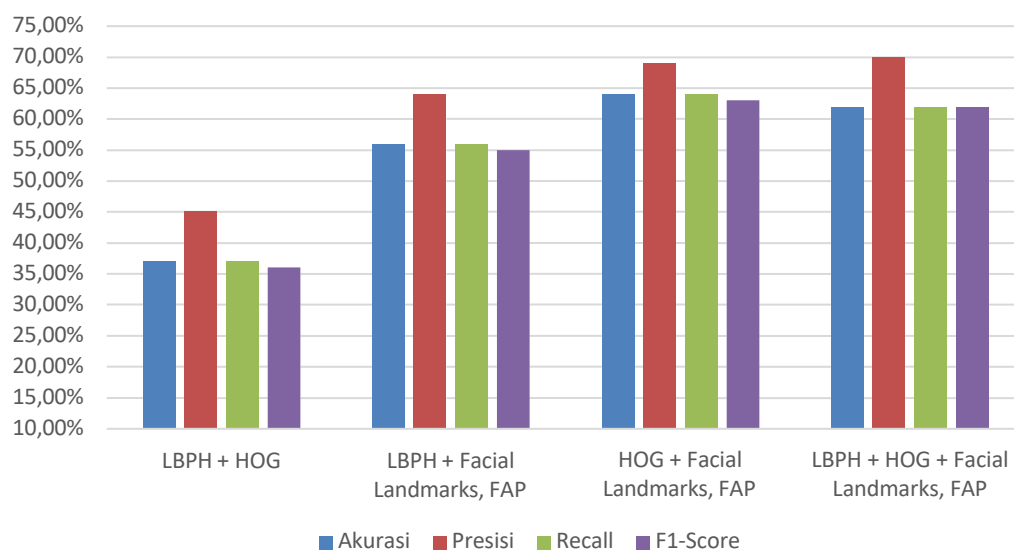
Model yang menggabungkan HOG dan *facial landmarks* menunjukkan peningkatan performa yang signifikan dengan akurasi 64,00%, presisi 69,00%, recall 64,00%, dan F1-score 63,00%. Kombinasi ini menunjukkan bahwa menambahkan *facial landmarks* ke dalam kombinasi fitur dapat meningkatkan performa model secara signifikan.

Terakhir, model yang menggabungkan ketiga metode (LBPH, HOG, dan *facial landmarks*) mencapai hasil dengan akurasi 62,00%, presisi 70,00%, recall 62,00%, dan F1-score 62,00%. Hal ini menunjukkan bahwa menambahkan lebih banyak metode ekstraksi fitur tidak selalu memberikan peningkatan performa yang signifikan jika satu kombinasi sudah cukup kuat.

**Tabel 6. 10 Hasil Evaluasi *Hybrid Feature* Menggunakan *Classifier SVM***

Model	Metrik Evaluasi			
	Akurasi	Presisi	Recall	F1-Score
LBPH + HOG	37,00%	45,00%	37,00%	36,00%
LBPH + <i>Facial Landmarks</i> , FAP	56,00%	64,00%	56,00%	55,00%
HOG + <i>Facial Landmarks</i> , FAP	64,00%	69,00%	64,00%	63,00%
LBPH + HOG + <i>Facial Landmarks</i> , FAP	62,00%	70,00%	62,00%	62,00%

Dari hasil ini, dapat disimpulkan bahwa penggunaan *facial landmarks* dalam kombinasi fitur memberikan kontribusi yang signifikan terhadap peningkatan performa model. Kombinasi HOG dan *facial landmarks*, serta kombinasi ketiganya, yaitu LBPH, HOG, dan *facial landmarks*, FAP menghasilkan performa terbaik dalam pengenalan wajah dengan progresi usia. Hal ini menunjukkan bahwa metode *hybrid* yang menggabungkan informasi tekstur dan geometris wajah mampu meningkatkan performa dalam tugas pengenalan wajah dengan progresi usia.



