

TESIS

PERBANDINGAN MODEL CNN UNTUK KLASIFIKASI EMOSI WAJAH



Disusun oleh:

Nama : Elfandry Bayunanda
NIM : 21.51.2112
Konsentrasi : Digital Transformation Intelligence

**PROGRAM STUDI S2 TEKNIK INFORMATIKA
PROGRAM PASCASARJANA UNIVERSITAS AMIKOM YOGYAKARTA
YOGYAKARTA**

2023

TESIS

PERBANDINGAN MODEL CNN UNTUK KLASIFIKASI EMOSI WAJAH

***COMPARISON OF CNN MODELS FOR FACIAL EMOTION
CLASSIFICATION***

Diajukan untuk memenuhi salah satu syarat memperoleh derajat Magister



Disusun oleh:

Nama : Elfandry Bayunanda
NIM : 21.51.2112
Konsentrasi : Digital Transformation Intelligence

**PROGRAM STUDI S2 TEKNIK INFORMATIKA
PROGRAM PASCASARJANA UNIVERSITAS AMIKOM YOGYAKARTA
YOGYAKARTA**

2023

HALAMAN PENGESAHAN

PERBANDINGAN MODEL CNN UNTUK KLASIFIKASI EMOSI WAJAH

COMPARISON OF CNN MODELS FOR FACIAL EMOTION CLASSIFICATION

Diperiapkan dan Disusun oleh

Elfandry Bayunanda

21.51.2112

Telah Diujikan dan Dipertahankan dalam Sidang Ujian Tesis
Program Studi S2 Teknik Informatika
Program Pascasarjana Universitas AMIKOM Yogyakarta
pada hari Jumat, 1 September 2023

Tesis ini telah diterima sebagai salah satu persyaratan
untuk memperoleh gelar Magister Komputer

Yogyakarta, Jumat, 1 September 2023

Rektor

Prof. Dr. M. Suvanto, M.M.
NIK. 190302001

HALAMAN PERSETUJUAN
PERBANDINGAN MODEL CNN UNTUK KLASIFIKASI EMOSI WAJAH

**COMPARISON OF CNN MODELS FOR FACIAL EMOTION
CLASSIFICATION**

Dipersiapkan dan Disusun oleh

Elfandry Bayunanda

21.51.2112

Telah Diujikan dan Dipertahankan dalam Sidang Ujian Tesis
Program Studi S2 Teknik Informatika
Program Pascasarjana Universitas AMIKOM Yogyakarta
pada hari Jumat, 1 September 2023

Pembimbing Utama


Prof. Dr. Ena Utami, S.Si., M.Kom
NIK. 190302037

Anggota Tim Penguji


Alva Hendi M., S.T., M.Eng., Ph.D
NIK. 190302106

Pembimbing Pendamping



Dhani Ariatmanto, M.Kom., Ph.D
NIK. 190302197


Hanafi S.Kom., M.Eng., Ph.D
NIK. 190302024


Prof. Dr. Ena Utami, S.Si., M.Kom
NIK. 190302037

Tesis ini telah diterima sebagai salah satu persyaratan
untuk memperoleh gelar Magister Komputer

Yogyakarta, 1 September 2023
Direktur Program Pascasarjana


Prof. Dr. Kusri, M.Kom.
NIK. 190302106

HALAMAN PERNYATAAN KEASLIAN TESIS

Yang bertandatangan di bawah ini,

Nama mahasiswa : Elfandry Bayunanda
NIM : 21.51.2112
Konsentrasi : Digital Transformation Intelligence

Menyatakan bahwa Tesis dengan judul berikut:
Perbandingan Model CNN Untuk Klasifikasi Emosi Wajah

Dosen Pembimbing Utama : Prof. Dr. Ema Utami, S.Si., M.Kom.
Dosen Pembimbing Pendamping : Dhani Ariatmanto, M.Kom., Ph.D.

1. Karya tulis ini adalah benar-benar **ASLI** dan **BELUM PERNAH** diajukan untuk mendapatkan gelar akademik, baik di Universitas **AMIKOM** Yogyakarta maupun di Perguruan Tinggi lainnya
2. Karya tulis ini merupakan gagasan, rumusan dan penelitian **SAYA** sendiri, tanpa bantuan pihak lain kecuali arahan dari Tim Dosen Pembimbing
3. Dalam karya tulis ini tidak terdapat karya atau pendapat orang lain, kecuali secara tertulis dengan jelas dicantumkan sebagai acuan dalam naskah dengan disebutkan nama pengarang dan disebutkan dalam Daftar Pustaka pada karya tulis ini
4. Perangkat lunak yang digunakan dalam penelitian ini sepenuhnya menjadi tanggung jawab **SAYA**, bukan tanggung jawab Universitas **AMIKOM** Yogyakarta
5. Pernyataan ini **SAYA** buat dengan sesungguhnya, apabila di kemudian hari terdapat penyimpangan dan ketidakbenaran dalam pernyataan ini, maka **SAYA** bersedia menerima **SANKSI AKADEMIK** dengan pencabutan gelar yang sudah diperoleh, serta sanksi lainnya sesuai dengan norma yang berlaku di Perguruan Tinggi

