



**IMPLEMENTASI KOMBINASI FITUR GEOMETRIS, LBP, DAN
HOG UNTUK EKSTRAKSI FITUR DENGAN MODEL
KLASIFIKASI SVM PADA PENGENALAN EKSPRESI WAJAH**

LAPORAN SKRIPSI

Oleh

**Putri Regita Saptaningtias
NIM 192410101106**

**KEMETERIAN PENDIDIKAN, KEBUDAYAAN, RISET DAN TEKNOLOGI
UNIVERSITAS JEMBER
FAKULTAS ILMU KOMPUTER
SISTEM INFORMASI
JEMBER
2024**



**IMPLEMENTASI KOMBINASI FITUR GEOMETRIS, LBP, DAN
HOG UNTUK EKSTRAKSI FITUR DENGAN MODEL
KLASIFIKASI SVM PADA PENGENALAN EKSPRESI WAJAH**

*diajukan untuk memenuhi sebagian persyaratan memperoleh gelar Sarjana pada
program studi Sistem Informasi*

LAPORAN SKRIPSI

Oleh

**Putri Regita Saptaningtias
NIM 192410101106**

**KEMETERIAN PENDIDIKAN, KEBUDAYAAN, RISET DAN TEKNOLOGI
UNIVERSITAS JEMBER
FAKULTAS ILMU KOMPUTER
SISTEM INFORMASI
JEMBER
2024**

PERSEMBAHAN

Penulisan skripsi ini saya persembahkan untuk:

1. Allah SWT yang selalu melimpahkan rahmat, petunjuk, dan hidayah-Nya sepanjang proses menimba ilmu, telah memberikan kelancaran dan kemudahan yang memungkinkan penelitian ini berjalan dengan baik. Dengan penuh kearifan, Allah membuka pintu-pintu ilmu yang mendalam dan memberikan petunjuk agar penelitian dapat dilaksanakan dengan lancar.
2. Orang tua penulis Ibunda Henny dan Ayahanda David, serta keluarga yang selalu memberikan dukungan, semangat, dan doa dalam proses pengerjaan skripsi
3. Bapak Muhamad Arief Hidayat S.Kom M.Kom, selaku Dosen Pembimbing Utama dan Bapak Tio Dharmawan, S.Kom, M.Kom selaku Dosen Pembimbing Pendamping yang senantiasa memberikan bimbingan, dukungan, dan semangat dalam menyelesaikan skripsi
4. Seluruh guru dan dosen yang berkontribusi dalam perjalanan menuntut ilmu
5. Semua sahabat dan teman penulis yang selalu memberi dukungan dan kerjasama selama menempuh perjalanan di bangku perkuliahan
6. Almamater Program Studi Sistem Informasi Fakultas Ilmu Komputer Universitas Jember

MOTTO

“Dan bersabarlah kamu, sesungguhnya janji Allah adalah benar.”

Q.S Ar- Rum: 60

“Jangan menggantungkan kebahagiaan kepada orang lain. Akan tetapi,
gantungkanlah kepada sumber segala kebahagiaan.”

Tere Liye

"Berapapun usiamu, selalu ada hal baru untuk dipelajari. Jika kau menganggapnya penyesalan, tamatlah sudah. Namun jika kau menganggapnya sebagai pelajaran, itu akan menjadi hal yang baru."

18 Again

PERNYATAAN ORISINALITAS

Saya yang bertanda tangan di bawah ini :

Nama : Putri Regita Saptaningtias

NIM : 192410101106

Menyatakan dengan sesungguhnya bahwa skripsi yang berjudul: *Implementasi Kombinasi Fitur Geometris, LBP, dan HOG untuk Ekstraksi Fitur dengan Model Klasifikasi SVM pada Pengenalan Ekspresi Wajah* adalah benar-benar hasil karya sendiri, kecuali jika dalam pengutipan substansi disebutkan sumbernya, dan belum pernah diajukan pada institusi manapun, serta bukan karya jiplakan. Saya bertanggung jawab atas keabsahan dan kebenaran isinya sesuai dengan skripsi ilmiah yang harus dijunjung tinggi.

Demikian pernyataan ini saya buat dengan sebenarnya, tanpa adanya tekanan dan paksaan dari pihak manapun serta bersedia mendapat sanksi akademik jika ternyata di kemudian hari pernyataan ini tidak benar.

Jember, 12 Januari 2024

Yang menyatakan,



Putri Regita Saptaningtias

NIM 192410101106

HALAMAN PERSETUJUAN

Skripsi berjudul *Implementasi Kombinasi Fitur Geometris, LBP, dan HOG untuk Ekstraksi Fitur dengan Model Klasifikasi SVM pada Pengenalan Ekspresi Wajah* telah diuji dan disahkan oleh Fakultas Ilmu Komputer Universitas Jember pada:

Hari : Senin

Tanggal : 22 Januari 2024

Tempat : Fakultas Ilmu Komputer Universitas Jember

Pembimbing

1. Pembimbing Utama

Nama : M. Arief Hidayat S.Kom.,M.Kom

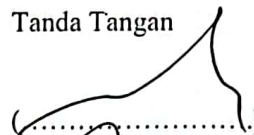
NIP : 198101232010121003

2. Pembimbing Anggota


Nama : Tio Darmawan S.Kom., M.Kom

NIP : 199111122022031011

Tanda Tangan



(.....)



(.....)

Penguji

1. Penguji Utama

Nama : Nelly Oktavia Adiwijaya, S.Si., MT

NIP : 198410242009122008

2. Penguji Anggota 1

Nama : Januar Adi Putra S.Kom, M.Kom

NIP : 199301312022031005



(.....)



(.....)

ABSTRACT

In communication, facial expressions play a major role with 55% of messages received by humans. Facial expression recognition faces challenges such as variations in lighting, pose, and skin color. This research aims to identify and understand emotions in human facial images by extracting features such as position, shape, and intensity of facial area movement. The research uses two types of feature extraction, namely geometric based (Vectorized Landmark and Landmark Curvature) and appearance based (Histogram of Oriented Gradients and Local Binary Pattern). The combination of these two methods was integrated with the Support Vector Machine (SVM) classification method. The study involved four main scenarios: no SMOTE and no feature selection resulted in an accuracy of 61%, no SMOTE with feature selection resulted in an accuracy of 47%, using SMOTE without feature selection resulted in an accuracy of 90%, and using SMOTE with feature selection resulted in an accuracy of 47%. These four scenarios used combined data of geometry features and texture features. This research makes an important contribution to facial expression recognition with more comprehensive feature extraction methods.

Keywords: facial emotion recognition, feature extraction, geometric based, appearance based, Support Vector Machine, Histogram of Oriented Gradients, Local Binary Pattern

RINGKASAN

Penelitian ini fokus pada peran ekspresi wajah dalam proses komunikasi, dimana sebanyak 55% pesan yang diterima oleh manusia melibatkan elemen ekspresi tersebut. Meskipun demikian, tantangan-tantangan seperti variasi pencahayaan, pose, dan warna kulit mempersulit pengenalan ekspresi wajah. Tujuan utama penelitian ini adalah untuk mengenali dan memahami emosi yang terkandung dalam gambar wajah manusia dengan mengekstrak fitur-fitur seperti posisi, bentuk, dan perubahan kelengkungan pada area wajah. Dalam pendekatan eksperimentalnya, penelitian ini menggunakan dua jenis ekstraksi fitur, yaitu *geometric based* (*Vectorized Landmark* dan *Landmark Curvature*) dan *appearance based* (*Histogram of Oriented Gradients* dan *Local Binary Pattern*).

Proses pemodelan dalam penelitian ini memanfaatkan algoritma *Support Vector Machine* (SVM), di mana parameter-parameter yang digunakan yaitu *kernel* dan *cost*. Berbagai jenis kernel, seperti *Radial Basis Function* (RBF), *poly*, dan *linear*, diterapkan untuk melihat pengaruhnya terhadap hasil model. Rentang nilai *cost* yaitu $[10^{-2}, 10^{-1}, 10^0, 10^1, 10^2, 10^{2.5}, 10^3, 10^{3.5}, 10^4]$. Untuk menemukan kombinasi optimal dari parameter-parameter ini, penelitian menggunakan metode *grid search*. Sebelum proses pemodelan dimulai, dilakukan proses *feature scaling* untuk memastikan keseragaman skala pada semua fitur. Penelitian ini kemudian dibagi menjadi empat kategori eksperimen: *without smote and feature selection*, *without smote and using feature selection*, *using smote and without feature selection*, dan *using smote and feature selection*. Pada kategori *without smote and feature selection* dilakukan skenario pada ketiga jenis data fitur yaitu fitur geometri saja, fitur tekstur saja, dan gabungan keduanya. Sementara pada kategori lainnya akan diimplementasikan pada gabungan data fitur tekstur dan geometri.

Pada skenario *without smote and feature selection* menghasilkan akurasi tertinggi yaitu 61% pada data fitur gabungan dengan *kernel RBF*. Kemudian pada skenario kedua, yaitu *without smote and using feature selection* menghasilkan akurasi tertinggi yaitu 48% pada *kernel RBF*. Skenario ketiga yaitu *using smote*

and without feature selection menghasilkan akurasi tertinggi sebesar 90% pada *kernel RBF*. Skenario ini merupakan skenario dengan model yang menghasilkan performa terbaik dari model lain. Terakhir, skenario keempat yaitu *using smote and feature selection* menghasilkan akurasi tertinggi sebesar 53% pada *kernel RBF*. Analisis perbandingan nilai *f1-Score* per kelas juga dilakukan untuk mengilustrasikan perbedaan antara dua situasi, yaitu menggunakan metode SMOTE dan tanpa SMOTE. Hasilnya menunjukkan bahwa performa pada situasi tanpa SMOTE cukup tinggi terutama pada kelas happy dan neutral, sementara kelas lainnya menunjukkan tingkat kinerja yang cukup rendah. Sebaliknya, implementasi SMOTE memberikan tingkat kinerja yang konsisten dan unggul di setiap kelas.

PRAKATA

Puji syukur atas kehadiran Allah SWT dan segala rahmat-Nya yang telah diberikan, sehingga Penulis dapat menyelesaikan penelitian dan penyusunan skripsi. Proses penyelesaian skripsi ini tak terlepas dari dukungan serta doa yang tulus dari berbagai pihak. Maka dari itu, Penulis menyampaikan banyak terima kasih kepada:

1. Allah SWT yang selalu melimpahkan rahmat, petunjuk, dan hidayah-Nya sepanjang proses menimba ilmu, telah memberikan kelancaran dan kemudahan yang memungkinkan penelitian ini berjalan dengan baik. Dengan penuh kearifan, Allah membuka pintu-pintu ilmu yang mendalam dan memberikan petunjuk agar penelitian dapat dilaksanakan dengan lancar.
2. Orang tua penulis Ibunda Henny dan Ayahanda David, serta keluarga yang selalu memberikan dukungan, semangat, dan doa dalam proses pengerjaan skripsi
3. Bapak Muhamad Arief Hidayat S.Kom M.Kom, selaku Dosen Pembimbing Utama dan Bapak Tio Dharmawan, S.Kom, M.Kom selaku Dosen Pembimbing Pendamping yang senantiasa memberikan bimbingan, dukungan, dan semangat dalam menyelesaikan skripsi
4. Seluruh guru, dosen, dan staff karyawan di Fakultas Ilmu Komputer Universitas Jember yang berkontribusi dalam perjalanan menuntut ilmu
5. Semua sahabat dan teman penulis yang selalu memberi dukungan dan kerjasama selama menempuh perjalanan di bangku perkuliahan
6. Almater Program Studi Sistem Informasi Fakultas Ilmu Komputer Universitas Jember
7. Para sahabat penulis, ciwi yakni Evi, Vio, Riris, Nuri, Shafa, Felyn, Farah, Nada, dan Fira, Ciwondel, serta Hida yang telah menjadi tempat berbagi cerita suka dan duka, memberikan dukungan dan motivasi hingga selesainya pengerjaan skripsi
8. Rekan-rekan mahasiswa program studi Sistem Informasi Fakultas Ilmu Komputer Universitas Jember angkatan 2019

Penulis menyadari bahwasanya dokumen skripsi ini masih jauh dari kata sempurna. Maka dari itu, penulis sangat mengharapkan masukan yang dapat membangun sehingga penelitian ini dapat terus berlanjut dan berkembang di masa yang akan datang, serta dapat memberikan manfaat bagi semua pihak.

Jember, 3 Januari 2024

Penulis

DAFTAR ISI

HALAMAN JUDUL	i
PERSEMBAHAN	iii
MOTTO	iv
PERNYATAAN ORISINALITAS.....	v
HALAMAN PERSETUJUAN	vi
ABSTRACT.....	vii
RINGKASAN.....	viii
PRAKATA.....	x
DAFTAR ISI	xii
DAFTAR TABEL.....	xiv
DAFTAR GAMBAR	xv
DAFTAR LAMPIRAN	xvi
BAB 1. PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah.....	3
1.3 Batasan Penelitian.....	3
1.4 Tujuan Penelitian	3
1.5 Manfaat Penelitian	3
BAB 2. TINJAUAN TEORI	5
2.1 Penelitian Terdahulu	5
2.2 Pengenalan Ekspresi Wajah	6
2.3 Computer Vision.....	6
2.4 <i>Image Preprocessing</i>	7
2.5 Fitur Geometri.....	8
2.6 <i>Histogram of Oriented Gradients (HOG)</i>	10
2.7 <i>Local Binary Pattern (LBP)</i>	10
2.8 <i>Handling Imbalanced data</i>	11
2.9 <i>Chi-square</i>	11
2.10 <i>Support Vector Machine (SVM)</i>	11
2.11 <i>Confusion matrix</i>	12
BAB 3. METODOLOGI PENELITIAN.....	13
3.1 Jenis Penelitian.....	13
3.2 Sumber Data	13
3.3 Tempat dan Waktu Penelitian	13
3.4 Tahapan Penelitian.....	14

3.4.1	<i>Preprocessing</i>	14
3.4.2	<i>Image Cropping</i>	15
3.4.3	<i>Histogram equalization</i>	15
3.4.4	<i>Z-Normalization</i>	15
3.4.5	<i>Data Augmentasi</i>	15
3.5	Ekstraksi Fitur	16
3.5.1	<i>Fitur Geometri</i>	16
3.5.2	<i>Histogram of Oriented Gradients (HOG)</i>	17
3.5.3	<i>Local Binary Pattern (LBP)</i>	17
3.6	<i>Handling Imbalanced data</i>	17
3.7	Seleksi Fitur	17
3.8	Modelling Experiments	18
3.9	Evaluasi	18
BAB 4. HASIL DAN PEMBAHASAN		19
4.1	<i>Dataset Acquisition</i>	19
4.2	<i>Preprocessing</i>	19
4.2.1	<i>Deteksi wajah dan landmark</i>	20
4.2.2	<i>Image Cropping</i>	21
4.2.3	<i>Histogram equalization</i>	21
4.2.4	<i>Z-Normalization</i>	22
4.2.5	<i>Data Augmentation</i>	23
4.3	Ekstraksi Fitur	23
4.3.1	<i>Vectorized Landmark (VL)</i>	23
4.3.2	<i>Landmark Curvature (LC)</i>	25
4.3.3	<i>Local Binary Pattern (LBP)</i>	26
4.3.4	<i>Histogram of Oriented Gradients (HOG)</i>	26
4.3.5	<i>Penggabungan Fitur</i>	27
4.4	Analisis Fitur	27
4.5	<i>Handling Imbalanced data</i>	28
4.6	Seleksi Fitur	29
4.7	<i>Classification Experiments</i>	29
4.8	<i>Model Evaluation</i>	30
4.8.1	<i>Without Smote and Feature Selection</i>	30
4.8.2	<i>Without Smote and using Feature Selection</i>	31
4.8.3	<i>Using Smote and Without Feature Selection</i>	32
4.8.4	<i>Using Smote and Feature Selection</i>	34
4.8.5	<i>Analisis Hasil</i>	35
BAB 5. KESIMPULAN DAN SARAN		37
5.1	Kesimpulan	37
5.2	Saran	37
DAFTAR PUSTAKA		38
LAMPIRAN-LAMPIRAN		41

DAFTAR TABEL

Tabel 4.1 Jumlah Fitur Data <i>Vectorized Landmark</i> per kelas	24
Tabel 4.2 Fitur <i>Vectorized Landmark</i>	25
Tabel 4.3 Fitur <i>Landmark Curvature</i>	25
Tabel 4.4 Fitur LBP	26
Tabel 4.5 Fitur HOG	27
Tabel 4.6 Fitur <i>Landmark Curvature</i> pada facial segment 2	28
Tabel 4.7 Hasil akurasi dan <i>F1-Score</i> skenario tanpa SMOTE dan seleksi fitur ...	31
Tabel 4.8 Hasil akurasi dan <i>F1-Score</i> skenario tanpa SMOTE dan menggunakan seleksi fitur	32
Tabel 4.9 Hasil akurasi dan <i>F1-Score</i> skenario menggunakan SMOTE namun tidak menggunakan seleksi fitur	33
Tabel 4.10 Hasil akurasi dan <i>f1-Score</i> skenario menggunakan SMOTE dan seleksi fitur	34
Tabel 4.11 Skenario yang dilakukan dan deskripsinya	35

DAFTAR GAMBAR

Gambar 3.1 Tahapan Penelitian	14
Gambar 4.1 Citra dengan <i>landmark</i> yang berhasil terdeteksi	20
Gambar 4.2 Citra dengan <i>landmark</i> yang berhasil terdeteksi	20
Gambar 4.3 Gambar sebelum dan sesudah <i>image cropping</i>	21
Gambar 4.4 Gambar sebelum dan sesudah <i>histogram equalization</i>	22
Gambar 4.5 Gambar sebelum dan sesudah <i>z-normalization</i>	22
Gambar 4.6 Gambar penerapan data augmentation	23
Gambar 4.7 Perbandingan visualisasi jumlah gambar setelah dideteksi dan digabung data augmentasi dengan data yang telah dilakukan SMOTE.....	28
Gambar 4.8 Hasil <i>confusion matrix</i> skenario tanpa menggunakan SMOTE dan seleksi fitur.....	30
Gambar 4.9 Hasil <i>confusion matrix</i> skenario tanpa menggunakan SMOTE dan menggunakan seleksi fitur	32
Gambar 4.10 Hasil <i>confusion matrix</i> skenario menggunakan SMOTE namun tanpa seleksi fitur.....	33
Gambar 4.11 Hasil <i>confusion matrix</i> skenario menggunakan SMOTE dan seleksi fitur	34
Gambar 4.12 Hasil akurasi.....	35
Gambar 4.13 Diagram perbandingan nilai <i>f1-Score</i> per kelas dengan dan tanpa SMOTE	36
Gambar 4.14 Hasil <i>confusion matrix</i> pada dataset <i>testing</i>	36

DAFTAR LAMPIRAN

Lampiran 2.1 <i>Facial segment</i> beserta deskripsi dan nomor <i>landmark</i> untuk setiap <i>segment</i>	41
Lampiran 3.1 Skenario penelitian	41
Lampiran 4.1 Hasil ekstraksi fitur <i>Landmark Curvature</i> (LC) per <i>facial segment</i>	42
Lampiran 4.2 Hasil ekstraksi fitur <i>Vectorized Landmark</i> (VL)	45
Lampiran 4.3 Hasil Seleksi Fitur	49
Lampiran 4.3 Jumlah data awal sebelum dideteksi	49
Lampiran 4.5 Jumlah data hasil <i>image cropping</i>	50
Lampiran 4.5 Jumlah data augmentation	50
Lampiran 4.6 Jumlah data setelah dilakukan penggabungan data augmentasi dan data z-normalization	51
Lampiran 4.7 Jumlah data gabungan setelah dilakukan deteksi ulang pada tahap <i>vectorized landmark</i>	51
Lampiran 4.8 kode program metode ekstraksi fitur <i>Landmark Curvature</i>	52
Lampiran 4.9 kode program metode ekstraksi fitur HOG	54
Lampiran 4.10 kode program metode ekstraksi fitur <i>Local Binary Pattern</i> (LBP)	54

BAB 1. PENDAHULUAN

1.1 Latar Belakang

Dalam berkomunikasi, sebagian besar pesan diterima melalui ekspresi wajah sebesar 55%, sementara 7% melalui kata-kata dan sisanya melalui suara (Triwijoyo et al., 2021). Dalam penerapan pengenalan ekspresi wajah, terdapat tantangan dalam mengatasi variasi dalam pose dan warna kulit (Revina & Emmanuel, 2021). Terdapat tujuh emosi dasar dalam manusia, yaitu bahagia, terkejut, marah, sedih, takut, jijik, dan netral. Emosi-emosi ini muncul sebagai hasil dari gerakan-gerakan yang terjadi di area wajah dan digunakan sebagai ciri atau karakteristik untuk mengidentifikasi ekspresi wajah yang mencerminkan emosi tersebut (Revina & Emmanuel, 2021). Untuk mengidentifikasi dan memahami emosi-emosi tersebut dalam citra wajah manusia, diperlukan proses ekstraksi fitur melibatkan analisis ciri-ciri wajah seperti posisi, bentuk, dan intensitas perubahan piksel pada wajah.