**Gambar 6. 11 Evaluasi Perbandingan Model *Hybrid Feature* Menggunakan *Classifier SVM***

### 6.1 Hasil Pengujian

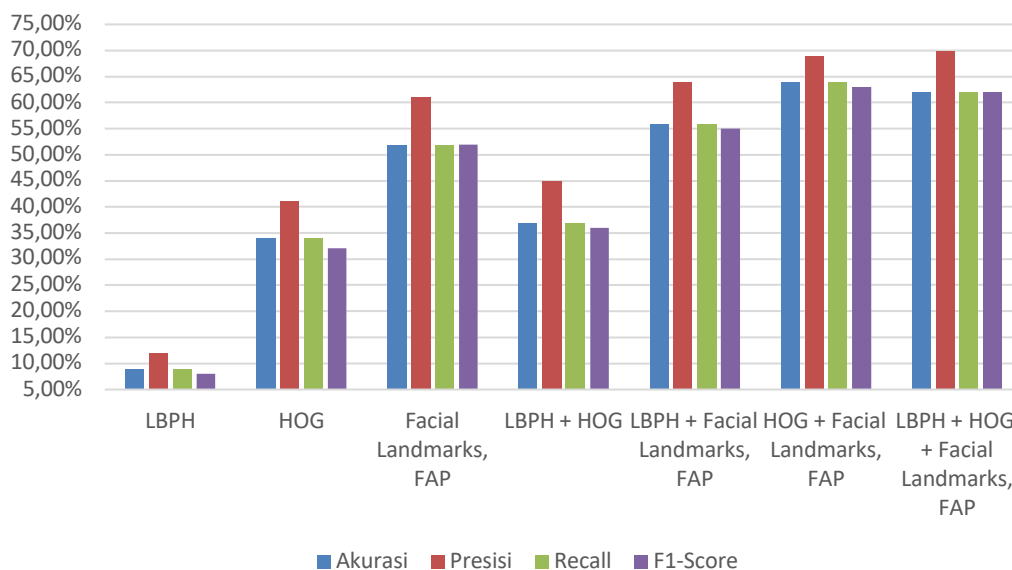
Dalam penelitian ini, dilakukan pengujian terhadap beberapa model untuk pengenalan wajah dengan mempertimbangkan progresi usia menggunakan SVM. Tabel 6.11 menampilkan hasil evaluasi performa berbagai model yang menggunakan fitur-fitur seperti LBPH (*Local Binary Patterns Histogram*), HOG (*Histogram of Oriented Gradients*), dan *facial landmarks*. Dari hasil pengujian, dapat dilihat bahwa kombinasi fitur HOG dengan *landmarks* wajah menunjukkan performa yang sangat baik dengan akurasi mencapai 64,00%, presisi 69,00%, *recall* 64,00%, dan *F1-score* 63,00%. Kombinasi ini menyoroti pentingnya penggunaan

fitur-fitur yang mencakup informasi tekstur dan struktur geometris wajah untuk meningkatkan ketepatan dalam pengenalan wajah yang mempertimbangkan faktor progresi usia.

**Tabel 6. 11 Pengujian Model Pengenalan Wajah dengan Progresi Usia Menggunakan SVM**

Model	Metrik Evaluasi			
	Akurasi	Presisi	Recall	F1-Score
LBPH	9,00%	12%	9%	8%
HOG	34,00%	41%	34%	32%
<i>Facial Landmarks, FAP</i>	52,00%	61%	52%	52%
LBPH + HOG	37,00%	45,00%	37,00%	36,00%
LBPH + <i>Facial Landmarks, FAP</i>	56,00%	64,00%	56,00%	55,00%
HOG + <i>Facial Landmarks, FAP</i>	64,00%	69,00%	64,00%	63,00%
LBPH + HOG + <i>Facial Landmarks, FAP</i>	62,00%	70,00%	62,00%	62,00%

Performa tertinggi dari kombinasi HOG dan landmarks wajah yang ditunjukkan pada Tabel 6.11 dan Gambar 6.12 dapat dijelaskan oleh kemampuan HOG dalam mengekstraksi informasi tentang orientasi dan distribusi gradien di area wajah, yang berguna untuk mengenali pola tekstur yang khas pada berbagai tahap usia. Sementara itu, *landmarks* wajah memberikan informasi spesifik tentang posisi dan bentuk titik-titik penting dalam wajah, seperti mata, hidung, dan mulut, yang sangat relevan dalam membangun representasi yang tepat untuk pengenalan wajah. Kombinasi ini secara efektif mengintegrasikan kekuatan masing-masing fitur untuk meningkatkan akurasi dan stabilitas model dalam menghadapi variasi progresi usia pada dataset yang digunakan.