Yogyakarta, Jumat, 1 September 2023
Yang Menyatakan,



AMIKOM
YOGYAKARTA
FAKSI 146138205


Elfandry Bayunanda

HALAMAN PERSEMBAHAN

Puji Syukur penulis panjatkan kepada Allah SWT atas segala berkat, rahmat, hidayah dan karunia-Nya, penulis dapat menyelesaikan penulisan Tesis yang berjudul "Perbandingan Model CNN Untuk Klasifikasi Emosi Wajah" dengan penuh perjuangan dan pengorbanan. Tesis ini dapat diselesaikan atas doa, dukungan, bantuan serta bimbingan dari berbagai pihak. Dalam kesempatan ini dengan segala kerendahan hati, penulis ingin menyampaikan ucapan terima kasih yang sebesar-besarnya kepada:

1. Allah SWT. Yang telah melimpahkan rahmat dan hidayah-Nya sehingga penulis dapat menyelesaikan tesis ini tepat waktu dan dengan baik.
2. Kedua orang tua saya Bapak Supardi dan Ibu Tati Tadjuddin, serta seluruh keluarga yang tidak pernah berhenti mendoakan dan memberikan dukungannya selama ini.
3. Apresiasi sebesar-besarnya kepada diri saya sendiri karena mampu melewati salah satu ujian kehidupan yang akan mengantarkan ke masa depan yang lebih baik.
4. Ibu Prof. Dr. Ema Utami, S.Si., M.Kom., selaku Dosen Pembimbing I yang telah memberikan bimbingan, saran, kritik, dan motivasi kepada penulis sehingga tesis ini dapat selesai.
5. Bapak Dhani Ariatmanto, M.Kom., Ph.D., selaku Dosen Pembimbing 2 yang telah memberikan arahan dan masukan selama penulisan tesis ini.
6. Abang saya Ryandhika Kumiawan, S.Pd beserta istri Sumiati, S.Pd yang telah memberikan dukungan serta motivasi selama penyusunan tesis ini.
7. Nabilah Alkautsar, A.Md.Kom yang telah menjadi alasan saya untuk menyelesaikan tesis ini dan semoga menjadi alasan saya untuk menjadi pribadi yang baik lagi untuk kedepannya.
8. Teman-teman MTI Angkatan 27 kelas A yang telah memberikan semangat, saran, masukan dan pengalaman yang tak ternilai.
9. Semua pihak yang tidak dapat penulis sebutkan satu persatu yang telah

memberikan bantuan berupa moril maupun materil, sehingga Tesis ini dapat diselesaikan.



HALAMAN MOTTO

“Fortis Fortuna Adiuvat”

(John Wick)

“Jangan pernah menyia-nyiakan waktumu, karena waktu yang kamu sia-siakan
sekarang, adalah waktu yang kamu ambil dari masa depanmu”

(Penulis)



KATA PENGANTAR

Puji Syukur penulis panjatkan kepada Allah SWT atas segala berkat, rahmat, hidayah dan karunia-Nya, penulis dapat menyelesaikan penulisan tesis ini yang berjudul "Perbandingan Model CNN Untuk Klasifikasi Emosi Wajah" tepat pada waktunya. Penulis menyadari masih terdapat banyak kekurangan selama penyusunan tesis ini dan tesis ini dapat diselesaikan atas doa, dukungan, bantuan serta bimbingan dari berbagai pihak. Dalam kesempatan ini dengan segala kerendahan hati, penulis ingin menyampaikan ucapan terima kasih yang sebesar-besarnya kepada:


1. Bapak Prof. Dr. M. Suyanto, MM., selaku Rektor Universitas AMIKOM Yogyakarta.
2. Ibu Prof. Dr. Kusriani, M.Kom., selaku Direktur Program Pasca Sarjana Universitas AMIKOM Yogyakarta.
3. Ibu Prof. Dr. Ema Utami, S.Si., M.Kom., dan bapak Dhani Ariatmanto, M.Kom., Ph.D., selaku dosen pembimbing yang dengan sabar dalam memberikan bimbingan, arahan dan masukan selama proses penulisan naskah tesis ini.
4. Kedua Orang Tua yang tak pernah Lelah dalam memberikan dukungan dan doa selama ini.
5. Dosen AMIKOM Yogyakarta yang telah memberikan banyak ilmu dan pengalaman.

Penulis menyadari bahwa keterbatasan pengetahuan dan pengalaman yang masih jauh dari harapan dan kesempurnaan, untuk itu penulis sangat mengharapkan

kritik, saran dan masukan yang bersifat membangun untuk memperbaiki penulisan tesis ini. Akhir kata, semoga apa yang telah diberikan kepada penulis baik itu segala dukungan, doa, bantuan ataupun jasa, akan mendapatkan balasan dari Allah SWT dan semoga tesis ini dapat memberikan manfaat bagi pembaca.