Ekstraksi fitur terdiri dari dua jenis, yaitu *geometric based* dan *appearance based* (Revina & Emmanuel, 2021). Kombinasi *geometric based* dan *appearance based* adalah solusi yang efektif karena memiliki informasi yang saling melengkapi untuk pengenalan ekspresi wajah. Fitur geometri berperan dalam merepresentasikan bentuk atau lokasi komponen wajah seperti area di sekitar mulut, mata, alis, dan hidung. Elemen-elemen ini mempunyai ukuran, bentuk, arah, dan posisi yang mempengaruhi ekspresi wajah yang terbentuk (Konar & Chakraborty, 2015). Fitur geometri yang digunakan dalam penelitian ini yaitu *Landmark Curvature* (LC) dan *Vectorized Landmark* (VL) yang diterapkan pada 68 titik *landmark* yang telah dideteksi menggunakan *library Dlib*. LC menggambarkan tingkat kelengkungan atau perubahan bentuk pada titik-titik *landmark* pada citra wajah. VL merujuk pada representasi titik-titik *landmark* pada wajah dalam bentuk vektor (Liu et al., 2021).

Dalam analisis citra wajah, tekstur merujuk pada susunan dan kerapatan pola piksel pada gambar wajah. Ekstraksi fitur berbasis tekstur dapat mengidentifikasi perubahan piksel dengan detail tinggi. Pada klasifikasi emosi wajah, informasi

tekstur seperti kerutan memiliki peranan yang lebih penting daripada warna. Hal ini dikarenakan gambar wajah dalam skala abu-abu memiliki sedikit variasi spektral, sehingga warna tidak begitu relevan (Verma Gyanendra K. & Kumar Singh Bhupesh, 2011). Salah satu metode ekstraksi fitur berbasis tekstur yang populer adalah *Local Binary Pattern* (LBP). LBP sering digunakan dalam analisis tekstur karena efisiensi komputasi yang tinggi dan kemampuan dalam mengatasi perubahan cahaya (Pan et al., 2017). LBP juga berkinerja stabil dan tangguh dalam berbagai resolusi gambar khususnya resolusi rendah (Shan et al., 2009). Metode ekstraksi fitur berbasis tekstur lainnya adalah *Histogram of Oriented Gradients* (HOG). Fitur HOG diperoleh dengan menghitung histogram orientasi *gradien* piksel dalam sel-sel wilayah lokal pada citra (Kobayashi et al., 2008). Fitur HOG peka terhadap bentuk objek yang dapat mendeteksi perubahan ekspresi wajah dan memungkinkan pengenalan emosi wajah yang lebih akurat (Dagher et al., 2019). HOG dan LBP sebagai metode ekstraksi fitur terbukti memiliki performa yang efisien jika digabungkan untuk mengekstraksi fitur pada pengenalan ekspresi wajah (Yaddaden, 2023).

Dalam pengenalan emosi wajah, terdapat beberapa metode yang sering digunakan untuk mengklasifikasikan ekspresi wajah. Pada penelitian yang dilakukan oleh (Mungra et al., 2020) memanfaatkan metode *Convolutional Neural Network* (CNN) pada dataset FER-2013 menghasilkan akurasi sebesar 78,52%. Penelitian lainnya dilakukan oleh (Kalsum et al., 2018) membandingkan kinerja algoritma *K-Nearest Neighbors* (KNN) dan *Support Vector Machine* (SVM) dalam pengenalan emosi wajah. Hasilnya menunjukkan bahwa SVM lebih unggul dengan akurasi sebesar 98,5% pada dataset CK+ dan 98,3% pada dataset JAFFE. Meskipun KNN juga memberikan akurasi di atas 90%, namun hasilnya lebih rendah dibandingkan dengan SVM karena KNN memiliki kinerja yang kurang baik dalam menangani data dengan distribusi yang kompleks. Penelitian lainnya dilakukan oleh (Liu et al., 2021) menggunakan SVM untuk mengklasifikasikan emosi menghasilkan akurasi di atas 95% pada tiga dataset yang berbeda.

Berdasarkan uraian diatas, dalam mengembangkan sistem pengenalan emosi wajah, penting untuk mempertimbangkan *geometric based* dan *appearance based*

khususnya fitur tekstur. Penggabungan kedua jenis fitur ini dapat menghasilkan hasil yang lebih baik karena keduanya saling melengkapi. Oleh karena itu, penelitian ini difokuskan pada penggabungan fitur tekstur dan geometri dengan metode klasifikasi SVM untuk mengevaluasi hasil dari gabungan kedua metode ekstraksi fitur tersebut.

1.2 Rumusan Masalah

Rumusan masalah dari penelitian ini berdasarkan latar belakang yang telah dijelaskan adalah bagaimana hasil kinerja penggabungan fitur geometris, *Local Binary Pattern* (LBP), dan *Histogram of Oriented Gradients* (HOG) untuk ekstraksi fitur dalam mengenali emosi pada wajah?

1.3 Batasan Penelitian

Batasan masalah diberikan agar dapat membatasi ruang lingkup penelitian dan menghindari pembahasan yang menyimpang pada proses penulisan. Batasan masalah pada penelitian ini adalah dataset yang digunakan dalam penelitian ini adalah dataset FER-2013.

1.4 Tujuan Penelitian

Berdasarkan latar belakang serta rumusan masalah yang telah dijabarkan, tujuan yang hendak dicapai dalam penelitian ini adalah mengetahui hasil kinerja penggabungan fitur geometris, *Local Binary Pattern* (LBP), dan *Histogram of Oriented Gradients* (HOG) untuk ekstraksi fitur dalam mengenali emosi pada wajah.

1.5 Manfaat Penelitian

Manfaat yang akan diperoleh dari penelitian ini adalah sebagai berikut :

1. Bagi Penulis

Meningkatkan kemampuan dan pemahaman pada topik yang diteliti terkait implementasi kombinasi ekstraksi fitur untuk meningkatkan akurasi klasifikasi pengenalan emosi wajah

2. Bagi Akademisi

Diharapkan penelitian yang dilakukan dapat memberikan pemahaman serta informasi yang berguna bagi pembaca dengan topik studi dan penelitian yang relevan

3. Bagi Peneliti Selanjutnya

Penelitian ini dapat memberikan pemahaman terkait topik yang diteliti dan menjadi bahan referensi untuk pengembangan penelitian oleh peneliti selanjutnya.

BAB 2. TINJAUAN TEORI

2.1 Penelitian Terdahulu

Dalam pengenalan ekspresi wajah, beberapa metode ekstraksi fitur terus mengalami pengembangan. Salah satu metode ekstraksi fitur yang populer dalam pengenalan ekspresi wajah adalah *Local Binary Pattern* (LBP) yang digunakan untuk mengekstraksi ciri tekstur pada wajah. LBP dikenal tahan terhadap perubahan cahaya (Beli & Guo, 2017). Dalam perkembangannya, LBP mulai digabungkan dengan metode-metode lain seperti metode ekstraksi fitur berbasis geometri. Salah satu fitur geometri yaitu adalah *Normalized Manhattan Chord* (NMC) telah dikombinasikan dengan LBP (Ghimire et al., 2017). Pengembangan fitur geometri dilakukan dengan memanfaatkan *landmark* wajah seperti *Landmark Curvature* (LC) dan *Vectorized Landmark* (VL). LC digunakan untuk mengukur tingkat perubahan kurvatur pada area wajah, sedangkan VL mengukur representasi vektor dari posisi *landmark* wajah yang menghasilkan pemahaman lebih komprehensif tentang kontribusi fitur-fitur tersebut terhadap interpretasi emosi pada wajah manusia (Liu et al., 2021). Selanjutnya terdapat kombinasi metode ekstraksi fitur LBP dan HOG yang memiliki performa baik jika digabungkan (Yaddaden, 2023). Berdasarkan penelitian-penelitian yang telah dijelaskan sebelumnya, penulis akan menggabungkan *geometric based* dan *appearance based*. *Geometric-based* fitur melibatkan LC dan VL. Sementara itu, dalam kategori *appearance-based*, akan digunakan LBP dan HOG.

Metode klasifikasi memiliki peran penting dalam pengenalan ekspresi wajah. Sejumlah penelitian terdahulu telah mengeksplorasi penggunaan metode klasifikasi dalam mengenali emosi wajah. Salah satu metode klasifikasi yang digunakan dalam pengenalan emosi wajah yaitu *Artificial Neural Network* (ANN). Namun, ANN memerlukan volume data *training* yang besar untuk meningkatkan performanya (Islam et al., 2018). Metode klasifikasi lain menggunakan *deep learning* yaitu *Convolutional Neural Network* (CNN) yang menghasilkan akurasi sebesar 78.52% pada dataset FER-2013. Namun, CNN memerlukan waktu komputasi yang sangat

besar (Mungra et al., 2020). Selanjutnya, terdapat metode *Support Vector Machine* (SVM) yang dioptimasi parameternya menggunakan *Genetic Algorithm* (GA) yang menghasilkan akurasi sebesar 95.85% pada dataset CK+ (8 class), 97.59% pada dataset CK+ (7 class), dan 96.56% pada dataset MUG (Liu et al., 2021).

Terdapat banyak cara yang bisa dilakukan untuk meningkatkan performa SVM, salah satunya adalah melakukan *hyperparameter tuning*. Melalui proses *hyperparameter tuning*, SVM dapat menghasilkan peningkatan signifikan dalam akurasi. *Hyperparameter tuning* dilakukan pada SVM dengan *kernel radial basic function* (RBF) yang menghasilkan akurasi sebesar 97.25% pada dataset CK+ (Ghimire et al., 2017). *Hyperparameter tuning* juga dilakukan pada GA-SVM dengan rentang nilai $cost (C) = [10^{-2}, 10^{-1}, 10^0, 10^1, 10^2, 10^{2.5}, 10^3, 10^{3.5}, 10^4]$ menghasilkan akurasi sebesar 95.85% pada dataset CK+ (8 class), 97.59% pada dataset CK+ (7 class), dan 96.56% pada dataset MUG (Liu et al., 2021). Selanjutnya, terdapat *hyperparameter tuning* pada SVM yaitu penggunaan *kernel linear* dan *polynomial* yang menghasilkan akurasi sebesar 97.66% pada dataset CK+ (Lakshmi & Ponnusamy, 2021). Berdasarkan penelitian-penelitian terdahulu yang telah disebutkan, tujuan dari penelitian ini untuk mengetahui bagaimana performa kombinasi fitur geometri, fitur HOG, dan fitur LBP dengan model klasifikasi SVM.

2.2 Pengenalan Ekspresi Wajah

Pengenalan ekspresi wajah dapat diterapkan pada berbagai bidang, termasuk penelitian perilaku manusia, praktik klinis seperti pengobatan gangguan mental, serta kehidupan sehari-hari dengan adanya aplikasi seperti asisten virtual dan teknologi rumah pintar (Ton-That & Cao, 2022).

2.3 Computer Vision

Computer Vision adalah bidang terkait teknik pengolahan citra dan pengenalan pola digunakan untuk mengenali informasi visual. Fungsi utamanya adalah memproses gambar dan video untuk meningkatkan kualitas, menganalisis objek, dan mengidentifikasi pola (Yuli Syafitri, 2022).

2.4 Image Preprocessing

a. Face Detection

Dlib memulai proses deteksi dengan menerapkan algoritma Histogram of Oriented Gradients (HOG), yang mengekstraksi fitur-fitur kunci dari gambar dengan fokus pada distribusi orientasi gradien di blok-blok kecil. Setelah ekstraksi fitur, dlib menggunakan classifier yang dilatih dengan dataset gambar berlabel untuk membedakan bagian wajah dari bagian lainnya. Setelah deteksi wajah berhasil, dlib menentukan posisi titik-titik penting pada wajah, seperti mata, hidung, dan mulut, dengan menggunakan model regresi linear sebanyak 68 landmark (Liu et al., 2021).

b. Image Cropping

Image Cropping adalah pemotongan gambar yang dilakukan untuk menghilangkan latar belakang yang tidak dibutuhkan. Perhitungan *image cropping* dihitung terlebih dahulu jarak antara pusat mata (d) menggunakan persamaan (1) (Li et al., 2020):

$$d = \frac{\sum_{n=42}^{47} x_n - \sum_{n=36}^{41} x_r}{6} \quad (1)$$

Proses *cropping* dimulai dari bagian dahi dengan mengukur jarak tegak lurus dari bagian atas gambar yang dipotong ke garis horizontal yang menghubungkan pusat mata sejauh $0.6d$. Tiga sisi lain dari citra yang dipotong mencakup koordinat titik landmark wajah ke-1 (sisi kiri), ke-9 (sisi bawah), dan ke-17 (sisi kanan).

c. Histogram Equalization

Histogram equalization merupakan salah satu metode yang digunakan untuk menyamaratakan kecerahan dan kontras pada citra. Metode ini bekerja dengan mengubah histogram gambar secara proporsional, sehingga intensitas piksel yang terkonsentrasi pada rentang tertentu akan didistribusikan secara merata di seluruh rentang nilai gambar (Ilyas et al., 2019). Perhitungan *histogram equalization* dapat dilihat pada persamaan (2):

$$dP_k = \frac{(L-1)}{N} \sum_{i=0}^k n_i, \quad k = 0, 1, 2, \dots, L-1 \quad (2)$$

n_i adalah jumlah piksel dengan tingkat keabuan tertentu, N adalah total jumlah piksel dalam citra, L adalah tingkat keabuan maksimum, k adalah tingkat keabuan dalam rentang $[0, L-1]$. Hasil dari perubahan nilai piksel pada citra p (P_k) dibulatkan agar sesuai dengan rentang $[0, L-1]$ (Nikan & Hassanpour, 2020).

d. Z-Score Normalization

Z-Score Normalization adalah digunakan untuk mengubah nilai-nilai pada suatu dataset menjadi distribusi normal dengan rata-rata 0 dan simpangan baku 1. Tahap ini mengurangi setiap nilai data dengan rata-rata dari seluruh dataset kemudian membagi hasilnya dengan simpangan baku dari dataset. Tujuannya untuk meningkatkan kontras citra. Nilai *Z-Score Normalization* didapatkan dengan menggunakan persamaan (1) (Li et al., 2020).

$$x' = \frac{x - \mu}{\sigma} \tag{3}$$

Nilai x' adalah nilai piksel baru, x adalah nilai piksel asli pada gambar, μ adalah nilai piksel rata-rata dari semua gambar sampel, dan σ adalah simpangan baku nilai piksel dari semua gambar sampel.

e. Data augmentasi

Data augmentasi adalah teknik pengolahan data yang menciptakan variasi baru dari data yang sudah ada. Tujuannya adalah meningkatkan kinerja model dalam mengenali pola atau fitur data dengan variasi yang lebih beragam. Hal ini membuat model lebih adaptif terhadap berbagai situasi dan kondisi yang mungkin terjadi (Li et al., 2020). Penelitian yang dilakukan oleh (Mungra et al., 2020) melakukan filter data augmentasi seperti *adjusting gamma value*, *enhancing contrast*, *color inversion*, *random noise*, *zooming*, *rotation*, dan *flipping* sebagai data augmentasi.