**Gambar 6. 12 Perbandingan Performa Model Pengenalan Wajah dengan Progresi Usia Menggunakan *Classifier SVM***

Dalam penelitian ini, SVM menunjukkan akurasi tertinggi dengan kombinasi fitur HOG dan landmarks wajah mencapai 64,00%, presisi 69,00%, recall 64,00%, dan F1-score 63,00%.

Hasil ini juga didukung oleh Gambar 6.13 yang menampilkan contoh prediksi model yang akurat terhadap kelas sebenarnya yaitu Gambar 6.13 (a) dari data uji dalam konteks pengenalan wajah dengan progresi usia. Pada gambar tersebut, dapat dilihat bahwa model berhasil mengidentifikasi wajah-wajah pada berbagai tahap usia dengan tepat. Misalnya, wajah yang ditunjukkan memiliki ciri-ciri yang konsisten dengan dengan label kelasnya dalam dataset. Prediksi yang akurat ini mencerminkan kemampuan model untuk memahami perubahan karakteristik wajah seiring dengan progresi usia, berdasarkan fitur-fitur yang telah diekstraksi dan dipertimbangkan dalam proses pengenalan.

Correctly classified samples:  
 Index: 0, True Label: 038, Predicted: 038  
 Index: 3, True Label: 008, Predicted: 008  
 Index: 4, True Label: 037, Predicted: 037  
 Index: 5, True Label: 016, Predicted: 016  
 Index: 7, True Label: 009, Predicted: 009

Correctly classified samples



(a) Kelas yang Benar

Incorrectly classified samples:  
 Index: 1, True Label: 013, Predicted: 007  
 Index: 2, True Label: 029, Predicted: 048  
 Index: 6, True Label: 042, Predicted: 044  
 Index: 8, True Label: 068, Predicted: 038  
 Index: 10, True Label: 061, Predicted: 002

Incorrectly classified samples



(b) Kelas yang Salah

**Gambar 6. 13 Contoh Prediksi Model (a) Kelas yang Benar (b) Kelas yang Salah**

Sementara prediksi model yang salah terhadap kelas sebenarnya dari data uji menggambarkan situasi di mana model tidak mampu mengidentifikasi wajah

dengan akurat berdasarkan progresi usianya. Misalnya, terdapat kasus di mana wajah yang seharusnya diklasifikasikan pada kelas tertentu, namun model melakukan prediksi yang tidak sesuai. Hal ini dapat terjadi karena variasi yang kompleks dalam ciri-ciri wajah yang tidak dapat ditangkap dengan baik oleh fitur-fitur yang digunakan atau karena model mengalami kesulitan dalam proses klasifikasi dalam proses klasifikasi oleh model.

## 6.2 Pembahasan Hasil Performa Model

Pengujian model dievaluasi menggunakan metrik akurasi, presisi, *recall*, dan *F1-score* untuk menilai performa model dalam pengenalan wajah dengan progresi usia. Evaluasi ini bertujuan untuk menentukan seberapa baik model dapat mengenali wajah-wajah yang mengalami perubahan seiring bertambahnya usia.

**Tabel 6. 12 Hasil Pengujian Model Menggunakan SVM**

Model	Metrik Evaluasi			
	Akurasi	Presisi	<i>Recall</i>	<i>F1-Score</i>
HOG + <i>Facial Landmarks</i> , FAP	64,00%	69,00%	64,00%	63,00%
LBPH + HOG + <i>Facial Landmarks</i> , FAP	62,00%	70,00%	62,00%	62,00%

Tabel 6.12 menunjukkan bahwa model yang menggunakan SVM dengan fitur kombinasi HOG dan *Facial Landmarks* menghasilkan performa yang lebih baik secara konsisten (dengan akurasi, presisi, *recall*, dan *F1-score* sebesar 64,00%, 69,00%, 64,00%, dan 63,00%).

### Hasil Hybrid Feature

- **Hybrid Feature HOG dan *Facial Landmarks*, FAP**

*Hybrid Feature* HOG dan *facial landmarks* menunjukkan performa terbaik dengan akurasi 64,00%, presisi 69,00%, *recall* 64,00%, dan *F1-score* 63,00%. Hal ini menyoroti pentingnya integrasi fitur tekstur dan geometris dalam pengenalan wajah yang akurat dengan mempertimbangkan progresi usia.