2.5 Fitur Geometri

Fitur geometri memanfaatkan hubungan geometri antara titik-titik fitur wajah (Zhao & Zhang, 2016). Fitur geometri yang digunakan dalam penelitian ini yaitu *Landmark Curvature* (LC) dan *Vectorized Landmark* (VL). Penjelasan dan persamaan dari LC dan VL sebagai berikut (Liu et al., 2021):

a. Landmark Curvature (LC)

LC digunakan untuk menghitung kelengkungan lokal pada tiap *landmark*. Persamaan (4) digunakan untuk menghitung persamaan tiap *facial segment*. *Facial segment* merupakan kumpulan *landmark* yang dikategorikan sesuai dengan lampiran 2.1.

$$fFS_n(x) = \sum_{k=0}^M a_k x^k \quad (4)$$

Dimana $fFS_n(x)$ adalah fungsi *least squares regression*, M adalah derajat polinomial, k adalah kelengkungan pada titik *landmark*, a adalah koefisien pada $fFS_n(x)$.

$$k_i = \frac{|f''FS_n(x_i)|}{\{1 + (f'FS_n(x_i))^2\}^{\frac{3}{2}}} \quad (5)$$

Dimana k_i adalah *curvature* pada *landmark* ke-i, $f''FS_n(x_i)$ adalah turunan kedua dari fungsi *least squares regression*, $f'FS_n(x_i)$ adalah turunan pertama dari fungsi *least squares regression*.

b. Vectorized Landmark (VL)

VL menggambarkan *euclidean distance* (d_j) dan *angle* (θ_j) antara setiap *landmark* dengan *geometric center*. *Geometric center* merupakan titik pusat dalam kumpulan *landmark* pada wajah. Untuk N *landmark*, *geometric center* didefinisikan sebagai $L_c = (x_c, y_c)$ dimana $x_c = \frac{1}{N} \sum_{j=1}^N x_j$ dan $y_c = \frac{1}{N} \sum_{j=1}^N y_j$. Selanjutnya, menghitung *euclidean distance* dan *angle* antara garis yang menghubungkan *landmark* tersebut dan sumbu horizontal gambar. Perhitungan *euclidean distance* dan *angle* dapat dilihat pada persamaan (6) dan (7) sebagai berikut.

$$d_j = \sqrt{(x_j - x_c)^2 + (y_j - y_c)^2} \quad (6)$$

$$\theta_j = \tan^{-1} \frac{y_j - y_c}{x_j - x_c} \quad (7)$$

2.6 Histogram of Oriented Gradients (HOG)

HOG adalah deskriptor yang menghitung kemunculan orientasi *gradien* dalam bagian-bagian lokal dari sebuah gambar (Nuryasin et al., 2023). Untuk menghitung *gradien magnitude* dan orientasi pada setiap piksel dihitung dalam wilayah lokal menggunakan *filter sobel*. *Gradien magnitude* $m(x,y)$ dan orientasi $\theta(x, y)$ dihitung dengan menggunakan *gradien* dalam arah X dan Y yang disimbolkan sebagai $dx(x,y)$ dan $dy(x,y)$. Perhitungan *gradien magnitude* dan orientasi dapat dilihat pada Persamaan (8) dan Persamaan (9) (Gunadarma et al., n.d.):

$$m(x, y) = \sqrt{dx(x, y)^2 + dy(x, y)^2} \quad (8)$$

$$\theta(x, y) = \tan^{-1} \left(\frac{dy(x, y)}{dx(x, y)} \right) \quad (9)$$

2.7 Local Binary Pattern (LBP)

LBP adalah operator untuk identifikasi tekstur dengan melakukan *thresholding* pada piksel gambar dan mengubahnya menjadi angka biner (Pietikäinen et al., 2011). Metode ini mampu membedakan pola tekstur terhadap perubahan tingkat keabuan akibat variasi cahaya (Retnoningrum et al., 2019). Untuk menghitung perbandingan nilai keabuan antara piksel tetangga (G_p) dengan piksel pusat (G_c), secara matematis dapat dilihat pada persamaan (10) dan persamaan (11):

$$LBP_{P,R} = \sum_{p=0}^{p-1} s(g_p - g_c) \cdot 2^p \quad (10)$$

$$s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (11)$$

Dari persamaan (10) dapat diketahui bahwa nilai LBP yang didasarkan pada P (banyaknya piksel tetangga) dan R (nilai jarak/radius) dilakukan perhitungan pengurangan G_p dengan G_c . Kemudian, nilai binerisasi pada setiap piksel dikalikan dengan 2^p , dimana p merupakan urutan piksel tetangga yang berurutan searah jarum jam. Nilai hasil akan diterapkan sebagai *thresholding* menggunakan Persamaan (11). Jika hasilnya < 0 , nilainya diatur sebagai 0. Namun, jika hasilnya ≥ 0 , nilainya akan diatur sebagai 1 (Putri et al., 2019).

2.8 Handling Imbalanced data

Imbalanced data terjadi ketika rasio kelas dalam dataset tidak seimbang. Salah satu cara mengatasi masalah ini adalah menggunakan algoritma *oversampling*, di mana ukuran kelas minor ditingkatkan agar sebanding dengan kelas mayor. SMOTE (*Synthetic Minority Oversampling Technique*) adalah salah satu teknik *oversampling* yang umum digunakan. Melalui SMOTE, sampel-sampel sintetis diciptakan untuk kelas minoritas, menghasilkan dataset yang lebih seimbang (Dwi Astuti & Nova Lenti, 2021).

2.9 Chi-square

Chi-square mengukur sejauh mana setiap variabel independen berkaitan dengan kelas target. Untuk melakukan perhitungan menggunakan uji *Chi-square*, dapat menggunakan persamaan (12) (Sung et al., 2021).

$$Chi = \sum_{i=1}^k \frac{(O_i - E_i)^2}{E_i} \quad (12)$$

Dimana O_i adalah nilai yang diamati untuk kelas atau kategori tertentu, E_i adalah nilai yang diharapkan untuk kelas atau kategori tertentu, dan k adalah jumlah kelas atau kategori yang terlibat dalam uji *Chi-square*.

2.10 Support Vector Machine (SVM)

SVM adalah algoritma digunakan untuk klasifikasi dan regresi. SVM memiliki ketahanan terhadap data yang ekstrem (Ghimire et al., 2017). SVM digunakan untuk memisahkan data dengan hyperplane pada data *linear* atau *non-linear* melalui pendekatan *kernel*. *Kernel* berfungsi untuk memetakan data non-linear ke dalam ruang fitur berdimensi lebih tinggi (Cuentas et al., 2017). Salah satu kernel yang umum digunakan adalah *kernel linear*. *Kernel linear* adalah jenis kernel yang sederhana dan sangat bergantung pada parameter penalti C . Penyesuaian nilai C untuk mencapai keseimbangan optimal antara kesalahan dan kompleksitas aturan keputusan SVM (R. Sangeetha, 2011). Persamaan untuk menghitung *kernel* yang populer untuk digunakan dalam pengenalan emosi wajah (Dwi Ratna et al., 2016):

a. *Linear*

$$K(x_i, x_j) = x_i^T \times x_j \quad (13)$$

b. *Polynomial*

$$K(x_i, x_j) = ((x_i^T \times x_j + 1))^n \quad (14)$$

c. *Radical Basic Funtion (RBF)*

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right) \quad (15)$$

Dimana K adalah fungsi *kernel*, x_i adalah data input, x_i^T adalah transposisi data input, dan σ adalah parameter bebas.

2.11 *Confusion matrix*

Confusion matrix adalah salah satu alat yang penting digunakan untuk mengukur kinerja model klasifikasi. *Matrix* yang digunakan adalah akurasi, presisi, *recall*, dan skor F1. Penjelasan mengenai *matrix-matrix* tersebut dijelaskan sebagai berikut (Lek & Teo, 2023).

a. Akurasi adalah sejauh mana model klasifikasi dapat memprediksi dengan benar.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (16)$$

b. *Precision* mengukur kemampuan model dalam menghindari memberikan prediksi positif yang salah.

$$Precision = \frac{TP}{TP + FP} \quad (17)$$

c. *Recall* mengukur kemampuan model untuk mengidentifikasi semua kasus yang sebenarnya positif.

$$Recall = \frac{TP}{TP + FN} \quad (18)$$

d. *F1-Score* adalah ukuran kinerja yang menggabungkan *precision* dan *recall*. F1 membantu memahami sejauh mana model mampu menghindari kesalahan positif dan negatif.

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (19)$$

BAB 3. METODOLOGI PENELITIAN

Metodologi penelitian adalah serangkaian langkah atau tahapan sistematis yang dilakukan untuk menjawab rumusan masalah guna mencapai tujuan penelitian. Bagian ini menjelaskan mengenai jenis penelitian, objek penelitian, tempat dan waktu penelitian, serta tahap penelitian yang digunakan akan diuraikan sebagai berikut.

3.1 Jenis Penelitian

Jenis penelitian yang dilakukan pada penelitian ini adalah penelitian kuantitatif karena menggunakan operasi numerik dalam proses pengolahan datanya, yaitu menggunakan perhitungan fitur HOG, LBP, dan fitur geometri dengan *modelling classification SVM*.

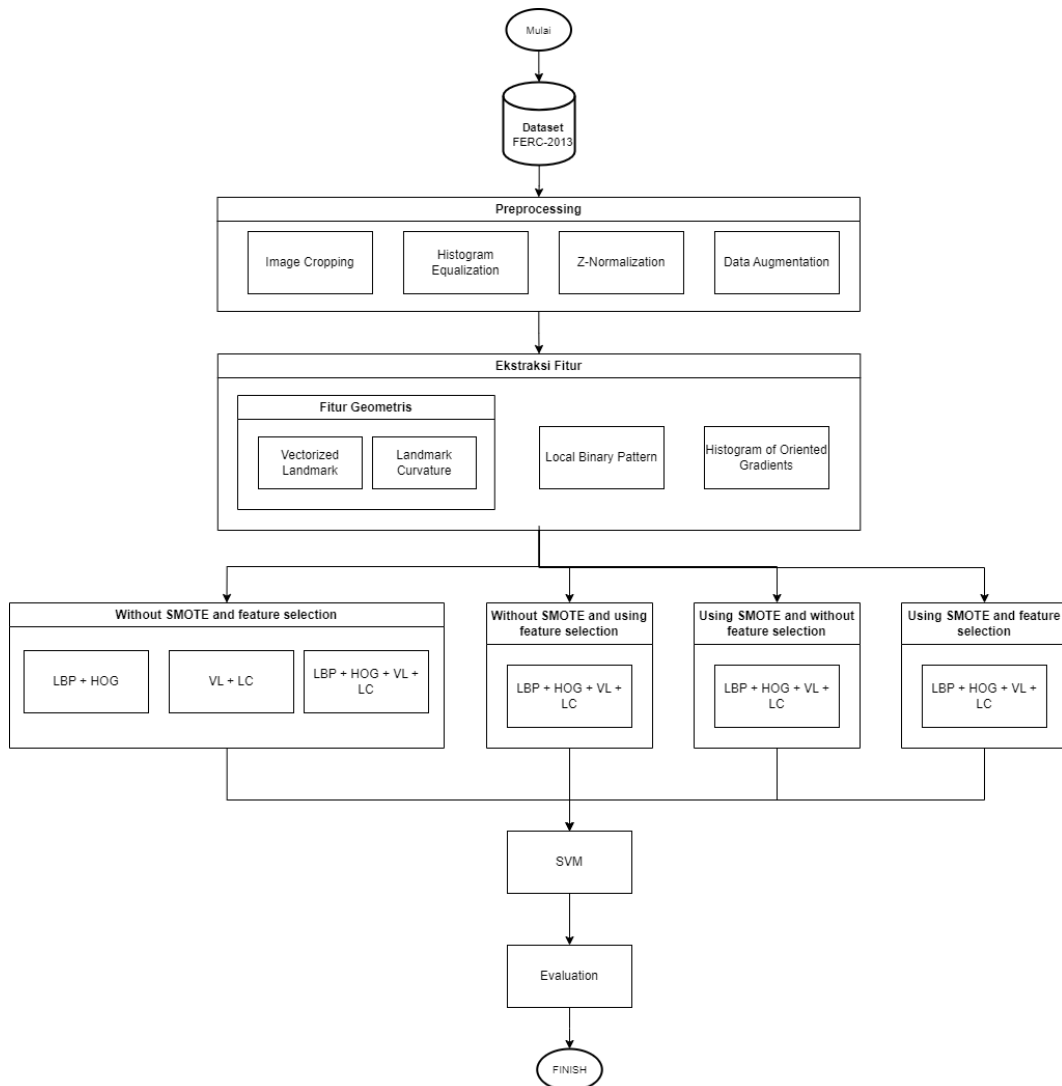
3.2 Sumber Data

Dataset yang digunakan pada penelitian ini yaitu dataset FER-2013. Dataset ini dapat diunduh dari website kaggle. Database ini berisi 35.887 gambar dengan jumlah data training 28.709 citra dan data testing 7178 citra. Data wajah dalam format *grayscale* dengan ukuran 48 x 48 piksel. Gambar-gambar tersebut disimpan dalam format CSV dan setiap barisnya berisi indeks emosi yang sesuai, dimana 0 menunjukkan *angry*, 1 untuk *disgust*, 2 untuk *fear*, 3 untuk *happy*, 4 untuk *sad*, 5 untuk *surprise*, dan 6 untuk *neutral* (Dalvi et al., 2021).

3.3 Tempat dan Waktu Penelitian

Penelitian akan dilaksanakan di Fakultas Ilmu Komputer Universitas Jember dengan waktu penelitian dimulai dari bulan Juli 2023.

3.4 Tahapan Penelitian



Gambar 3.1 Tahapan Penelitian

3.4.1 Preprocessing

Preprocessing adalah serangkaian langkah atau teknik pengolahan awal yang diterapkan pada citra untuk meningkatkan kualitas citra sebelum dilakukan analisis atau ekstraksi fitur lebih lanjut. Tahapan *preprocessing* yang dilakukan pada penelitian ini sebagai berikut:

3.4.2 Image Cropping

Image cropping dalam pemrosesan dataset FER-2013 penting karena dataset tersebut memiliki latar belakang dan elemen-elemen yang tidak dibutuhkan dalam tahap klasifikasi. *Image cropping* mengacu pada 68 *landmark* wajah yang terdeteksi menggunakan *library dlib*. Teknik pemotongan ini menggunakan metode slicing, dimana bagian atas gambar, yaitu area dahi, dipotong dengan jarak 0,6d tegak lurus terhadap garis horizontal yang menghubungkan pusat mata. Selain itu, tiga sisi lain dari gambar yang dipotong juga disesuaikan dengan koordinat dari titik *landmark* wajah tertentu, seperti titik ke-1, ke-9, dan ke-17.

3.4.3 Histogram equalization

Histogram equalization akan melakukan distribusi intensitas piksel dalam setiap gambar. Pada tahap ini, dilakukan proses transformasi dengan mengatur ulang nilai-nilai tingkat kecerahan secara merata di rentang 0-255. Hal ini berarti bahwa piksel-piksel dengan tingkat kecerahan yang semula rendah akan mengalami peningkatan nilai, sementara piksel-piksel dengan tingkat kecerahan yang semula tinggi akan mengalami penurunan nilai.

3.4.4 Z-Normalization

Pada tahapan ini, gambar yang telah melalui proses *histogram equalization* diubah distribusi datanya sehingga memiliki nilai rata-rata mendekati 0 dan nilai standar deviasi mendekati 1. Setelah melalui proses *z-normalization*, gambar yang dihasilkan memiliki kontras yang tinggi.

3.4.5 Data Augmentasi

Pada tahapan ini, data augmentasi digunakan untuk menghasilkan variasi tambahan dari dataset pelatihan dengan menciptakan citra yang mirip namun memiliki variasi dalam hal rotasi, ukuran, orientasi, atau lainnya. Pada penelitian ini, setiap gambar akan menggunakan tujuh filter berbeda. Penerapan filter ini dilakukan secara acak pada gambar, dengan setiap gambar hanya mengalami satu kali penerapan filter.

3.5 Ekstraksi Fitur

Pada penelitian ini, ekstraksi fitur mencakup fitur geometri, *Histogram of Oriented Gradients*, dan *Local Binary Pattern*. Berikut penerapan dari ekstraksi fitur dalam penelitian ini:

3.5.1 Fitur Geometri

Setelah data augmentasi, jumlah citra meningkat dan variasi citra lebih beragam. Proses ekstraksi fitur geometri membutuhkan informasi *landmark*, sehingga deteksi wajah dan *landmark* harus dilakukan ulang pada data hasil *preprocessing* dan augmentasi. Sedangkan, HOG dan LBP tidak memerlukan informasi *landmark*, sehingga semua citra wajah dapat diekstraksi fiturnya tanpa ketergantungan pada *landmark*. Untuk memastikan kesetaraan jumlah data citra pada semua tahapan ekstraksi fitur, tahap geometri dilakukan terlebih dahulu.

a. *Vectorized Landmark*

Vectorized Landmark digunakan untuk menggambarkan titik-titik *landmark* dalam bentuk vektor yang mewakili struktur atau fitur tertentu dalam analisis citra, seperti mata, hidung, mulut, dan lainnya. Setiap titik *landmark* dinyatakan sebagai pasangan koordinat (x, y) yang menandakan posisinya dalam citra. Jumlah *landmark* pada tiap wajah adalah 68 *landmark*. Tiap *landmark* akan dilakukan proses perhitungan *Vectorized Landmark* sesuai dengan persamaan (6) dan (7) yang telah dijelaskan pada tinjauan pustaka sebelumnya yang melibatkan perhitungan *euclidean distance* dan *angle*.

b. *Landmark Curvature*

Landmark Curvature menggambarkan struktur wajah dengan menemukan *curvature* segmen wajah berdasarkan *landmark*. Perubahan *curvature* dapat mengindikasikan perubahan ekspresi emosi, sehingga berguna untuk menganalisis ekspresi wajah dan emosi. Berdasarkan *facial segment* yang telah dikategorikan sesuai Lampiran 2.1, *Landmark Curvature* akan dihitung sesuai dengan persamaan (4) untuk mendapatkan persamaan tiap *facial segment*. Nilai parameter *degree* (M) mengacu pada penelitian terdahulu yakni bernilai 3 (Liu et al., 2021). Selanjutnya

persamaan tersebut akan dicari turunan pertama dan keduanya sesuai dengan perhitungan yang dilakukan pada persamaan (5), dimana koordinat tiap *landmark* ini akan dimasukkan ke dalam perhitungan tersebut sesuai dengan *facial segment* untuk mendapatkan *local curvature* tiap *landmark*.

3.5.2 *Histogram of Oriented Gradients (HOG)*

HOG menghasilkan vektor fitur yang mencerminkan arah perubahan warna dan intensitas dalam citra. Nilai parameter pada penelitian ini merujuk pada penelitian terdahulu yaitu orientasi (*orientations* = 36), ukuran sel (*pixels_per_cell* = (8x8)), dan blok (*cells_per_block* = (1, 1)) digunakan untuk mengatur detail fitur yang diambil (Lakshmi & Ponnusamy, 2021). Output yang dihasilkan dalam ekstraksi fitur ini adalah histogram yang disimpan dalam bentuk *Dataframe*.

3.5.3 *Local Binary Pattern (LBP)*

LBP menggunakan fungsi *local_binary_pattern* dari *library skimage.feature*, dengan parameter-parameter seperti *radius* ($r=1$) dan *n_points* ($n=8$) yang merujuk pada penelitian terdahulu (Yaddaden, 2023). Radius mengontrol ukuran wilayah di sekitar setiap piksel, sedangkan *n_points* menentukan seberapa banyak titik yang digunakan untuk mengukur orientasi dalam setiap wilayah tersebut. *Method* yang digunakan adalah "default". Hasil dari tahap LBP ini berupa histogram yang disimpan dalam bentuk *Dataframe*.

3.6 *Handling Imbalanced data*

Handling Imbalanced data dilakukan untuk menyeimbangkan jumlah sampel antar kelas dalam dataset klasifikasi. Pada dataset FER-2013, terdapat 7 kelas dalam dataset yang memiliki ketidakseimbangan jumlah data. Oleh karena itu, dilakukan *Handling Imbalanced data* dengan algoritma *oversampling* yaitu SMOTE.

3.7 **Seleksi Fitur**

Tujuan dari pemilihan fitur adalah untuk memilih sejumlah fitur yang memiliki pengaruh signifikan dari sejumlah besar fitur yang tersedia (Budi et al., 2016).

Seleksi fitur menggunakan uji *Chi-square* dilakukan pada tiga skenario, yaitu skenario menggunakan fitur geometri saja, gabungan fitur HOG dan LBP, serta gabungan fitur geometri, HOG, dan LBP.