HOG (*Histogram of Oriented Gradients*): Fitur ini sangat efektif dalam menangkap informasi tentang orientasi dan distribusi gradien di area wajah. HOG berguna untuk mengenali pola tekstur yang khas pada berbagai tahap usia. Gradien yang ditangkap oleh HOG membantu dalam mengenali detail-detail halus yang berubah seiring bertambahnya usia, seperti kerutan dan garis wajah.

*Facial Landmarks* dan FAP: Fitur ini menyediakan informasi spesifik tentang posisi dan bentuk titik-titik penting dalam wajah, seperti mata, hidung, dan mulut. *Landmarks* sangat relevan dalam membangun representasi yang tepat untuk pengenalan wajah. Informasi ini penting karena bentuk dan posisi relatif dari fitur-fitur wajah dapat berubah dengan bertambahnya usia, dan *landmark* membantu menangkap perubahan-perubahan ini secara akurat.

- ***Hybrid Feature LBPH, HOG, dan Facial Landmarks, FAP***

*Hybrid Feature* LBPH, HOG, dan *facial landmarks*, FAP memiliki hasil yang sama dengan kombinasi HOG dan *facial landmarks* saja, dengan akurasi 62,00%, presisi 70,00%, *recall* 62,00%, dan F1-score 62,00%.

LBPH (*Local Binary Patterns Histogram*): Fitur ini menangkap pola tekstur lokal di wajah, yang dapat membantu dalam mengenali variasi tekstur yang disebabkan oleh usia. Namun, dalam penelitian ini, penambahan LBPH tidak memberikan peningkatan performa yang signifikan dibandingkan dengan hanya menggunakan HOG dan *facial landmarks*. Hal ini mungkin disebabkan oleh LBP yang lebih sensitif terhadap variasi lokal kecil, yang mungkin tidak selalu relevan dalam konteks perubahan wajah yang lebih besar seiring bertambahnya usia.

## BAB VII

### KESIMPULAN DAN SARAN

#### 7.1 Kesimpulan

Berdasarkan hasil penelitian Pengenalan Wajah dengan Progresi Usia Menggunakan Metode *Hybrid Feature* pada Fitur Tekstur dan Fitur Geometri Wajah, maka dapat diambil kesimpulan sebagai berikut:

1. Penggunaan *Hybrid Feature*

Pendekatan yang menggabungkan fitur tekstur, seperti *Histogram of Oriented Gradients* (HOG), dengan fitur geometri wajah, seperti *facial landmarks*, memberikan hasil yang baik dalam pengenalan wajah dengan progresi usia. Kombinasi fitur ini memungkinkan model untuk menangkap informasi yang beragam dari gambar wajah, termasuk detail tekstur dan struktur geometris.

2. Performa Model

Model yang menggunakan metode *Support Vector Machine* (SVM) bersama dengan fitur *hybrid* mampu mencapai akurasi yang tinggi dalam mengklasifikasikan data. Secara khusus, model yang menggunakan fitur HOG dan *facial landmarks* memberikan performa terbaik dalam pengenalan wajah dengan progresi usia.

3. Pentingnya Fitur Geometri

Hasil penelitian menunjukkan bahwa fitur geometri wajah, seperti *facial landmarks*, memiliki kontribusi yang signifikan terhadap performa model. Hal ini menekankan pentingnya tidak hanya memperhatikan tekstur wajah, tetapi juga struktur geometrisnya dalam proses pengenalan wajah.

#### 7.2 Saran

Berdasarkan hasil dan analisis yang dilakukan, berikut adalah beberapa saran untuk penelitian dan pengembangan lebih lanjut:

1. Eksplorasi fitur lain, meskipun HOG dan *facial landmarks* telah menunjukkan performa yang baik, penelitian lebih lanjut dapat

mengeksplorasi fitur-fitur lain yang dapat mengekstraksi representasi wajah yang lebih kompleks dan mendalam.

2. Pengembangan model *hybrid*, menggabungkan metode tradisional dengan model *deep learning*, seperti *Convolutional Neural Networks* (CNNs), dapat memberikan peningkatan performa lebih lanjut. *Model hybrid* dapat memanfaatkan kekuatan kedua pendekatan untuk pengenalan wajah yang lebih akurat.