3.8 Modelling Experiments

Penelitian ini mengimplementasikan eksperimen pemodelan dengan memanfaatkan algoritma *Support Vector Machine* (SVM) dengan hyperparameter tuning yaitu *cost* dan *kernel*. Nilai *cost* telah ditentukan pada rentang $[10^{-2}, 10^{-1}, 10^0, 10^1, 10^2, 10^{2.5}, 10^3, 10^{3.5}, 10^4]$, sementara *kernel* memiliki pilihan *linear*, *RBF*, dan *poly*. Kombinasi parameter ini akan dicari yang terbaik dengan menggunakan metode grid search. Penelitian ini dibedakan menjadi 4 kategori, yaitu *without smote and feature selection*, *without smote and using feature selection*, *using smote and without feature selection*, and *using smote and feature selection*. Pada kategori *without smote and feature selection* dilakukan skenario pada ketiga jenis data fitur yaitu fitur geometri saja, fitur tekstur saja, dan gabungan keduanya. Sementara pada kategori lainnya akan diimplementasikan pada gabungan data fitur tekstur dan geometri. Untuk skenario dengan detail jenis data fitur dan *kernel* dapat dilihat pada Lampiran 3.1.

3.9 Evaluasi

Evaluasi kinerja model klasifikasi dalam penelitian ini dilakukan dengan menggunakan *confusion matrix*, yang berguna untuk mengukur sejauh mana model mampu mengklasifikasikan data dengan benar. Dalam *confusion matrix* ini akan didapatkan nilai *accuracy*, *f1-Score*, *recall*, dan *precision*.

BAB 4. HASIL DAN PEMBAHASAN

Pada bab ini, dibahas mengenai hasil yang diperoleh dari langkah-langkah penelitian yang telah dijalani. Berikut pembahasan hasil setiap tahapan.

4.1 *Dataset Acquisition*

Dataset yang digunakan dalam penelitian ini adalah dataset FER-2013. Setiap gambar disimpan dalam format CSV sehingga untuk dilakukan tahap *preprocessing* perlu dikonversi ke format image terlebih dahulu. Dataset FER-2013 ini terdiri dari dua atribut. Berikut penjelasan dari tiap atribut.

a. *Pixels*

Atribut *pixels* memuat data nilai piksel per barisnya dalam format *grayscale* yang mencerminkan tingkat kecerahan pada masing-masing citra wajah. Nilai-nilai ini merepresentasikan intensitas kecerahan pada setiap piksel gambar wajah.

b. *Emotion*

Atribut "*emotion*" pada dataset FER-2013 merupakan label emosi yang terkait dengan setiap gambar wajah. Setiap nilai dalam kolom "*emotion*" adalah angka yang merepresentasikan kategori emosi tertentu. Angka-angka ini mengindikasikan jenis emosi pada wajah citra, seperti *angry* (0), *disgust* (1), *fear* (2), *happy* (3), *sad* (4), *surprise* (5), dan *neutral* (6).


Dataset ini terdapat 35.887 gambar dengan data training sejumlah 28.709 dan data testing sejumlah 7.178 citra. Jumlah ini merupakan jumlah awal sebelum dilakukan deteksi wajah dan *landmark* menggunakan library Dlib. Jumlah ini akan berkurang saat dilakukan deteksi wajah dan *landmark* karena tidak semua gambar bisa dideteksi oleh library Dlib yang disebabkan karena terdapat bagian wajah yang tertutup atau *non frontal view*.

4.2 *Preprocessing*

Tahap ini penting dilakukan untuk meningkatkan kualitas citra wajah dan memperbanyak jumlah data menggunakan data augmentasi. Tahap ini juga dilakukan karena dapat meningkatkan performa model dan membantu dalam proses ekstraksi fitur dengan menghasilkan fitur yang lebih optimal.

4.2.1 Deteksi wajah dan *landmark*

Dlib memulai proses deteksi dengan menerapkan algoritma *Histogram of Oriented Gradients* (HOG), yang mengekstraksi fitur-fitur kunci dari gambar dengan fokus pada distribusi orientasi gradien di blok-blok kecil. Setelah ekstraksi fitur, dlib menggunakan classifier yang dilatih dengan dataset gambar berlabel untuk membedakan bagian wajah dari bagian lainnya. Setelah deteksi wajah berhasil, dlib menentukan posisi titik-titik penting pada wajah, seperti mata, hidung, dan mulut, dengan menggunakan model regresi linear. Proses ini mencakup konversi gambar ke skala keabuan, deteksi wajah, dan prediksi *landmark* wajah, dengan hasil *landmark* disimpan dalam daftar *shapes_list*. Dalam konteks deteksi wajah, umumnya terdapat 68 titik *landmark*. Wajah yang berhasil dideteksi dapat dilihat pada Gambar 4.1.



Gambar 4.1 Citra dengan *landmark* yang berhasil terdeteksi

Dari total 28.709 data pelatihan, hanya 19.778 citra yang berhasil terdeteksi, sedangkan sisanya tidak dapat terdeteksi karena wajah yang tidak menghadap ke depan dan beberapa area wajah yang tertutup oleh objek lain. Beberapa contoh gambar yang tidak dapat dideteksi dapat dilihat pada Gambar 4.2.



Gambar 4.2 Citra dengan *landmark* yang tidak berhasil terdeteksi

4.2.2 *Image Cropping*

Proses image cropping dilakukan dengan menghilangkan *background* dan bagian wajah yang tidak diperlukan sehingga dapat meningkatkan fokus pada fitur-fitur wajah yang relevan. Tahap awal melibatkan pembuatan fungsi "*eyes_detection*" yang bertugas menghitung koordinat pusat mata kiri dan kanan berdasarkan *landmark* wajah dari "*shapes_list*" yang sebelumnya telah diperoleh melalui fungsi *face_detection*. Langkah ini melibatkan perhitungan rata-rata koordinat x dan y dari *landmark* mata kiri (indeks 36-41) dan mata kanan (indeks 42-47).



Gambar 4.3 Gambar sebelum dan sesudah *image cropping*

Gambar 4.3 diatas menunjukkan citra sebelum dan sesudah dilakukan pemotongan gambar. Proses pemotongan ini melibatkan penentuan batas berdasarkan *landmark* tertentu, seperti titik ke-1 (telinga kiri), ke-9 (ujung dagu), dan ke-17 (telinga kanan), yang digunakan sebagai acuan dalam proses pemotongan. Selanjutnya, bagian atas citra dipotong dengan jarak 0,6d tegak lurus terhadap garis horizontal yang menghubungkan pusat mata.

4.2.3 *Histogram equalization*

Dataset FER-2013 memiliki tingkat kecerahan dan kontras yang beragam, sehingga dilakukan *histogram equalization* dilakukan setelah *image cropping* untuk menyamaratakan kontras. Pertama, gambar diubah menjadi skala abu-abu menggunakan *cv2.cvtColor* dengan mode konversi *cv2.COLOR_BGR2GRAY*. Selanjutnya, pemerataan histogram dilakukan dengan menggunakan fungsi *cv2.equalizeHist* pada gambar skala abu-abu tersebut. Proses ini bertujuan untuk meningkatkan kontras dan distribusi intensitas piksel dalam gambar, sehingga detail yang kurang terlihat dapat lebih mudah terlihat. Hasil pemerataan histogram

kemudian dikembalikan sebagai gambar yang sudah diperbarui. Hasil proses *histogram equalization* dapat dilihat pada gambar 4.4 berikut.



Gambar 4.4 Gambar sebelum dan sesudah *histogram equalization*

4.2.4 Z-Normalization


Hasil gambar yang telah dilakukan *histogram equalization* akan dilanjutkan ke tahap *z-normalization*. Tahap ini berguna untuk meningkatkan kontras pada gambar yang telah disamaratakan kecerahan dan kontrasnya melalui *histogram equalization*. Tahap awal dilakukan dengan menghitung nilai rata-rata (mean) dan deviasi standar (std_dev) dari intensitas piksel pada gambar. Selanjutnya, dilakukan normalisasi *Z-score* pada gambar dengan mengurangi nilai rata-rata dan membagi dengan deviasi standar. Langkah ini bertujuan untuk menghasilkan distribusi intensitas piksel yang memiliki nilai tengah nol dan standar deviasi satu. Setelah itu, dilakukan normalisasi range ke rentang 0-255 menggunakan fungsi `np.clip`. Terakhir, hasil normalisasi tersebut dikonversi kembali ke tipe data `uint8` agar sesuai dengan representasi piksel pada gambar. Fungsi ini memberikan gambar yang telah dinormalisasi sesuai dengan skala dan range yang diinginkan. Hasil proses *z-normalization* dapat dilihat pada gambar 4.5 berikut.



Gambar 4.5 Gambar sebelum dan sesudah *z-normalization*

4.2.5 Data Augmentation

Pada tahap data augmentation, gambar yang telah diproses pada tahap z-normalization akan dilanjutkan ke tahap data augmentation dengan memperbanyak variasi gambar sesuai dengan filter-filter yang telah ditentukan. Filter tersebut berjumlah 7 filter yang masing-masing gambar akan diterapkan satu filter secara acak, sehingga akan dihasilkan gambar dengan jumlah akhir 2 kali lipat dari sebelumnya. Filter yang digunakan yaitu *adjusting gamma value*, *enhancing contrast*, *color inversion*, *adding random noise*, *zooming*, *rotation*, dan *flipping* sebagai data augmentasi. *Adjusting gamma* menggunakan parameter gamma (0.7 hingga 1.3) untuk mengatur kecerahan. *Enhancing contrast* memanfaatkan *alpha* (0.8 hingga 1.2) dan *beta* (-20 hingga 20) untuk mengontrol kontras dan kecerahan. *Adding random noise* menggunakan *gaussian noise* dengan standar deviasi 20. *Zoom* dan *rotate* memakai *zoom scale* dan *angle* yang dipilih secara acak. *Flip* melakukan horizontal flip tanpa parameter tambahan. Dengan nilai-nilai ini, filter memberikan variasi penting dalam dataset gambar untuk melatih model secara *robust*. Hasil proses *data augmentation* dapat dilihat pada gambar 4.6 berikut.



Gambar 4.6 Gambar penerapan data augmentation

4.3 Ekstraksi Fitur

Tahap ekstraksi fitur dilakukan untuk menghasilkan fitur geometri dan fitur tekstur. Fitur geometri dihasilkan dari *Vectorized Landmark* dan *Landmark Curvature*. Fitur tekstur dihasilkan dari LBP dan HOG.

4.3.1 *Vectorized Landmark* (VL)

Pada tahap ini, dilakukan ekstraksi fitur berdasarkan *landmark* yang telah dideteksi oleh library Dlib. *Vectorized Landmarks* pada suatu gambar merupakan representasi titik-titik khusus pada wajah, yang diekstraksi sebagai fitur-fitur numerik dengan menggunakan pendekatan vektorisasi. Proses ini dimulai dengan

mendeteksi wajah dalam gambar dan mengidentifikasi *landmark* wajah menggunakan fungsi *face_detection*. Setiap *landmark* wajah direpresentasikan sebagai sebuah titik (x, y) dalam citra. Setelah mendapatkan *landmarks* untuk setiap wajah, dilakukan perhitungan menggunakan dengan mengukur jarak euclidean antara setiap *landmark* dengan *geometric center* dari *landmarks* tersebut. *Geometric Center* didapatkan dari perhitungan rata-rata koordinat x dan y dari seluruh *landmark*. Selanjutnya menghitung *angle* antara setiap *landmark* dengan pusat geometris, diukur dalam derajat. Hasil pengukuran jarak Euclidean dan *angle* untuk setiap *landmark* pada satu wajah kemudian disimpan dalam list.

Citra akan melalui tahapan deteksi wajah dan *landmark* kembali untuk bisa melakukan perhitungan VL. Dari data citra gabungan data augmentation dan z-normalization yang berjumlah 34192 data, sebanyak 13383 citra berhasil dideteksi wajah dan *landmark*nya. Jumlah ini berkurang karena terdapat variasi gambar hasil dari data augmentasi yang menyebabkan gambar tidak bisa dideteksi wajah atau *landmark*nya. Jumlah citra yang bisa dideteksi pada VL ini juga akan digunakan sebagai inputan data pada metode ekstraksi lainnya. Jumlah fitur data VL per kelasnya dapat dilihat pada Tabel 4.1.

Tabel 4.1 Jumlah Fitur Data *Vectorized Landmark* per kelas

No	Class	Jumlah Data
1	Happy	3973
2	Neutral	2886
3	Angry	1711
4	Surprise	1631
5	Fear	1488
6	Sad	1457
7	Disgust	237
Total		13383

Perhitungan VL juga menghasilkan **136 fitur** karena berdasarkan banyaknya *landmark* yang dideteksi pada suatu wajah sejumlah 68 *landmark* akan menghasilkan *euclidean distance* dan *angle* per *landmark*nya. Hasil dari perhitungan fitur geometris VL untuk setiap citra akan dipresentasikan dalam bentuk *Dataframe*, sesuai dengan format yang terdapat pada Tabel 4.2.

Tabel 4.2 Fitur *Vectorized Landmark*

No	Euclidean Distance1	Angle1	Euclidean Distance2	Angle2	...	Euclidean Distance68	Angle68	Emosi
0	23.106213	23.399695	20.632998	11.678337	...	10.333412	-71.926046	angry
1	23.291170	30.759019	21.830411	15.712121	...	12.737476	-71.627807	angry
...
13381	25.594425	28.258392	22.143607	13.362532	...	14.113549	-79.615057	surprise
13382	26.305079	23.770604	23.528171	11.281839	...	15.434438	-86.011620	surprise

4.3.2 *Landmark Curvature (LC)*

Pada tahap ini, dilakukan deteksi *landmark* seperti yang dilakukan pada ekstraksi fitur VL. Koordinat *landmark* yang diperoleh akan digunakan sebagai acuan untuk ekstraksi fitur. Terdapat 68 *landmark* pada suatu wajah sehingga akan didapatkan **68 fitur**. Berdasarkan penelitian yang dilakukan oleh (Liu et al., 2021) 68 *landmark* akan dibagi ke dalam 16 *facial segment* yang membentuk komponen wajah seperti alis sebelah kanan, alis sebelah kiri, mata kanan, mata kiri, dan komponen lainnya sesuai dengan lampiran 2.1. Selanjutnya, dilakukan pencarian persamaan kurva untuk setiap *facial segment*, dan setelah persamaan kurva berhasil ditemukan, koordinat absis dari setiap *landmark* akan dimasukkan. Tujuannya adalah untuk mengidentifikasi sejauh mana terjadi perubahan dalam kelengkungan dan menginterpretasikan ekspresi emosi tertentu. Dengan demikian, proses ini memungkinkan pemahaman yang lebih mendalam terhadap ekspresi wajah melalui analisis perubahan bentuk yang terjadi pada masing-masing komponen wajah. Hasil dari perhitungan fitur geometris LC untuk setiap citra akan dipresentasikan dalam bentuk *Dataframe*, sesuai dengan format yang terdapat pada Tabel 4.3.

Tabel 4.3 Fitur *Landmark Curvature*

No	Curvature_1	Curvature_2	Curvature_3	...	Curvature_67	Curvature_68	Emosi
0	0.000026	0.000037	0.000046	...	3.871206e-09	1.585802e-09	angry
1	0.000082	0.000111	0.000161	...	6.375995e-08	2.403001e-08	angry
...
13381	0.000072	0.000098	0.000163	...	1.561543e-08	9.167232e-09	surprise
13382	0.000035	0.000048	0.000084	...	3.496808e-09	2.050416e-09	surprise

4.3.3 Local Binary Pattern (LBP)

Pada tahap ini, proses ekstraksi fitur LBP dilakukan dengan menggunakan fungsi *local_binary_pattern()* dari *library skimage*. Terdapat beberapa parameter yang digunakan yaitu *radius = 1*, *n_points = 8*, dan *method = "default"* dimana nilai parameter ini ditentukan berdasarkan penelitian yang dilakukan oleh (Yaddaden, 2023). Hasil akhir dari ekstraksi fitur LBP yang nantinya akan digunakan yaitu histogram. Dalam histogram, terdapat parameter bins dan range, dimana bins digunakan untuk menentukan jumlah interval untuk mengelompokkan nilai LBP, sementara range untuk menentukan rentang nilai yang diperhitungkan dalam histogram. Jumlah bin (bins) yang digunakan pada penelitian ini adalah 256 dan rentang nilai (range) yang diperhitungkan dalam histogram adalah 0 hingga 255, dimana nilai ini berdasarkan penelitian yang dilakukan oleh (Ghimire et al., 2017). Fitur LBP menghasilkan **256 fitur**. Hasil dari perhitungan fitur tekstur LBP akan dipresentasikan dalam bentuk *Dataframe*, sesuai dengan format yang terdapat pada Tabel 4.4.

Tabel 4.4 Fitur LBP

No	LBP_0	LBP_1	LBP_2	LBP_3	...	LBP_254	LBP_255	Emosi
0	0.245968	0.326923	0.227273	0.675	...	0.256757	0.635081	angry
1	0.209677	0.278846	0.045455	0.275	...	0.202703	0.542339	angry
...
13381	0.225806	0.201923	0.090909	0.150	...	0.245968	0.326923	surprise
13382	0.245968	0.326923	0.245968	0.326923	...	0.209677	0.278846	surprise

4.3.4 Histogram of Oriented Gradients (HOG)

Pada tahap ini, proses ekstraksi fitur HOG dilakukan dengan menggunakan fungsi *hog()* dari *library skimage*. Beberapa parameter yang digunakan dalam fungsi tersebut melibatkan *orientations = 36*, *pixels_per_cell = 8x8*, dan *cells_per_block = 1, 1*. Nilai-nilai parameter ini dipilih berdasarkan penelitian yang dilakukan oleh (Lakshmi & Ponnusamy, 2021). Hasil akhir dari ekstraksi fitur HOG ini berupa histogram. Jumlah bin (bins) yang digunakan pada penelitian ini adalah 18. Rentang nilai (range) yang diperhitungkan dalam histogram dari 0 hingga 180 derajat. Hasil akhir dari perhitungan fitur tekstur HOG ini disajikan dalam bentuk *Dataframe* dengan kolom-kolom yang mewakili nilai-nilai orientasi dari setiap bin

dalam histogram berjumlah **18 fitur**. Hasil dari perhitungan fitur tekstur HOG akan dipresentasikan dalam bentuk *Dataframe*, sesuai dengan format yang terdapat pada Tabel 4.5.

Tabel 4.5 Fitur HOG

No	Bin_0-10	Bin_10-20	Bin_20-30	Bin_30-40	...	Bin_160-170	Bin_170-180	Emosi
0	533.0	796.0	558.0	283.0	...	624.0	864.0	angry
1	597.0	757.0	680.0	352.0	...	451.0	486.0	angry
...
13381	709.0	740.0	610.0	439.0	...	367.0	559.0	surprise
13382	685.0	765.0	651.0	494.0	...	491.0	562.0	surprise

4.3.5 Penggabungan Fitur

Penggabungan fitur tekstur dan fitur geometri dapat memberikan representasi yang lebih komprehensif terhadap informasi yang terkandung dalam gambar. Pada penelitian ini diperoleh hasil ekstraksi fitur pada masing-masing metode yaitu *Histogram of Oriented Gradients* (HOG) menghasilkan **18 fitur**, sementara *Local Binary Pattern* (LBP) terdapat **256 fitur**. Di sisi lain, fitur geometris, seperti fitur *Vectorized Landmark* (VL) menghasilkan **136 fitur** dan *Landmark Curvature* (LC) dengan **68 fitur**. Dengan demikian, total fitur hasil penggabungan keempat metode ekstraksi fitur adalah **478 fitur**.

4.4 Analisis Fitur

Setelah dilakukan ekstraksi fitur khususnya fitur geometri, diperlukan analisis seperti pola yang membentuk karakteristik wajah dengan berbagai ekspresi emosi. Hasil ekstraksi fitur direpresentasikan dalam bentuk tabel pada lampiran 4.1 terkait rata-rata nilai *landmark curvature* untuk setiap *landmark*. *Landmark curvature* adalah ukuran geometris yang menggambarkan sejauh mana suatu garis melengkung pada suatu *landmark*. Rata-rata nilai ini disusun berdasarkan *facial segment*, yang merupakan bagian-bagian tertentu dari wajah yang memiliki karakteristik tertentu. Analisis ini memberikan gambaran tentang seberapa melengkung tiap *landmark* dalam konteks *facial segment*, yang memberi informasi kontribusi setiap bagian wajah terhadap ekspresi emosi. Tabel 4.6 menggambarkan rata-rata nilai LC pada *facial segment 2*. Hasil menunjukkan bahwa pada emosi

neutral dan *surprise*, *landmark* 23 menunjukkan tingkat kelengkungan yang lebih tinggi dibandingkan dengan ekspresi lainnya. Informasi lebih detail mengenai hasil ekstraksi fitur LC dapat dilihat pada lampiran 4.1.


Tabel 4.6 Fitur *Landmark Curvature* pada facial segment 2

Emosi	Facial Segment 2		
	LC23	LC24	LC25
angry	0.003753	0.003441	0.004775
disgust	0.003839	0.003237	0.005181
fear	0.003772	0.003489	0.004551
happy	0.003537	0.003283	0.004099
neutral	0.004017	0.003672	0.004615
sad	0.003752	0.003491	0.004651
surprise	0.004343	0.003981	0.004548

Selain itu, lampiran 4.2 menyajikan rata-rata nilai VL untuk setiap *landmark*. Pada konteks ini, setiap *landmark* direpresentasikan sebagai vektor yang terdiri dari dua nilai, yaitu *euclidean distance* yang mengukur jarak antara *landmark* tersebut dengan pusat geometris, dan *angle* mengukur sudut antara vektor *landmark* dan pusat geometris yang ditarik garis lurus. Hasil ini digunakan sebagai dasar untuk memahami bagaimana karakteristik geometris wajah.

4.5 Handling Imbalanced data

Pada tahap ini, dilakukan penanganan terhadap *Imbalanced data* guna mengurangi bias pada model yang cenderung memprioritaskan kelas mayoritas. Dapat dilihat bahwa pada jumlah awal citra yang dapat dideteksi, terdapat ketidakseimbangan pada kelas-kelasnya. Gambar 4.7 menunjukkan diagram perbedaan jumlah antar kelas dari data, dengan kelas mayoritas memiliki frekuensi yang jauh lebih tinggi dibandingkan dengan kelas minoritas.



Gambar 4.7 Perbandingan visualisasi jumlah gambar setelah dideteksi dan digabung data augmentasi dengan data yang telah dilakukan SMOTE

Penanganan *Imbalanced data* ini akan menggunakan metode SMOTE, yaitu teknik yang bertujuan untuk menciptakan sampel sintetis pada kelas minoritas. Hasil smote diperoleh sejumlah **3973 data** pada tiap kelas. Gambar 4.7 menunjukkan bahwa setelah menerapkan teknik SMOTE, terlihat bahwa distribusi data kini telah menjadi seimbang dengan jumlah data sebanyak **27811 data**.

4.6 Seleksi Fitur

Pada tahap ini, seleksi fitur diterapkan menggunakan algoritma *Chi-square*. Tujuan utama dari proses ini adalah memilih fitur-fitur yang memiliki korelasi yang signifikan dengan kelas target, yaitu kolom "Emosi". Pada tahap ekstraksi fitur telah menghasilkan **478 fitur**. Jumlah yang besar ini perlu diminimalkan melalui seleksi fitur guna meningkatkan efisiensi model. Output dari proses seleksi fitur disimpan dalam sebuah *Dataframe* baru, sementara fitur-fitur yang dianggap tidak signifikan akan dieliminasi. Jumlah akhir fitur yang terpilih sejumlah **10 fitur**, jumlah ini akan diproses lebih lanjut ke dalam model. Hasil dari seleksi fitur *Chi-square* akan dipresentasikan dalam bentuk *Dataframe*, sesuai dengan format yang terdapat pada Lampiran 4.3.

4.7 Classification Experiments

Tahap modelling akan membahas semua eksperimen yang telah dilakukan dalam penelitian ini. Proses modelling ini memanfaatkan algoritma *Support Vector Machine* (SVM), di mana parameter-parameter yang terlibat melibatkan *kernel* dan *cost*. Jenis *kernel* yang diterapkan meliputi rbf, poly, dan linear. Rentang nilai *cost* yang dipertimbangkan melibatkan $[10^{-2}, 10^{-1}, 10^0, 10^1, 10^2, 10^{2.5}, 10^3, 10^{3.5}, 10^4]$. Pemilihan kombinasi optimal dari parameter-parameter ini akan dilakukan melalui metode *grid search*. Sebelum tahap modelling, perlu dilakukan *feature scalling* pada data ekstraksi fitur yang telah diperoleh sebelumnya. Hal ini diperlukan karena terdapat perbedaan signifikan dalam rentang nilai hasil ekstraksi fitur dari berbagai metode. Proses *feature scalling* ini menjadi penting karena SVM bersifat sensitif terhadap perbedaan skala nilai. *Feature scaling* ini menggunakan metode Min-Max guna memastikan bahwa semua fitur memiliki rentang nilai yang seragam, dengan nilai-nilai fitur yang terletak dalam rentang 0 hingga 1. Pembagian

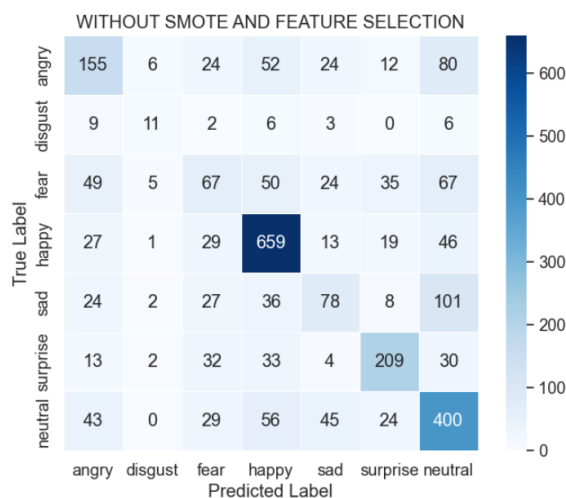
data menjadi *train* dan *test* akan dilakukan dengan menggunakan metode *train-test split*, dengan proporsi ukuran data testing sebesar 0.2 dari keseluruhan data.

4.8 Model Evaluation

Pada tahap ini, dibahas mengenai evaluasi hasil kinerja model klasifikasi. Nilai akurasi dan *f1-Score* pada tahap ini mencakup nilai rata-rata yang diperoleh dari proses *train-test split*. Akurasi adalah untuk mengukur sejauh mana model klasifikasi benar dalam memprediksi seluruh sampel. Pada distribusi kelas tidak seimbang, akurasi kurang akurat dalam memberikan informasi mengenai performa model. Oleh karena itu, dalam kasus ketidakseimbangan kelas, dipilih *f1-Score* karena kemampuannya dalam mencerminkan keseimbangan antara nilai *precision* dan *recall*. *F1-Score* dapat berperan secara positif dalam memastikan bahwa kinerja model tidak terlalu dipengaruhi oleh ketidakseimbangan kelas tersebut.

4.8.1 Without Smote and Feature Selection

Pada skenario ini, dilakukan tanpa menggunakan SMOTE dan feature selection pada tiga jenis data. Data yang akan digunakan dalam skenario ini dibedakan menjadi 3, yaitu HOG dan LBP saja sebagai fitur tekstur, VL dan LC saja sebagai fitur geometri, dan gabungan keempat metode ekstraksi fitur tersebut. Melalui skenario ini, dapat diketahui bagaimana performa model jika tidak melakukan penanganan *Imbalanced data* dan tidak melakukan seleksi fitur.



Gambar 4.8 Hasil *confusion matrix* skenario tanpa menggunakan SMOTE dan seleksi fitur

Gambar 4.8 menunjukkan akurasi pengujian dari model tanpa SMOTE dan seleksi fitur. Model mampu mengklasifikasikan wajah *happy*, *neutral*, dan *surprise* dengan lebih akurat dibandingkan dengan kelas yang lain, sementara citra dengan emosi wajah lainnya memiliki akurasi klasifikasi yang lebih rendah. Terlihat bahwa jumlah yang dapat diklasifikasikan dengan akurat sangat jauh per kelasnya. Perbedaan ini dikarenakan jumlah data pada masing-masing kelas yang tidak seimbang. Hasil akurasi dan *f1-Score* pada tiap scenario yang tidak menggunakan SMOTE dan feature selection dapat dilihat ada Tabel 4.7.

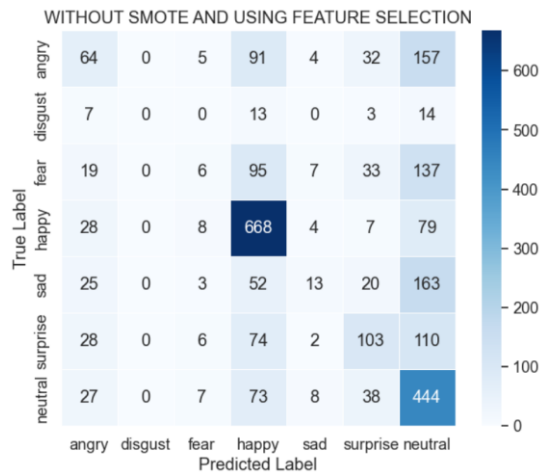
Tabel 4.7 Hasil akurasi dan *F1-Score* skenario tanpa SMOTE dan seleksi fitur

No	Eksperimen		Accuracy	F1-Score
	Fitur	Kernel		
1	HOG + LBP	RBF	0.5864	0.5692
2		Poly	0.5826	0.5541
3		Linear	0.4292	0.3904
4	VL + LC	RBF	0.5062	0.4919
5		Poly	0.5008	0.4890
6		Linear	0.5487	0.5151
7	HOG + LBP + VL + LC	RBF	0.6127	0.6040
8		Poly	0.6061	0.5967
9		Linear	0.5325	0.5143

Tabel 4.7 menunjukkan nilai akurasi dan *f1-Score* hasil eksperimen dengan menggunakan ketiga jenis data fitur tanpa menerapkan SMOTE dan seleksi fitur. Hasil menunjukkan bahwa untuk semua tiga jenis data fitur tersebut, *kernel rbf* mencapai tingkat akurasi dan *f1-Score* yang lebih tinggi dibandingkan dengan *kernel poly* dan *kernel linear*. Selain itu, penggabungan fitur tekstur dan geometri juga menghasilkan peningkatan nilai akurasi dan *f1-Score* jika dibandingkan dengan penggunaan fitur tekstur atau geometri saja.

4.8.2 Without Smote and using Feature Selection

Pada skenario ini, dilakukan tanpa menggunakan SMOTE namun menggunakan seleksi fitur. Data yang akan digunakan dalam skenario ini yaitu data gabungan dari HOG, LBP, VL, dan LC. Melalui skenario ini, dapat diketahui bagaimana performa model jika tidak melakukan penanganan terhadap *Imbalanced data* namun melakukan seleksi fitur.



Gambar 4.9 Hasil *confusion matrix* skenario tanpa menggunakan SMOTE dan menggunakan seleksi fitur

Gambar 4.9 menunjukkan akurasi pengujian model tanpa SMOTE dan menggunakan seleksi fitur. Pada kelas *happy* dan *neutral*, terdapat peningkatan akurasi, namun pada kelas lainnya mengalami penurunan jumlah data yang bisa diklasifikasikan dengan benar dibandingkan dengan skenario pertama yang tidak menggunakan seleksi fitur. Hasil akurasi dan *f1-Score* pada tiap skenario yang tidak menggunakan SMOTE namun menggunakan seleksi fitur dapat dilihat ada Tabel 4.8.

Tabel 4.8 Hasil akurasi dan *F1-Score* skenario tanpa SMOTE dan menggunakan seleksi fitur

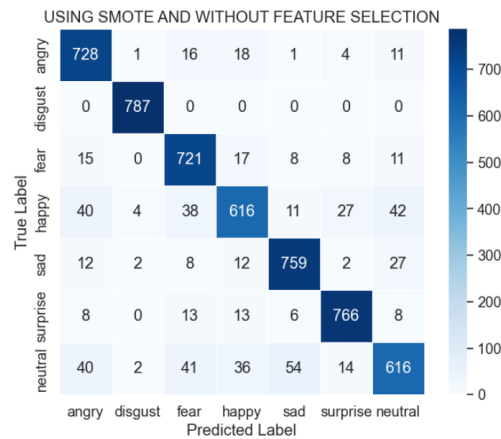
No	Eksperimen		Accuracy	<i>F1-Score</i>
	Feature	Kernel		
1		RBF	0.4849	0.4171
2	HOG + LBP + VL + LC	Poly	0.4714	0.3824
3		Linear	0.4531	0.3610

Tabel 4.10 menunjukkan nilai akurasi dan *f1-Score* tanpa menerapkan SMOTE namun menggunakan seleksi fitur. Hasil menunjukkan bahwa data fitur gabungan tersebut, *kernel rbf* mencapai tingkat akurasi dan *f1-Score* yang lebih tinggi dibandingkan dengan *kernel poly*.

4.8.3 Using Smote and Without Feature Selection

Pada skenario ini, dilakukan dengan menggunakan SMOTE namun tidak menggunakan seleksi fitur. Data yang akan digunakan dalam skenario ini yaitu data

gabungan dari HOG, LBP, VL, dan LC. Melalui skenario ini, dapat diketahui bagaimana performa model jika melakukan penanganan terhadap *Imbalanced data* namun tidak melakukan seleksi fitur.



Gambar 4.10 Hasil *confusion matrix* skenario menggunakan SMOTE namun tanpa seleksi fitur

Gambar 4.10 menunjukkan akurasi pengujian dari model yang menggunakan SMOTE dan tidak menggunakan seleksi fitur. Model mampu mengklasifikasikan wajah dengan lebih akurat pada semua kelas. Terlihat bahwa jumlah data yang dapat diklasifikasikan dengan benar meningkat dan memiliki selisih yang kecil tiap kelasnya dibandingkan dengan skenario yang tidak menggunakan SMOTE. Hasil akurasi dan *f1-Score* pada tiap scenario yang menggunakan SMOTE namun tidak menggunakan seleksi fitur dapat dilihat ada Tabel 4.9.

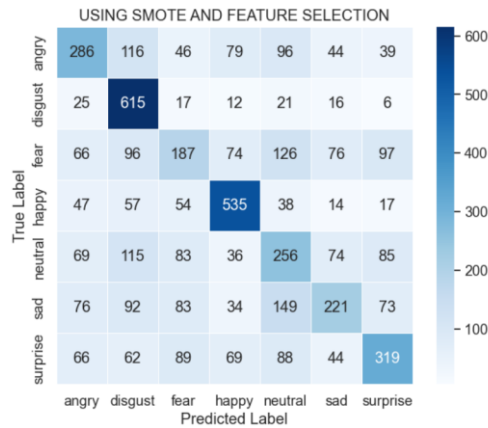
Tabel 4.9 Hasil akurasi dan *F1-Score* skenario menggunakan SMOTE namun tidak menggunakan seleksi fitur

No	Eksperimen		Accuracy	<i>F1-Score</i>
	Feature	Kernel		
1		RBF	0.8975	0.8963
2	HOG + LBP + VL + LC	Poly	0.8920	0.8904
3		Linear	0.7994	0.7986

Tabel 4.9 menunjukkan nilai akurasi dan *f1-Score* dengan menerapkan SMOTE namun tidak menggunakan seleksi fitur. Hasil menunjukkan bahwa pada data fitur gabungan tersebut, *kernel rbf* mencapai tingkat akurasi dan *f1-Score* yang lebih tinggi dibandingkan dengan *kernel poly* dan *kernel linear*.

4.8.4 Using Smote and Feature Selection

Pada skenario ini, dilakukan dengan menggunakan SMOTE dan seleksi fitur. Data yang akan digunakan dalam skenario ini yaitu data gabungan dari HOG, LBP, VL, dan LC. Melalui skenario ini, dapat diketahui bagaimana performa model jika melakukan penanganan terhadap *Imbalanced data* dan melakukan seleksi fitur.



Gambar 4.11 Hasil *confusion matrix* skenario menggunakan SMOTE dan seleksi fitur

Gambar 4.11 menunjukkan akurasi pengujian dari model yang menggunakan SMOTE dan seleksi fitur. Model mampu mengklasifikasikan wajah dengan cukup akurat pada semua kelas. Namun, terdapat penurunan jumlah data yang dapat diklasifikasikan dengan benar dibandingkan dengan skenario yang menggunakan SMOTE namun tidak menggunakan seleksi fitur. Hasil akurasi dan *f1-Score* pada tiap skenario yang menggunakan SMOTE dan seleksi fitur dapat dilihat ada Tabel 4.10.

Tabel 4.10 Hasil akurasi dan *f1-Score* skenario menggunakan SMOTE dan seleksi fitur

No	Eksperimen		Accuracy	<i>F1-Score</i>
	Feature	Kernel		
1		RBF	0.5290	0.5278
2	HOG + LBP + VL + LC	Poly	0.4563	0.4452
3		Linear	0.3534	0.3325

Tabel 4.10 menunjukkan nilai akurasi dan *f1-Score* dengan menerapkan SMOTE dan seleksi fitur. Hasil menunjukkan bahwa pada data fitur gabungan tersebut, *kernel rbf* mencapai tingkat akurasi dan *f1-Score* yang lebih tinggi dibandingkan dengan *kernel poly* dan *kernel linear*.

4.8.5 Analisis Hasil

Berdasarkan hasil tiap skenario yang telah dijelaskan, dilakukan visualisasi perbandingan akurasi pada gabungan fitur geometri dan fitur tekstur. Pada keempat skenario, dimana deskripsi masing-masing skenario dijelaskan pada Tabel 4.11.

Tabel 4.11 Skenario yang dilakukan dan deskripsinya


Skenario	Deskripsi
Skenario 1	Without smote and feature selection
Skenario 2	Without smote and using feature selection
Skenario 3	Using smote and without feature selection
Skenario 4	Using smote and feature selection

Gambar 4.12 memperlihatkan grafik perbandingan kinerja 4 skenario dalam penelitian. Pada skenario pertama, diperoleh akurasi sebesar 0.6127 dimana angka ini berarti model masih belum cukup baik dalam mengklasifikasikan data. Pada skenario kedua yang melibatkan seleksi fitur menghasilkan penurunan akurasi menjadi 0.4849. Hal ini menunjukkan bahwa penggunaan seleksi fitur menggunakan *Chi-square* tidak efektif dalam meningkatkan kinerja model. Pada skenario ketiga, dengan penerapan SMOTE tanpa seleksi fitur terjadi peningkatan akurasi menjadi 0.8975. Hasil ini menunjukkan bahwa penggunaan SMOTE sebagai strategi untuk menangani ketidakseimbangan data meningkatkan kinerja model. Pada skenario keempat yang melibatkan penggunaan SMOTE dengan seleksi fitur, didapatkan hasil akurasi menjadi 0.5290. Hasil ini menunjukkan bahwa penerapan SMOTE bersama dengan seleksi fitur tidak dapat meningkatkan performa model. Grafik perbandingan akurasi pada keempat skenario dapat dilihat pada Gambar 4.12.