## DAFTAR PUSTAKA

- Adjabi, I., Ouahabi, A., Benzaoui, A., & Taleb-Ahmed, A. (2020). Past, present, and future of face recognition: A review. In *Electronics (Switzerland)* (Vol. 9, Issue 8, pp. 1–53). MDPI AG. <https://doi.org/10.3390/electronics9081188>
- Andono, P. N., Sutojo, J., & Muljono. (2017). *Pengolahan Citra Digital* (A. Pramesta, Ed.; 1st ed.). Penerbit ANDI (Anggota IKAPI).
- Barde, S., & Sinha, A. (2022). Face Recognition Across Age Progression By Using PCA. *I Journal*, 11. <https://doi.org/10.48047/IJFANS/S3/144>
- Baruni, K., Mokoena, N., Veeraragoo, M., & Holder, R. (2021a). Age Invariant Face Recognition Methods: A Review. *Proceedings - 2021 International Conference on Computational Science and Computational Intelligence, CSCI 2021*, 1657–1662. <https://doi.org/10.1109/CSCI54926.2021.00317>
- Baruni, K., Mokoena, N., Veeraragoo, M., & Holder, R. (2021b). Age Invariant Face Recognition Methods: A Review. *Proceedings - 2021 International Conference on Computational Science and Computational Intelligence, CSCI 2021*, 1657–1662. <https://doi.org/10.1109/CSCI54926.2021.00317>
- Bhavani, A. J. N., Sree, G. B., Yasaswini, A., Brahmam, B., Padmanaban, K., & Kumar, A. D. (2023). A Novel Real-time Automated Face Classification and Detection system using Machine Learning Technique. *Proceedings of the 2023 2nd International Conference on Electronics and Renewable Systems, ICEARS 2023*, 1119–1122. <https://doi.org/10.1109/ICEARS56392.2023.10085500>
- Boussaad, L., & Boucetta, A. (2021). The aging effects on face recognition algorithms: The accuracy according to age groups and age gaps. *2021 Proceedings of the International Conference on Artificial Intelligence for Cyber Security Systems and Privacy, AI-CSP 2021*. <https://doi.org/10.1109/AI-CSP52968.2021.9671213>
- Chater, A., Benradi, H., & Lasfar, A. (2023). New approach to similarity detection by combining technique three-patch local binary patterns (TP-LBP) with support vector machine. *IAES International Journal of Artificial Intelligence*, 12(4), 1644–1653. <https://doi.org/10.11591/ijai.v12.i4.pp1644-1653>
- Guo, G., & Zhang, N. (2019). A survey on deep learning based face recognition. *Computer Vision and Image Understanding*, 189. <https://doi.org/10.1016/j.cviu.2019.102805>
- Hu, Z., Wen, Y., Wang, J., Wang, M., Hong, R., & Yan, S. (2017). Facial age estimation with age difference. *IEEE Transactions on Image Processing*, 26(7), 3087–3097. <https://doi.org/10.1109/TIP.2016.2633868>
- Kortli, Y., Jridi, M., Al Falou, A., & Atri, M. (2020). Face recognition systems: A survey. In *Sensors (Switzerland)* (Vol. 20, Issue 2). MDPI AG. <https://doi.org/10.3390/s20020342>
- Kumar H N, N., Kumar, A. S., Prasad M S, G., & Shah, M. A. (2023). Automatic facial expression recognition combining texture and shape features from prominent facial regions. *IET Image Processing*, 17(4), 1111–1125. <https://doi.org/10.1049/ipr2.12700>