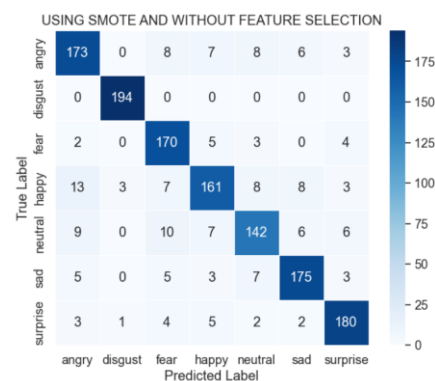
Gambar 4.12 Hasil akurasi

Analisis perbandingan *f1-Score* per kelas juga dilakukan untuk menggambarkan perbedaan antara dua skenario, yakni dengan penerapan SMOTE dan tanpa SMOTE. Hasilnya menunjukkan bahwa skenario tanpa SMOTE berkinerja cukup baik hanya pada kelas *happy*, *neutral*, dan *surprise*, sementara kelas lain tergolong cukup rendah. Di sisi lain, penerapan SMOTE menghasilkan tingkat kinerja yang konsisten dan unggul di setiap kelas. Grafik perbandingan *f1-Score* dapat dilihat pada Gambar 4.12.



Gambar 4.13 Diagram perbandingan nilai *f1-Score* per kelas dengan dan tanpa SMOTE

Untuk mengevaluasi kemungkinan *overfitting* dilakukan pengujian pada model menggunakan dataset testing dari FER-2013 yang berjumlah 7178 data. Setelah dideteksi wajah dan landmarknya maka jumlah data menjadi 3385 data dikarenakan terdapat wajah yang tidak dapat terdeteksi. Data tersebut kemudian diujikan pada skenario dengan performa terbaik yaitu skenario yang menggunakan SMOTE dan tanpa seleksi fitur. Hasil akhir menunjukkan akurasi sebesar 88%, dengan *f1-Score* mencapai 87%. Skor ini menunjukkan bahwa model tidak mengalami *overfitting* karena berhasil menjaga kinerjanya saat dihadapkan pada data yang belum pernah dilihat sebelumnya. Hasil *confusion matrix* dari pengujian ini dapat dilihat pada Gambar 4.14.



Gambar 4.14 Hasil *confusion matrix* pada dataset testing

BAB 5. KESIMPULAN DAN SARAN

5.1 Kesimpulan

Hasil penelitian menunjukkan bahwa gabungan data fitur tekstur dan geometri tanpa penerapan SMOTE dan seleksi fitur menghasilkan akurasi sebesar 61% dibandingkan dengan fitur tekstur atau geometri saja yang masing-masing menghasilkan akurasi sebesar 58% dan 51%. Meskipun demikian, akurasi yang dicapai dalam penelitian ini masih kurang optimal, terutama jika dibandingkan dengan penelitian sebelumnya yang menggunakan CNN dan dataset serupa, mencapai akurasi 78.52%. Skenario terbaik dalam penelitian ini ditemukan pada penggunaan fitur gabungan dengan penerapan SMOTE tanpa seleksi fitur, yang menghasilkan akurasi sebesar 90% dengan *kernel rbf*. Namun, penggunaan metode seleksi fitur *Chi-square* mengurangi performa model karena akurasi mengalami penurunan menjadi 48%. Selain itu, hasil penelitian juga menunjukkan ekstraksi fitur geometri dan tekstur efektif hanya pada emosi *happy*, *neutral*, dan *surprise* saja.

5.2 Saran

Saran untuk penelitian ini mencakup beberapa aspek yang perlu dipertimbangkan. Berikut beberapa saran yang dapat diberikan:

1. Dapat menggunakan tambahan algoritma deteksi wajah selain algoritma dlib karena dlib memiliki keterbatasan dalam mendeteksi wajah pada citra yang sebagian wajahnya tertutup atau menghadap ke samping sehingga jumlah citra wajah mengalami banyak pengurangan data.
2. Penelitian sebaiknya mempertimbangkan penggunaan metode ekstraksi fitur lainnya. Eksplorasi metode ekstraksi fitur tambahan dapat meningkatkan keakuratan dan ketepatan analisis, terutama untuk memperoleh informasi tambahan tentang fitur wajah. Hal ini diharapkan bisa memberikan keakuratan pengenalan emosi wajah pada semua kelas.
3. Dapat mempertimbangkan eksplorasi algoritma seleksi fitur lainnya yang dapat lebih mendukung peningkatan performa model.

DAFTAR PUSTAKA

- Beli, I. L. K., & Guo, C. (2017). Enhancing face identification using local binary patterns and K-nearest neighbors. *Journal of Imaging*, 3(3). <https://doi.org/10.3390/jimaging3030037>
- Budi, A. S., Maulana, H., Multimedia Digital, T., Sains dan Teknologi, F., & Teknik Informatika dan Komputer, J. (2016). *Pengenalan Citra Wajah Sebagai Identifier Menggunakan Metode Principal Component Analysis (PCA)*. 9(2).
- Cuentas, S., Peñabaena-Niebles, R., & Garcia, E. (2017). Support vector machine in statistical process monitoring: a methodological and analytical review. In *International Journal of Advanced Manufacturing Technology* (Vol. 91, Issues 1–4, pp. 485–500). Springer London. <https://doi.org/10.1007/s00170-016-9693-y>
- Dagher, I., Dahdah, E., & Al Shakik, M. (2019). Facial expression recognition using three-stage support vector machines. *Visual Computing for Industry, Biomedicine, and Art*, 2(1). <https://doi.org/10.1186/s42492-019-0034-5>
- Dalvi, C., Rathod, M., Patil, S., Gite, S., & Kotecha, K. (2021). A Survey of AI-Based Facial Emotion Recognition: Features, ML DL Techniques, Age-Wise Datasets and Future Directions. *IEEE Access*, 9, 165806–165840. <https://doi.org/10.1109/ACCESS.2021.3131733>
- Dwi Astuti, F., & Nova Lenti, F. (2021). *Implementasi SMOTE untuk mengatasi Imbalance Class pada Klasifikasi Car Evolution menggunakan K-NN*.
- Dwi Ratna, S., Setyono, B., & Herdha, T. (2016). Bullet Image Classification using Support Vector Machine (SVM). *Journal of Physics: Conference Series*, 693(1). <https://doi.org/10.1088/1742-6596/693/1/012009>
- Ghimire, D., Jeong, S., Lee, J., & Park, S. H. (2017). Facial expression recognition based on local region specific features and support vector machines. *Multimedia Tools and Applications*, 76(6), 7803–7821. <https://doi.org/10.1007/s11042-016-3418-y>
- Gunadarma, A., Ratri, K., & Wardani, R. (n.d.). Penerapan Histogram of Oriented Gradients, Principal Component Analysis, dan AdaBoost untuk Sistem Pengenalan Wajah. *Jurnal Telematika*, 13(2).
- Ilyas, B. R., Mohammed, B., Khaled, M., Ahmed, A. T., & Ihsen, A. (2019). Facial expression recognition based on DWT feature for deep CNN. *2019 6th International Conference on Control, Decision and Information Technologies (CoDIT)*, 344–348.
- Islam, B., Mahmud, F., Hossain, A., Bikash, P., Dqg, G., & Sumon Mia, M. (2018). *A Facial Region Segmentation Based Approach to Recognize Human Emotion Using Fusion of HOG & LBP Features and Artificial Neural Network*.
- Kalsum, T., Anwar, S. M., Majid, M., Khan, B., & Ali, S. M. (2018). Emotion recognition from facial expressions using hybrid feature descriptors. *IET Image Processing*, 12(6), 1004–1012. <https://doi.org/10.1049/iet-ipr.2017.0499>

- Kobayashi, T., Hidaka, A., & Kurita, T. (2008). *LNCS 4985 - Selection of Histograms of Oriented Gradients Features for Pedestrian Detection*.
- Konar, A., & Chakraborty, A. (2015). *Emotion Recognition: A Pattern Analysis Approach*. Wiley. <https://books.google.co.id/books?id=WeOfBQAAQBAJ>
- Lakshmi, D., & Ponnusamy, R. (2021). Facial emotion recognition using modified HOG and LBP features with deep stacked autoencoders. *Microprocessors and Microsystems*, 82. <https://doi.org/10.1016/j.micpro.2021.103834>
- Lek, J. X. Y., & Teo, J. (2023). Academic Emotion Classification Using FER: A Systematic Review. In *Human Behavior and Emerging Technologies* (Vol. 2023). Wiley-Hindawi. <https://doi.org/10.1155/2023/9790005>
- Li, K., Jin, Y., Akram, M. W., Han, R., & Chen, J. (2020). Facial expression recognition with convolutional neural networks via a new face cropping and rotation strategy. *Visual Computer*, 36(2), 391–404. <https://doi.org/10.1007/s00371-019-01627-4>
- Liu, X., Cheng, X., & Lee, K. (2021). GA-SVM-Based Facial Emotion Recognition Using Facial Geometric Features. *IEEE Sensors Journal*, 21(10), 11532–11542. <https://doi.org/10.1109/JSEN.2020.3028075>
- Mungra, D., Agrawal, A., Sharma, P., Tanwar, S., & Obaidat, M. S. (2020). PRATIT: a CNN-based emotion recognition system using histogram equalization and data augmentation. *Multimedia Tools and Applications*, 79(3–4), 2285–2307. <https://doi.org/10.1007/s11042-019-08397-0>
- Nikan, F., & Hassanpour, H. (2020). Face recognition using non-negative matrix factorization with a single sample per person in a large database. *Multimedia Tools and Applications*, 79(37–38), 28265–28276. <https://doi.org/10.1007/s11042-020-09394-4>
- NURYASIN, M. F., MACHBUB, C., & YULIANTI, L. (2023). Kombinasi Deteksi Objek, Pengenalan Wajah dan Perilaku Anomali menggunakan State Machine untuk Kamera Pengawas. *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, 11(1), 86. <https://doi.org/10.26760/elkomika.v11i1.86>
- Pan, Z., Li, Z., Fan, H., & Wu, X. (2017). Feature based local binary pattern for rotation invariant texture classification. *Expert Systems with Applications*, 88, 238–248. <https://doi.org/10.1016/j.eswa.2017.07.007>
- Pietikäinen, M., Hadid, A., Zhao, G., & Ahonen, T. (2011). *Computer Vision Using Local Binary Patterns*. Springer London. <https://books.google.co.id/books?id=wBrZz9FiERsC>
- Putri, E. C., Priyambadha, B., & Pradana, F. (2019). *PENERAPAN LOCAL BINARY PATTERN UNTUK MENGUKUR TINGKAT KEPUASAN PENGUNJUNG SECARA OTOMATIS*. 6(4), 363–368. <https://doi.org/10.25126/jtiik.201961290>
- R. Sangeetha, B. K. (2011). *Performance Evaluation of Kernels in Multiclass Support Vector Machines*.
- Retnoningrum, D., Widodo, A. W., & Rahman, M. A. (2019). *Ekstraksi Ciri Pada Telapak Tangan Dengan Metode Local Binary Pattern (LBP)* (Vol. 3, Issue 3). <http://j-ptiik.ub.ac.id>

- Revina, I. M., & Emmanuel, W. R. S. (2021). A Survey on Human Face Expression Recognition Techniques. In *Journal of King Saud University - Computer and Information Sciences* (Vol. 33, Issue 6, pp. 619–628). King Saud bin Abdulaziz University. <https://doi.org/10.1016/j.jksuci.2018.09.002>
- Shan, C., Gong, S., & McOwan, P. W. (2009). Facial expression recognition based on Local Binary Patterns: A comprehensive study. *Image and Vision Computing*, 27(6), 803–816. <https://doi.org/10.1016/j.imavis.2008.08.005>
- Sung, S., Kim, S., Park, B. K., Kang, D. Y., Sul, S., Jeong, J. H., & Kim, S. P. (2021). A study on facial expression change detection using machine learning methods with feature selection technique. *Mathematics*, 9(17). <https://doi.org/10.3390/math9172062>
- Ton-That, A. H., & Cao, N. T. (2022). Facial Expression Recognition Using a Novel Modeling of Combined Gray Local Binary Pattern. *Advances in Human-Computer Interaction*, 2022. <https://doi.org/10.1155/2022/6798208>
- Triwijoyo, B. K., Adil, A., & Anggrawan, A. (2021). Convolutional Neural Network With Batch Normalization for Classification of Emotional Expressions Based on Facial Images. *MATRIK : Jurnal Manajemen, Teknik Informatika Dan Rekayasa Komputer*, 21(1), 197–204. <https://doi.org/10.30812/matrik.v21i1.1526>
- Verma Gyanendra K., & Kumar Singh Bhupesh. (2011). *ICIIP 2011 Proceedings : 2011 International Conference on Image Information Processing : November 3-5, 2011, Jaypee University of Information Technology, Wagnaghat, Shimla, Himachal Pradesh, India*. IEEE.
- Yaddaden, Y. (2023). An efficient facial expression recognition system with appearance-based fused descriptors. *Intelligent Systems with Applications*, 17. <https://doi.org/10.1016/j.iswa.2022.200166>
- Yuli Syafitri, G. Y. K. S. S. S. M. (2022). *SISTEM INFORMASI MANAJEMEN*. 228. <https://books.google.co.id/books?id=es11EAAAQBAJ>
- Zhao, X., & Zhang, S. (2016). A review on facial expression recognition: Feature extraction and classification. *IETE Technical Review (Institution of Electronics and Telecommunication Engineers, India)*, 33(5), 505–517. <https://doi.org/10.1080/02564602.2015.1117403>

LAMPIRAN-LAMPIRAN

Lampiran 2.1 *Facial segment* beserta deskripsi dan nomor *landmark* untuk setiap *segment*

FS	Deskripsi	Indeks <i>landmark</i>
FS1	<i>Left inner brow raiser</i>	20-22
FS2	<i>Right inner brow raiser</i>	23-25
FS3	<i>Left outer brow raiser</i>	18-20
FS4	<i>Right outer brow raiser</i>	25-27
FS5	<i>Left upper lid raiser</i>	37-40
FS6	<i>Right upper lid raiser</i>	43-46
FS7	<i>Left lid tightener</i>	37, 40-42
FS8	<i>Right lid tightener</i>	43, 46-48
FS9	<i>Nose wrinkle</i>	32-36
FS10	<i>Upper lid raiser</i>	49-55
FS11	<i>Left lip corner</i>	49, 61, 68
FS12	<i>Right lip corner</i>	55, 65, 66
FS13	<i>Lip stretched/tightener</i>	49, 55-60
FS14	<i>Left cheek puffer</i>	1-6
FS15	<i>Right cheek puffer</i>	12-17
FS16	<i>Chin raiser</i>	7-11

Lampiran 3.2 Skenario penelitian

No	<i>Experiments</i>				
	<i>Handling Imbalanced data</i>	<i>Feature Selection</i>	<i>Feature</i>	<i>Kernel</i>	
1	<i>Without SMOTE</i>	<i>Without feature selection</i>	HOG + LBP	RBF	
2				Poly	
3				Linear	
4			VL + LC	RBF	
5				Poly	
6				Linear	
7			HOG + LBP + VL + LC	RBF	
8				Poly	
9				Linear	
10			<i>Using feature selection</i>	<i>Without feature selection</i>	RBF
11					HOG + LBP + VL + LC
12					Poly
13			<i>Using SMOTE</i>	<i>Using feature selection</i>	HOG + LBP + VL + LC
14					Poly
15					Linear
16			<i>Using feature selection</i>	<i>Using feature selection</i>	HOG + LBP + VL + LC
17					Poly
18					Linear

Lampiran 4.1 Hasil ekstraksi fitur *Landmark Curvature* (LC) per *facial segment*

Facial Segment 1			
Emosi	LC20	LC21	LC22
angry	0.002421	0.003756	0.003711
disgust	0.002302	0.003748	0.003604
fear	0.002324	0.003773	0.003734
happy	0.002011	0.003537	0.003507
neutral	0.002501	0.004125	0.004032
sad	0.002318	0.003752	0.003720
surprise	0.002448	0.004343	0.004291

Facial Segment 2			
Emosi	LC23	LC24	LC25
angry	0.003753	0.003441	0.004775
disgust	0.003839	0.003237	0.005181
fear	0.003772	0.003489	0.004551
happy	0.003537	0.003283	0.004099
neutral	0.004017	0.003672	0.004615
sad	0.003752	0.003491	0.004651
surprise	0.004343	0.003981	0.004548

Facial Segment 3			
Emosi	LC18	LC19	LC20
angry	0.002421	0.002397	0.002421
disgust	0.002302	0.002279	0.002302
fear	0.002324	0.002300	0.002324
happy	0.002011	0.001993	0.002011
neutral	0.002502	0.002475	0.002501
sad	0.002318	0.002294	0.002318
surprise	0.002448	0.002426	0.002448

Facial Segment 4			
Emosi	LC25	LC26	LC27
angry	0.004775	0.004623	0.004775
disgust	0.005181	0.005024	0.005181
fear	0.004551	0.004411	0.004551
happy	0.004099	0.004000	0.004099
neutral	0.004615	0.004462	0.004615
sad	0.004651	0.004496	0.004651
surprise	0.004548	0.004397	0.004548

Facial Segment 5				
Emosi	LC37	LC38	LC39	LC40
angry	0.000016	0.000012	0.000009	0.000012
disgust	0.000058	0.000049	0.000045	0.000049
fear	0.000018	0.000011	0.000008	0.000012
happy	0.000034	0.000018	0.000010	0.000024
neutral	0.000017	0.000008	0.000005	0.000013
sad	0.000014	0.000006	0.000003	0.000007
surprise	0.000002	0.000002	0.000001	0.000002

Facial Segment 6				
Emosi	LC43	LC44	LC45	LC46
angry	0.005674	0.005895	0.006083	0.000373
disgust	0.005461	0.005644	0.005809	0.000212
fear	0.005631	0.005842	0.006019	0.000232
happy	0.003375	0.003451	0.003511	0.001110
neutral	0.006660	0.006945	0.007173	0.000260
sad	0.006118	0.006362	0.006559	0.001266
surprise	0.005879	0.006129	0.006332	0.000173

Facial Segment 7				
Emosi	LC37	LC40	LC41	LC42
angry	0.000016	0.000012	0.000006	0.000006
disgust	0.000058	0.000049	0.000001	0.000001
fear	0.000018	0.000012	0.000005	0.000005
happy	0.000034	0.000024	0.000059	0.000051
neutral	0.000017	0.000013	0.000074	0.000059
sad	0.000014	0.000007	0.000018	0.000018
surprise	0.000002	0.000002	0.000001	0.000001