- Mehrabi, N., & Boroujeni, S. P. H. (2021). Age Estimation Based on Facial Images Using Hybrid Features and Particle Swarm Optimization. *ICCKE 2021 - 11th International Conference on Computer Engineering and Knowledge*, 412–418. <https://doi.org/10.1109/ICCKE54056.2021.9721496>
- Najafi Khanbebin, S., & Mehrdad, V. (2021). Local improvement approach and linear discriminant analysis-based local binary pattern for face recognition. *Neural Computing and Applications*, 33(13), 7691–7707. <https://doi.org/10.1007/s00521-020-05512-3>
- N.P. Gopalan. (n.d.). *Proceedings of the International Conference on Inventive Research in Computing Applications (ICIRCA 2018) : date: July 11-12, 2018.*
- Ojala, T., Pietika, M., & Ma, T. (n.d.). *Multiresolution Gray-Scale and Rotation Invariant Texture Classification with Local Binary Patterns.*
- Parate, V., Dey, A., Bhandarkar, M., Dafedar, S., & Chavan, S. (2022). Age Progression and Regression using cycleGAN. *2022 IEEE 3rd Global Conference for Advancement in Technology, GCAT 2022.* <https://doi.org/10.1109/GCAT55367.2022.9972089>
- Pard, M., & Bonafonte, A. (2002). Facial animation parameters extraction and expression recognition using Hidden Markov Models \$. In *Signal Processing: Image Communication* (Vol. 17).
- Patel, N., & Macwan, R. (n.d.). *A Survey on Facial Feature Extraction Techniques for Face Recognition.*
- Prakasa, E. (n.d.). *Ekstraksi Ciri Tekstur dengan Menggunakan Local Binary Pattern Texture Feature Extraction by Using Local Binary Pattern.*
- Santhosh, S., & Rajashekararadhya, S. V. (2023). A Design of Face Recognition Model with Spatial Feature Extraction using Optimized Support Vector Machine. *2023 2nd International Conference for Innovation in Technology, INOCON 2023.* <https://doi.org/10.1109/INOCON57975.2023.10101149>
- Sharifisoraki, Z., Amini, M., & Rajan, S. (2023). A Novel Face Recognition Using Specific Values from Deep Neural Network-based Landmarks. *Digest of Technical Papers - IEEE International Conference on Consumer Electronics, 2023-January.* <https://doi.org/10.1109/ICCE56470.2023.10043417>
- Sun, L., Dai, J. B., & Shen, X. (2021). Facial emotion recognition based on LDA and Facial Landmark Detection. *Proceedings - 2021 2nd International Conference on Artificial Intelligence and Education, ICAIE 2021*, 64–67. <https://doi.org/10.1109/ICAIE53562.2021.00020>
- Tang, J., Su, Q., Su, B., Fong, S., Cao, W., & Gong, X. (2020). Parallel ensemble learning of convolutional neural networks and local binary patterns for face recognition. *Computer Methods and Programs in Biomedicine*, 197. <https://doi.org/10.1016/j.cmpb.2020.105622>
- Usgan, M., Ferdiana, R., & Ardiyanto, I. (2021). Deep learning pre-trained model as feature extraction in facial recognition for identification of electronic identity cards by considering age progressing. *IOP Conference Series: Materials Science and Engineering*, 1115(1), 012009. <https://doi.org/10.1088/1757-899x/1115/1/012009>
- Vaidya, K. S., Patil, P. M., & Alagirisamy, M. (2023). Hybrid CNN-SVM Classifier for Human Emotion Recognition Using ROI Extraction and Feature Fusion.

- Wireless Personal Communications*, 132(2), 1099–1135.  
<https://doi.org/10.1007/s11277-023-10650-7>
- Vasanthi, M., & Seetharaman, K. (2022). Facial image recognition for biometric authentication systems using a combination of geometrical feature points and low-level visual features. *Journal of King Saud University - Computer and Information Sciences*, 34(7), 4109–4121.  
<https://doi.org/10.1016/j.jksuci.2020.11.028>
- Xiong, W., IEEE Computer Society, International Association for Computer & Information Science, Pattern Recognition and Machine Intelligence Association., & Institute of Electrical and Electronics Engineers. (n.d.). *17th IEEE/ACIS International Conference on Computer and Information Science (ICIS 2018) : proceedings : June 6-8, 2018, Singapore*.

## LAMPIRAN

Lampiran 1. Tabel Pengaturan Parameter pada Ekstraksi Fitur LBP

Pengaturan Parameter pada Ekstraksi Fitur LBP							
LBP Radius (R)	1	2	3	4	5	6	11
LBP Jumlah titik dalam lingkaran (P)	8	16	24	32	40	48	88

Lampiran 2. Pengaturan Parameter Ekstraksi Fitur HOG

Pengaturan Parameter Ekstraksi Fitur Menggunakan HOG				
Percobaan	<i>Orientations</i>	<i>Pixels Per Cell</i>	<i>Cells Per Block</i>	<i>Block Norm</i>
1	9	8,8	3,3	L2-Hys
2	12	4,4	3,3	L2-Hys

Lampiran 3. Hasil Ekstraksi Fitur