Facial Segment 8				
Emosi	LC43	LC46	LC47	LC48
angry	0.005674	0.000373	0.000124	0.000205
disgust	0.005461	0.000212	0.000103	0.000118
fear	0.005631	0.000232	0.000058	0.000078
happy	0.003375	0.001110	0.000104	0.000153
neutral	0.006660	0.000260	0.000065	0.000090
sad	0.006118	0.001266	0.000092	0.000131
surprise	0.005879	0.000173	0.000042	0.000062

Facial Segment 9					
Emosi	LC32	LC33	LC34	LC35	L36
angry	0.000055	0.004888	0.000072	0.000033	0.000023
disgust	0.000009	0.000333	0.000090	0.000078	0.000069
fear	0.000055	0.000723	0.000165	0.000067	0.000038
happy	0.000067	0.002667	0.000729	0.000101	0.000060
neutral	0.000035	0.002924	0.000145	0.000164	0.000053
sad	0.000058	0.000881	0.000221	0.000058	0.000030
surprise	0.000084	0.000760	0.000009	0.000005	0.000004

Facial Segment 10							
Emosi	LC49	LC50	LC51	LC52	LC53	LC54	LC55
angry	0.000254	0.000296	0.000400	0.000456	0.592061	0.268285	0.076568
disgust	0.000135	0.000160	0.000205	0.000248	0.775110	0.362227	0.050975
fear	0.000106	0.000153	0.000381	0.002338	0.580013	0.250013	0.141455
happy	0.000354	0.001511	0.001735	0.003157	0.591141	0.283219	0.089601
neutral	0.001361	0.000202	0.000224	0.000322	0.663821	0.247551	0.075957
sad	0.000246	0.000540	0.000840	0.001527	0.582474	0.278376	0.078665
surprise	0.000086	0.000118	0.000186	0.000239	0.595872	0.216465	0.053952

Facial Segment 11			
Emosi	LC49	LC61	LC68
angry	0.000254	0.000314	0.000107
disgust	0.000135	0.000413	0.000053
fear	0.000106	0.000242	0.000108
happy	0.000354	0.000371	0.000102
neutral	0.001361	0.000190	0.000122
sad	0.000246	0.000261	0.000117
surprise	0.000086	0.000126	0.000163

Facial Segment 12			
Emosi	LC55	LC65	LC66
angry	0.076568	0.001244	0.000206
disgust	0.050975	0.000292	0.000135
fear	0.141455	0.000884	0.000227
happy	0.089601	0.003026	0.000250
neutral	0.075957	0.000512	0.000326
sad	0.078665	0.000471	0.000208
surprise	0.053952	0.000455	0.000290

Facial Segment 13							
Emosi	LC49	LC55	LC56	LC57	LC58	LC59	LC60
angry	0.000254	0.076568	0.018877	0.002092	0.000325	0.000315	0.000314
disgust	0.000135	0.050975	0.003305	0.000336	0.000427	0.000417	0.000415
fear	0.000106	0.141455	0.021602	0.002901	0.000252	0.000243	0.000243
happy	0.000354	0.089601	0.024341	0.004909	0.000383	0.000372	0.000371
neutral	0.001361	0.075957	0.015088	0.002216	0.000198	0.000191	0.000190
sad	0.000246	0.078665	0.030304	0.002325	0.000271	0.000262	0.000262
surprise	0.000086	0.053952	0.007904	0.000852	0.000133	0.000128	0.000127

Facial Segment 14						
Emosi	LC1	LC2	LC3	LC4	LC5	LC6
angry	0.005821	0.005704	0.005450	0.002212	0.002197	0.002180
disgust	0.006804	0.006647	0.006339	0.001961	0.001950	0.001937
fear	0.005941	0.005819	0.005534	0.002278	0.002262	0.002245
happy	0.006411	0.006272	0.005911	0.002354	0.002336	0.002317
neutral	0.006154	0.006028	0.005720	0.002264	0.002248	0.002232
sad	0.006238	0.006095	0.005763	0.002141	0.002126	0.002109
surprise	0.005823	0.005724	0.005463	0.002421	0.002403	0.002383

Facial Segment 15						
Emosi	LC12	LC13	LC14	LC15	LC16	LC17
angry	0.003676	0.006192	0.005982	0.005765	0.005982	0.002449
disgust	0.003600	0.006596	0.006396	0.006164	0.006396	0.002326
fear	0.003954	0.006243	0.006042	0.005834	0.006042	0.002351
happy	0.003849	0.005671	0.005486	0.005285	0.005487	0.002032
neutral	0.003889	0.006718	0.006393	0.006164	0.006393	0.002534
sad	0.003768	0.006697	0.006449	0.006194	0.006449	0.002347
surprise	0.004141	0.006754	0.006522	0.006295	0.006522	0.002479

Facial Segment 16					
Emosi	LC7	LC8	LC9	LC10	LC11
angry	0.010195	0.009299	0.008380	0.003509	0.003478

disgust	0.010266	0.008687	0.007553	0.003427	0.003396
fear	0.011395	0.010271	0.009141	0.003730	0.003693
happy	0.012407	0.011010	0.009393	0.003654	0.003619
neutral	0.011543	0.010505	0.009202	0.003691	0.003656
sad	0.013288	0.011608	0.009751	0.003586	0.003552
surprise	0.012269	0.011303	0.010244	0.003898	0.003859

Lampiran 4.2 Hasil ekstraksi fitur *Vectorized Landmark* (VL)

Emosi	ED1	A1	ED2	A2	ED3	A3	ED4	A4
angry	25.336761	25.832689	22.982372	12.616364	21.553644	-2.443883	21.220046	-18.268224
disgust	24.928918	26.284481	22.702203	12.743085	21.265378	-2.435649	21.019168	-18.223268
fear	24.911230	25.837787	22.771675	12.574581	21.497983	-2.508927	21.296757	-18.197263
happy	25.116947	25.400791	23.069424	12.462605	21.853309	-2.220752	21.629451	-17.535980
neutral	25.212820	26.300915	22.981089	13.346547	21.483919	-1.661542	21.108408	-17.552815
sad	24.832324	25.758001	22.576294	12.641400	21.119142	-2.332600	20.798603	-18.200578
surprise	24.550284	24.690262	22.421327	11.341395	21.116604	-3.916750	20.897895	-19.842324

Emosi	ED5	A5	ED6	A6	ED7	A7
angry	21.549505	-33.993863	22.116161	-49.004325	22.712671	-63.206478
disgust	21.500966	-34.115303	22.296085	-48.744992	23.008733	-62.480072
fear	21.724556	-33.703453	22.368647	-48.290220	22.945605	-61.996410
happy	21.918453	-32.979589	22.231639	-48.105975	22.776786	-62.488683
neutral	21.452819	-33.254265	21.946705	-48.346147	22.481351	-62.537727
sad	21.165215	-33.951428	21.721008	-49.016852	22.283430	-63.054188
surprise	21.394900	-35.135236	22.184603	-49.630645	22.929865	-63.106520

Emosi	ED8	A8	ED9	A9	ED10	A10
angry	23.400445	-76.660816	23.343540	-90.697673	23.381970	-104.708488
disgust	23.565763	-75.789470	23.378961	-90.296544	23.589151	-104.939712
fear	23.443456	-75.177261	23.311687	-89.147906	23.358806	-103.184395
happy	23.636906	-76.196574	23.680988	-90.318887	23.619195	-104.432891
neutral	23.066321	-76.218989	22.951039	-90.406697	23.067028	-104.672102
sad	22.897456	-76.645709	22.780047	-90.814685	22.956472	-105.109153
surprise	23.414325	-75.956911	23.338524	-89.592281	23.319288	-103.292792

Emosi	ED11	A11	ED12	A12	ED13	A13
angry	22.765853	-118.299999	22.313837	-132.704746	21.899661	-147.498010
disgust	23.453657	-118.963498	23.286884	-132.967502	22.902402	-147.507986
fear	22.872650	-116.896991	22.507534	-131.126340	22.159108	-145.226001
happy	22.911157	-118.388026	22.596642	-132.889661	22.420992	-147.395460
neutral	22.628977	-118.640049	22.393563	-133.061098	22.152778	-147.594243
sad	22.625192	-119.114093	22.499979	-133.479512	22.307128	-148.220921
surprise	22.832654	-116.713689	22.336920	-130.576717	21.769320	-145.101243

Emosi	ED14	A14	ED15	A15	ED16	A16
angry	21.709675	-156.522692	22.083972	-10.590736	23.560564	144.754850
disgust	22.551351	-152.413785	22.843676	-6.771078	24.354158	148.792518
fear	21.927154	-155.156980	22.186112	-59.402818	23.519422	131.762511
happy	22.248296	-151.200070	22.490192	-31.924325	23.732138	138.094708
neutral	21.960424	-156.811995	22.349383	-29.567735	23.810194	149.475166
sad	22.176003	-150.459256	22.543089	-26.587682	23.971769	142.986532
surprise	21.445400	-158.092121	21.745479	-86.815850	23.108507	151.062480

Emosi	ED17	A17	ED18	A18	ED19	A19
angry	25.975343	151.150941	25.266307	39.148779	24.853262	48.471367
disgust	26.733079	153.970598	25.619003	39.408509	25.359412	48.605978
fear	25.754229	152.217891	25.669870	41.048426	25.541976	50.333492
happy	25.888748	149.667878	25.339580	39.589454	25.009082	48.741648
neutral	26.086640	151.616690	25.839093	40.278766	25.725556	49.456777
sad	26.302489	151.966184	25.429041	39.816224	25.193250	48.865893
surprise	25.296587	156.262201	25.936410	40.493035	26.076395	49.840670

Emosi	ED20	A20	ED21	A21	ED22	A22
angry	22.769313	57.651369	20.134554	67.278852	17.177363	77.728448
disgust	23.237007	57.854532	20.622199	67.410273	17.539264	77.266063
fear	23.777677	59.577102	21.403000	69.108371	18.423444	78.708305
happy	23.122311	57.863992	20.601099	67.170797	17.494331	76.485577
neutral	23.807639	58.632355	21.247294	67.976143	18.185638	77.609800
sad	23.372026	58.050865	20.982827	67.595582	18.101629	77.449279
surprise	24.460234	59.131205	22.062753	68.248889	18.953215	77.330960

Emosi	ED23	A23	ED24	A24	ED25	A25
angry	17.224707	100.036387	20.191147	110.835095	22.814527	120.633670
disgust	17.583540	99.166094	20.651472	110.140470	23.407698	120.388717
fear	18.500785	101.556465	21.494953	111.644601	23.918650	121.235737
happy	17.545910	101.822170	20.670696	111.801832	23.221787	121.360581
neutral	18.214442	100.564022	21.284132	110.990097	23.885071	120.609405
sad	18.077042	99.071030	20.963442	109.962695	23.397522	120.025060
surprise	19.057926	101.833352	22.207116	111.445820	24.676977	120.620020

Emosi	ED26	A26	ED27	A27	ED28	A28
angry	24.861028	130.162443	25.391730	139.478408	13.247692	88.815791
disgust	25.571759	130.086315	26.090771	139.528280	13.737629	87.966827
fear	25.649743	130.800127	25.879021	139.986730	13.583774	89.995790
happy	25.064763	130.918371	25.498073	140.090740	12.859229	89.061358
neutral	25.761995	130.172524	26.024337	139.473310	13.273987	89.054771
sad	25.249104	129.852153	25.710512	139.200147	13.422904	88.028530
surprise	26.319516	130.069855	26.272439	139.378793	13.590339	89.699990

Emosi	ED29	A29	ED30	A30	ED31	A31
angry	9.369409	88.388208	5.634689	87.100978	3.097000	31.438987
disgust	9.477449	86.530809	5.448304	82.189752	2.851232	7.329121
fear	9.624477	89.656632	5.805997	88.860003	3.184280	37.538249
happy	8.952843	88.445793	5.222647	86.763591	2.859436	19.396406
neutral	9.288370	88.423648	5.434445	86.658892	2.702816	30.207662
sad	9.416151	86.965079	5.611444	83.970051	3.064544	28.433358
surprise	9.784975	89.553625	6.101374	89.200667	2.987529	59.254609

Emosi	ED32	A32	ED33	A33	ED34	A34
angry	5.412046	-14.905428	3.771207	-35.977373	3.253609	-73.249918
disgust	5.949928	-14.794770	4.269373	-36.845092	3.655057	-74.990328
fear	5.392616	-16.120410	3.764916	-37.223068	3.253618	-78.084254
happy	5.680682	-16.251860	3.990808	-39.245858	3.519183	-80.161054
neutral	5.471222	-22.243622	3.972812	-44.206651	3.464270	-82.801667
sad	5.519190	-20.785335	4.075782	-41.822017	3.527949	-77.248475
surprise	5.046465	-15.728774	3.407493	-37.245672	2.817541	-79.748055

Emosi	ED35	A35	ED36	A36	ED37	A37
angry	3.622748	-99.902316	5.165293	-90.503167	19.379969	39.528204
disgust	3.721157	-111.433268	5.234227	-112.757882	19.806555	39.672273
fear	3.623921	-107.578019	5.154701	-109.516791	19.554113	40.176714
happy	3.722210	-113.850953	5.307231	-112.103029	19.247699	38.661676
neutral	3.662658	-120.357193	5.058595	-132.824754	19.542778	39.351647
sad	3.640043	-108.433486	4.958424	-116.100087	19.345323	38.922105
surprise	3.279548	-115.541181	4.873904	-116.570315	19.658537	39.015792

Emosi	ED38	A38	ED39	A39	ED40	A40
angry	18.547246	48.329113	16.617582	56.582109	13.578939	61.978620
disgust	18.961332	48.274069	17.072835	56.241704	14.057880	61.977131
fear	18.855865	49.448135	16.878013	57.829889	13.593525	63.106798
happy	18.319697	47.803996	16.297280	55.889736	13.085097	61.131575
neutral	18.785356	48.437604	16.739459	56.880174	13.454164	61.936626
sad	18.485660	47.699699	16.540108	55.986315	13.485418	61.592750
surprise	19.260976	49.208281	17.116906	58.094256	13.390072	62.583744

Emosi	ED41	A41	ED42	A42	ED43	A43
angry	14.595865	50.648387	16.710353	42.208866	13.555103	116.224279
disgust	15.182124	51.039895	17.256436	42.743133	14.107954	116.059788
fear	14.606961	51.341602	16.829373	42.655083	13.581772	117.412922
happy	14.389764	49.747849	16.609973	41.550187	13.037495	117.597297
neutral	14.478937	50.086724	16.739753	41.392231	13.405577	116.989827
sad	14.488837	49.926371	16.645543	41.372379	13.438231	116.344811
surprise	14.326532	49.854716	16.803027	40.661674	13.445063	117.161789

Emosi	ED44	A44	ED45	A45	ED46	A46
angry	16.665222	122.050305	18.560579	130.346073	19.352348	139.172217
disgust	17.220278	122.348931	19.112079	130.302611	19.977687	139.082771
fear	16.968278	123.038853	18.913550	131.435403	19.558423	140.768650
happy	16.343731	123.458308	18.301908	131.641926	19.175666	140.821102
neutral	16.782601	122.618609	18.777180	131.152564	19.510423	140.255520
sad	16.560639	122.331026	18.463547	130.833983	19.342639	139.492158
surprise	17.304658	121.882921	19.375252	130.788229	19.731823	140.758638

Emosi	ED47	A47	ED48	A48	ED49	A49
angry	16.801409	136.517625	14.656721	128.254660	13.429099	-47.255729
disgust	17.409170	135.959455	15.280098	127.801194	13.732697	-46.672063
fear	16.941333	138.274548	14.694208	129.948762	13.781495	-45.881454
happy	16.621145	137.803480	14.408646	129.834994	13.633172	-37.020668
neutral	16.810439	138.222304	14.525969	129.798705	13.777272	-48.624807
sad	16.680744	136.893276	14.502188	128.759455	13.647630	-48.783509
surprise	16.990645	139.248022	14.514289	130.508912	13.782577	-48.411415

Emosi	ED50	A50	ED51	A51	ED52	A52
angry	9.773739	-51.628238	7.257927	-68.675581	7.342924	-89.764204
disgust	10.126647	-50.677899	7.673272	-67.965904	7.771110	-87.920622
fear	10.048608	-50.897079	7.457051	-68.117442	7.543544	-88.192696
happy	9.771041	-43.338931	6.961988	-64.116074	6.852426	-88.432060
neutral	10.335911	-55.164900	7.993229	-71.133450	8.185226	-88.397187
sad	10.249681	-54.414163	7.909897	-70.314271	8.041095	-88.256771
surprise	9.880926	-52.234609	7.085841	-69.068973	7.200780	-88.415215

Emosi	ED53	A53	ED54	A54	ED55	A55
angry	7.249509	-112.017988	9.797710	-129.432018	13.357435	-134.006718
disgust	7.511207	-109.932605	10.064951	-129.176950	13.844696	-134.324485
fear	7.433604	-109.619322	10.015558	-127.563361	13.684317	-132.808284
happy	6.888395	-114.752137	9.745174	-136.733015	13.627435	-143.563215
neutral	7.921508	-107.258726	10.306698	-124.241290	13.691541	-131.505788
sad	7.765092	-107.891094	10.117941	-125.465800	13.599180	-132.313074
surprise	7.048078	-109.807162	9.857258	-127.076147	13.670623	-130.980882

Emosi	ED56	A56	ED57	A57	ED58	A58
angry	14.144408	-115.842764	14.459563	-101.224764	14.468399	-90.055480
disgust	14.488090	-116.149960	14.689966	-100.910872	14.696288	-89.368492
fear	14.337112	-114.714714	14.609960	-99.882267	14.650008	-88.694923
happy	14.427457	-119.915165	14.871823	-102.023609	14.912548	-89.646736
neutral	13.978633	-114.536324	14.026415	-100.240037	14.032343	-89.342212
sad	13.819275	-115.200125	13.904169	-100.638420	13.915195	-89.556526
surprise	14.653524	-113.366554	15.166445	-99.442061	15.232224	-89.082189

Emosi	ED59	A59	ED60	A60	ED61	A61
angry	14.505644	-79.634235	14.238091	-65.209825	12.573025	-51.771852
disgust	14.733766	-78.304637	14.511211	-64.173016	12.860243	-51.335118
fear	14.709655	-78.292192	14.463833	-63.791900	12.902265	-50.492027
happy	14.920542	-78.104846	14.498646	-60.600116	12.807501	-41.621549
neutral	14.088218	-79.133145	14.078483	-65.282008	12.939787	-53.300583
sad	13.981110	-79.228042	13.982275	-65.344134	12.818299	-53.362324
surprise	15.260704	-79.585146	14.788527	-65.708954	12.917273	-53.221125

Emosi	ED62	A62	ED63	A63	ED64	A64
angry	9.098668	-73.798953	8.954891	-89.909994	9.085413	-107.379375
disgust	9.554067	-72.345366	9.353138	-88.180831	9.404119	-106.091876
fear	9.504187	-73.132234	9.363127	-88.466531	9.444481	-105.059375
happy	8.621753	-69.721917	8.414403	-88.808291	8.552724	-109.577870
neutral	10.163213	-75.446173	10.099080	-88.868563	10.124016	-103.412176
sad	9.890348	-74.798165	9.813559	-88.783328	9.822901	-104.064166
surprise	9.325572	-74.426304	9.185806	-88.858208	9.281936	-104.530543


Emosi	ED65	A65	ED66	A66	ED67	A67
angry	12.498620	-129.364023	11.508245	-103.429443	11.564405	-89.867971
disgust	12.976772	-129.642669	11.692911	-103.135827	11.741563	-88.828512
fear	12.778405	-128.077108	11.620170	-101.908403	11.675204	-88.483747
happy	12.773777	-139.156528	12.113766	-104.069276	12.122821	-89.411490
neutral	12.813246	-126.620553	10.873771	-102.406106	10.923346	-88.944146
sad	12.688242	-127.566131	10.943464	-102.552996	10.986378	-89.049324
surprise	12.782980	-125.960709	12.018766	-101.275507	12.108901	-88.966938

Emosi	ED68	A68
angry	11.566183	-77.397235
disgust	11.776660	-75.797593
fear	11.731596	-76.177109
happy	12.174792	-75.838565
neutral	10.966799	-76.513340
sad	11.049203	-76.607774
surprise	12.107441	-77.600546


Lampiran 4.3 Hasil Seleksi Fitur

No	Angle 15	Angle 36	Angle 49	Angle 50	ED52	Angle 61	ED62	ED63	ED64	Angle 65	Emosi
1	0.0204 24	0.9941 42	0.4338 78	0.4311 25	0.5128 72	0.4582 71	0.4598 85	0.4274 94	0.5211 10	0.6326 77	Angry
2	0.0204 24	0.9941 42	0.4338 78	0.4311 25	0.5128 72	0.4582 71	0.4598 85	0.4274 94	0.5211 10	0.6326 77	Angry
...
133 81	0.9872 24	0.0124 49	0.3173 13	0.4387 24	0.3991 55	0.3639 72	0.4871 83	0.4686 07	0.5238 75	0.5735 53	Surprise
133 82	0.9872 24	0.0124 49	0.3173 13	0.4387 24	0.3991 55	0.3639 72	0.4871 83	0.4686 07	0.5238 75	0.5735 53	Surprise


Lampiran 4.4 Jumlah data awal sebelum dideteksi




Lampiran 4.5 Jumlah data setelah deteksi wajah dan landmark




Lampiran 4.6 Jumlah data hasil *image cropping*



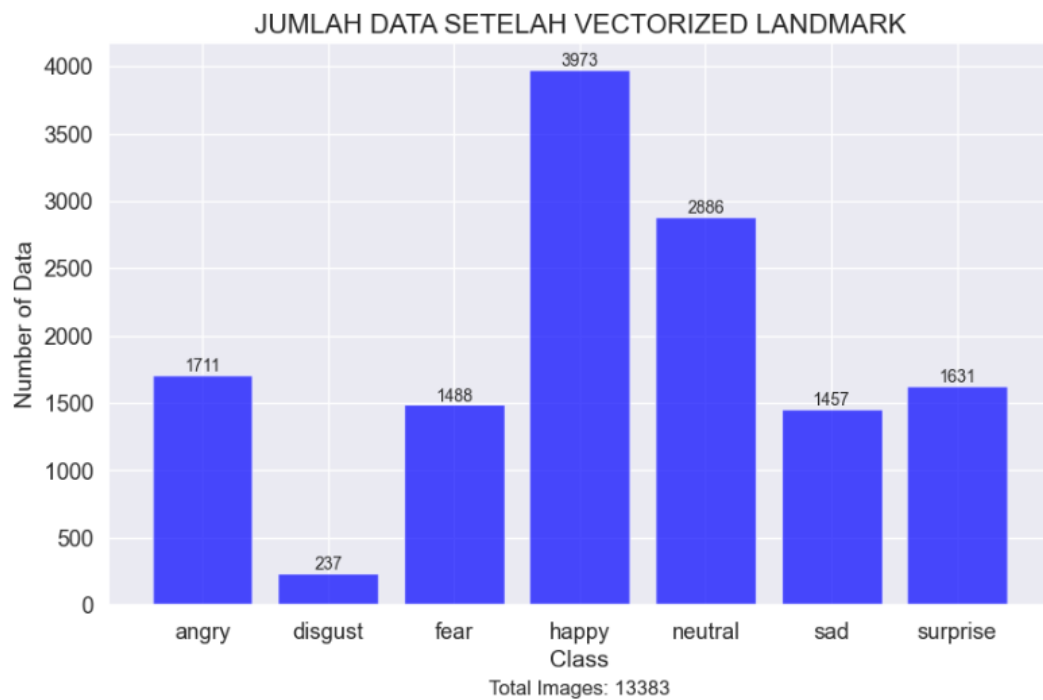
Lampiran 4.7 Jumlah data augmentation



Lampiran 4.8 Jumlah data setelah dilakukan penggabungan data augmentasi dan data z-normalization



Lampiran 4.9 Jumlah data gabungan setelah dilakukan deteksi ulang pada tahap *vectorized landmark*



Lampiran 4.10 kode program metode ekstraksi fitur *Vectorized Landmark*

```
1. def Euclidean_distance(p, q):
2.     dist = np.sqrt(np.sum(np.square(p - q)))
3.     return dist
4. def Angle(p, q):
5.     return np.degrees(np.arctan2(q[1] - p[1], q[0] - p[0]))
6. def Geometric_center(landmarks):
7.     N = len(landmarks)
8.     Xc, Yc = np.sum(landmarks, axis=0) / N
9.     return Xc, Yc
```

Lampiran 4.11 kode program metode ekstraksi fitur *Landmark Curvature*

```
1. df_LC = pd.DataFrame(columns=columns)
2. image_files = get_image_files(main_directory)
3. for image_path in image_files:
4.     label = os.path.basename(os.path.dirname(image_path))
5.     image = cv2.imread(image_path)
6.     try :
7.         landmarks_list = face_detection(image, detector,
            predictor)
8.         face_index = 0
9.         landmarks_array = landmarks_list[face_index]
10.        facial_segments = {
11.            "FS1": landmarks_array[20:23],
12.            "FS2": landmarks_array[23:26],
13.            "FS3": landmarks_array[18:21],
14.            "FS4": landmarks_array[25:28],
15.            "FS5": landmarks_array[37:41],
16.            "FS6": landmarks_array[43:47],
17.            "FS7": np.concatenate((landmarks_array[37:38],
            landmarks_array[40:43])),
18.            "FS8": np.concatenate((landmarks_array[43:44],
            landmarks_array[46:49])),
19.            "FS9": landmarks_array[32:37],
20.            "FS10": landmarks_array[49:56],
21.            "FS11": np.concatenate((landmarks_array[49:50],
            landmarks_array[61:62], landmarks_array[68:69])),
22.            "FS12": np.concatenate((landmarks_array[55:56],
            landmarks_array[65:66], landmarks_array[66:67])),
23.            "FS13": np.concatenate((landmarks_array[49:50],
            landmarks_array[55:61])),
```

```

24.         "FS14": landmarks_array[1:6],
25.         "FS15": landmarks_array[12:18],
26.         "FS16": landmarks_array[7:12]
27.     }
28.     degree = 3
29.     np.set_printoptions(precision=5)
30.     equations = []
31.     curvature_values = []
32.     for segment_name, segment_landmarks in
        facial_segments.items():
33.         x = segment_landmarks[:, 0]
34.         y = segment_landmarks[:, 1]
35.         x = x.reshape(-1, 1)
36.         y = y.reshape(-1, 1)
37.         model = make_pipeline(PolynomialFeatures(degree),
            LinearRegression())
38.         model.fit(x, y)
39.         coefficients =
            model.named_steps['linearregression'].coef_[0]
40.         intercept =
            model.named_steps['linearregression'].intercept_
41.         f_1st_derivative = np.polyder(coefficients, m=1)
42.         f_2nd_derivative = np.polyder(coefficients, m=2)
43.         segment_curvatures = []
44.         for xi in segment_landmarks:
45.             x_value = xi[0]
46.             curvature =
                np.abs(np.polyval(f_2nd_derivative, x_value)) / (1 +
                np.power(np.polyval(f_1st_derivative, x_value), 2))**(3/2)
47.             segment_curvatures.append(curvature)
48.             curvature_values.extend(segment_curvatures)
49.             row_data = curvature_values + [label]
50.             df_LC.loc[len(df_LC)] = row_data

```

Lampiran 4.12 kode program metode ekstraksi fitur HOG

```
1. def extract_hog(image, target_size=(48, 48)):  
2.     orientations = 8  
3.     pixels_per_cell = (8, 8)  
4.     cells_per_block = (2, 2)  
5.     hog_features = hog(image, orientations=orientations,  
6.                        pixels_per_cell=pixels_per_cell,  
7.                        cells_per_block=cells_per_block,  
8.                        visualize=False, block_norm='L2-Hys')  
9.     hog_features = (hog_features * 255).astype(np.uint8)  
10.    return hog_features
```

Lampiran 4.13 kode program metode ekstraksi fitur *Local Binary Pattern* (LBP)

```
1. def lbp_image(image, radius, n_points):  
2.     lbp_result = local_binary_pattern(image, n_points,  
3.     radius, method='default')  
4.     lbp_result = np.uint8((lbp_result / np.max(lbp_result)) *  
5.     255)  
6.     return lbp_result
```

INDEKS DAFTAR PUSTAKA

No	Daftar Pustaka	Indeks
1	Beli, I. L. K., & Guo, C. (2017). Enhancing face identification using <i>Local Binary Patterns</i> and K-nearest neighbors. <i>Journal of Imaging</i> , 3(3). https://doi.org/10.3390/jimaging3030037	Q2
2	Budi, A. S., Maulana, H., Multimedia Digital, T., Sains dan Teknologi, F., & Teknik Informatika dan Komputer, J. (2016). <i>Pengenalan Citra Wajah Sebagai Identifier Menggunakan Metode Principal Component Analysis (PCA)</i> . 9(2).	SINTA 3
3	Cuentas, S., Peñabaena-Niebles, R., & Garcia, E. (2017). <i>Support Vector Machine</i> in statistical process monitoring: a methodological and analytical review. In <i>International Journal of Advanced Manufacturing Technology</i> (Vol. 91, Issues 1–4, pp. 485–500). Springer London. https://doi.org/10.1007/s00170-016-9693-y	Q4
4	Dalvi, C., Rathod, M., Patil, S., Gite, S., & Kotecha, K. (2021). A Survey of AI-Based Facial Emotion Recognition: Features, ML DL Techniques, Age-Wise Datasets and Future Directions. <i>IEEE Access</i> , 9, 165806–165840. https://doi.org/10.1109/ACCESS.2021.3131733	Q1
5	Dagher, I., Dahdah, E., & Al Shakik, M. (2019). Facial expression recognition using three-stage <i>Support Vector Machines</i> . <i>Visual Computing for Industry, Biomedicine, and Art</i> , 2(1). https://doi.org/10.1186/s42492-019-0034-5	Q1
6	Dwi Astuti, F., & Nova Lenti, F. (2021). <i>Implementasi SMOTE untuk mengatasi Imbalance Class pada Klasifikasi Car Evolution menggunakan K-NN</i> .	SINTA 4
7	Dwi Ratna, S., Setyono, B., & Herdha, T. (2016). Bullet Image Classification using <i>Support Vector Machine (SVM)</i> . <i>Journal of Physics: Conference Series</i> , 693(1). https://doi.org/10.1088/1742-6596/693/1/012009	Tidak Berindeks
8	Ghimire, D., Jeong, S., Lee, J., & Park, S. H. (2017). Facial expression recognition based on local region specific features and <i>Support Vector Machines</i> . <i>Multimedia Tools and Applications</i> , 76(6), 7803–7821. https://doi.org/10.1007/s11042-016-3418-y	Q1
9	Gunadarma, A., Ratri, K., & Wardani, R. (n.d.). Penerapan <i>Histogram of Oriented Gradients</i> , Principal Component Analysis, dan AdaBoost untuk Sistem Pengenalan Wajah. <i>Jurnal Telematika</i> , 13(2).	SINTA 3
10	Ilyas, B. R., Mohammed, B., Khaled, M., Ahmed, A. T., & Ihsen, A. (2019). Facial expression recognition based on DWT feature for deep CNN. <i>2019 6th International</i>	Tidak Berindeks

No	Daftar Pustaka	Indeks
	<i>Conference on Control, Decision and Information Technologies (CoDIT)</i> , 344–348.	
11	Islam, B., Mahmud, F., Hossain, A., Bikash, P., Dqg, G., & Sumon Mia, M. (2018). <i>A Facial Region Segmentation Based Approach to Recognize Human Emotion Using Fusion of HOG & LBP Features and Artificial Neural Network</i> .	Tidak Berindeks
12	Kalsum, T., Anwar, S. M., Majid, M., Khan, B., & Ali, S. M. (2018). Emotion recognition from facial expressions using hybrid feature descriptors. <i>IET Image Processing</i> , 12(6), 1004–1012. https://doi.org/10.1049/iet-ipr.2017.0499	Q2
13	Kobayashi, T., Hidaka, A., & Kurita, T. (2008). <i>LNCS 4985 - Selection of Histograms of Oriented Gradients Features for Pedestrian Detection</i> .	Q3
14	Konar, A., & Chakraborty, A. (2015). <i>Emotion Recognition: A Pattern Analysis Approach</i> . Wiley. https://books.google.co.id/books?id=WeOfBQAAQBAJ	Tidak Berindeks
15	Lakshmi, D., & Ponnusamy, R. (2021). Facial emotion recognition using modified HOG and LBP features with deep stacked autoencoders. <i>Microprocessors and Microsystems</i> , 82. https://doi.org/10.1016/j.micpro.2021.103834	Q2
16	Lek, J. X. Y., & Teo, J. (2023). Academic Emotion Classification Using FER: A Systematic Review. In <i>Human Behavior and Emerging Technologies</i> (Vol. 2023). Wiley-Hindawi. https://doi.org/10.1155/2023/9790005	Q1
17	Li, K., Jin, Y., Akram, M. W., Han, R., & Chen, J. (2020). Facial expression recognition with convolutional neural networks via a new face cropping and rotation strategy. <i>Visual Computer</i> , 36(2), 391–404. https://doi.org/10.1007/s00371-019-01627-4	Q2
18	Liu, X., Cheng, X., & Lee, K. (2021). GA-SVM-Based Facial Emotion Recognition Using Facial Geometric Features. <i>IEEE Sensors Journal</i> , 21(10), 11532–11542. https://doi.org/10.1109/JSEN.2020.3028075	Q1
19	Mungra, D., Agrawal, A., Sharma, P., Tanwar, S., & Obaidat, M. S. (2020). PRATIT: a CNN-based emotion recognition system using <i>histogram equalization</i> and data augmentation. <i>Multimedia Tools and Applications</i> , 79(3–4), 2285–2307. https://doi.org/10.1007/s11042-019-08397-0	Q1
20	Nikan, F., & Hassanpour, H. (2020). Face recognition using non-negative <i>matrix</i> factorization with a single sample per person in a large database. <i>Multimedia Tools</i>	Q1

No	Daftar Pustaka	Indeks
	and Applications, 79(37–38), 28265–28276. https://doi.org/10.1007/s11042-020-09394-4	
21	NURYASIN, M. F., MACHBUB, C., & YULIANTI, L. (2023). Kombinasi Deteksi Objek, Pengenalan Wajah dan Perilaku Anomali menggunakan State Machine untuk Kamera Pengawas. <i>ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika</i> , 11(1), 86. https://doi.org/10.26760/elkomika.v11i1.86	SINTA 2
22	Pan, Z., Li, Z., Fan, H., & Wu, X. (2017). Feature based <i>Local Binary Pattern</i> for rotation invariant texture classification. <i>Expert Systems with Applications</i> , 88, 238–248. https://doi.org/10.1016/j.eswa.2017.07.007	Q1
23	Pietikäinen, M., Hadid, A., Zhao, G., & Ahonen, T. (2011). <i>Computer Vision Using Local Binary Patterns</i> . Springer London. https://books.google.co.id/books?id=wBrZz9FiERsC	Tidak Berindeks
24	Putri, E. C., Priyambadha, B., & Pradana, F. (2019). <i>PENERAPAN LOCAL BINARY PATTERN UNTUK MENGUKUR TINGKAT KEPUASAN PENGUNJUNG SECARA OTOMATIS</i> . 6(4), 363–368. https://doi.org/10.25126/jtiik.201961290	SINTA 2
25	R. Sangeetha, B. K. (2011). <i>Performance Evaluation of Kernels in Multiclass Support Vector Machines</i> .	Tidak Berindeks
26	Retnoningrum, D., Widodo, A. W., & Rahman, M. A. (2019). <i>Ekstraksi Ciri Pada Telapak Tangan Dengan Metode Local Binary Pattern (LBP)</i> (Vol. 3, Issue 3). http://j-ptiik.ub.ac.id	SINTA 2
27	Revina, I. M., & Emmanuel, W. R. S. (2021). A Survey on Human Face Expression Recognition Techniques. In <i>Journal of King Saud University - Computer and Information Sciences</i> (Vol. 33, Issue 6, pp. 619–628). King Saud bin Abdulaziz University. https://doi.org/10.1016/j.jksuci.2018.09.002	Q1
28	Shan, C., Gong, S., & McOwan, P. W. (2009). Facial expression recognition based on <i>Local Binary Patterns</i> : A comprehensive study. <i>Image and Vision Computing</i> , 27(6), 803–816. https://doi.org/10.1016/j.imavis.2008.08.005	Q2
29	Sung, S., Kim, S., Park, B. K., Kang, D. Y., Sul, S., Jeong, J. H., & Kim, S. P. (2021). A study on facial expression change detection using machine learning methods with feature selection technique. <i>Mathematics</i> , 9(17). https://doi.org/10.3390/math9172062	Q2
30	Ton-That, A. H., & Cao, N. T. (2022). Facial Expression Recognition Using a Novel Modeling of Combined Gray	Q2

No	Daftar Pustaka	Indeks
	<i>Local Binary Pattern. Advances in Human-Computer Interaction</i> , 2022. https://doi.org/10.1155/2022/6798208	
31	Triwijoyo, B. K., Adil, A., & Anggrawan, A. (2021). Convolutional Neural Network With Batch Normalization for Classification of Emotional Expressions Based on Facial Images. <i>MATRIK: Jurnal Manajemen, Teknik Informatika Dan Rekayasa Komputer</i> , 21(1), 197–204. https://doi.org/10.30812/matrik.v21i1.1526	SINTA 2
32	Yaddaden, Y. (2023). An efficient facial expression recognition system with appearance-based fused descriptors. <i>Intelligent Systems with Applications</i> , 17. https://doi.org/10.1016/j.iswa.2022.200166	Q1
33	Yuli Syafitri, G. Y. K. S. S. S. M. (2022). <i>SISTEM INFORMASI MANAJEMEN</i> . 228. https://books.google.co.id/books?id=es11EAAAQBAJ	Tidak Berindeks
34	Zhao, X., & Zhang, S. (2016). A review on facial expression recognition: Feature extraction and classification. <i>IETE Technical Review (Institution of Electronics and Telecommunication Engineers, India)</i> , 33(5), 505–517. https://doi.org/10.1080/02564602.2015.1117403	Q2