Yogyakarta, 1 September 2023

Penulis




DAFTAR ISI

HALAMAN JUDUL.....	ii
HALAMAN PENGESAHAN.....	iii
HALAMAN PERSETUJUAN.....	iv
HALAMAN PERNYATAAN KEASLIAN TESIS.....	v
HALAMAN PERSEMBAHAN.....	vi
HALAMAN MOTTO.....	viii
KATA PENGANTAR.....	ix
DAFTAR ISI.....	xi
DAFTAR TABEL.....	xiv
DAFTAR GAMBAR.....	xv
INTISARI.....	xvii
<i>ABSTRACT</i>	xviii
BAB I PENDAHULUAN.....	1
1.1. Latar Belakang Masalah.....	1
1.2. Rumusan Masalah.....	4
1.3. Batasan Masalah.....	5
1.4. Tujuan Penelitian.....	5
1.5. Manfaat Penelitian.....	5
BAB II TINJAUAN PUSTAKA.....	6
2.1. Tinjauan Pustaka.....	6
2.2. Keaslian Penelitian.....	9
2.3. Landasan Teori.....	19


2.3.1	Klasifikasi Emosi	19
2.3.2	Convolutional Neural Network	21
2.3.3	Machine Learning.....	23
2.3.4	Deep Leaning	24
2.3.5	Convolution Layer.....	25
2.3.6	Activation Function.....	25
2.3.7	Pooling Layer	27
2.3.8	Fully Connected Layer	27
2.3.9	Fine Tuning	28
2.3.10	ResNet-50.....	28
2.3.11	VGG19	29
BAB IIIMETODE PENELITIAN		31
3.1.	Jenis, Sifat, dan Pendekatan Penelitian	31
3.2.	Metode Pengumpulan Data.....	31
3.3.	Metode Analisis Data.....	32
3.4.	Dataset.....	34
3.5.	Alur Penelitian	36
BAB IVHASIL PENELITIAN DAN PEMBAHASAN		40
4.1	Pengumpulan Data	40
4.2	Analisa Data.....	41
4.3	Fine Tuning	41
4.3.1	Skenario Percobaan	48
4.3.2	Preprocessing Data (Augmentasi dan Balancing)	48
4.3.3	Proses Pembelajaran data	54

4.3.4 Ekstraksi Fitur VGG19.....	54
4.3.5 Ekstraksi Fitur ResNet50.....	56
4.4 Pembahasan hasil penelitian	57
4.4.1 Perbandingan Waktu Komputasi.....	59
4.4.2 Perbandingan <i>Training Loss</i> dan <i>Testing Loss</i>	61
4.4.3 Perbandingan <i>Training Accuracy</i> dan <i>Testing Accuracy</i>	68
BAB V PENUTUP	78
5.1. Kesimpulan	78
5.2. Saran.....	80
DAFTAR PUSTAKA	82



DAFTAR TABEL


Tabel 2.1 Matriks literatur review dan posisi penelitian.....	9
Tabel 2.2 Kategori Emosi	20
Tabel 3.1 Pembagian dataset tiap kelas.....	36
Tabel 4.1 Skenario Percobaan.....	48
Tabel 4.2 Hasil Percobaan.....	58



DAFTAR GAMBAR

Gambar 2.1 Proses CNN	21
Gambar 2.2 Alur Kerja Machine Learning	23
Gambar 2.3 Cara Kerja Deep Learning.....	24
Gambar 2.4 Proses Convolutional Layer	25
Gambar 2.5 Ilustrasi Max Pooling dan Average Pooling	27
Gambar 2.6 Contoh Fully Connected Layer	28
Gambar 2.7 Alur Proses ResNet-50	29
Gambar 2.8 Arsitektur VGG19	30
Gambar 3.1 Tampilan Dataset.....	34
Gambar 3.2 Alur Penelitian.....	37
Gambar 4.1 Persebaran Dataset	41
Gambar 4.2 Model VGG19 sebelum fine tuning	42
Gambar 4.3 Model VGG19 setelah fine tuning	43
Gambar 4.4 Model ResNet50 sebelum fine tuning	44
Gambar 4.5 Model ResNet50 setelah fine tuning	46
Gambar 4.6 Sintaks Augmentasi Gambar	49
Gambar 4.7 Augmentasi Data	51
Gambar 4.8 Sintaks Balancing Dataset	52
Gambar 4.9 Data Sebelum dan Setelah Oversampling	54
Gambar 4.10 Perbandingan Waktu Komputasi.....	59
Gambar 4.11 Grafik Validation Loss	61

Gambar 4.12 Perbandingan Training Loss dan Testing Loss	65
Gambar 4.13 Grafik Akurasi	68
Gambar 4.14 Training Accuracy dan Testing Accuracy	70
Gambar 4.15 Perbandingan Nilai Akurasi dengan Penelitian Sebelumnya	74



INTISARI

Emosi adalah suatu cara manusia untuk mengungkapkan perasaannya dan hal tersebut dapat ditunjukkan melalui ekspresi wajah, nada bicara, dan gerak tubuh seseorang. Salah satu cara paling mudah untuk mengetahui emosi seseorang adalah dengan melihat melalui ekspresi wajahnya. Untuk mengetahui ekspresi wajah seseorang bukanlah suatu hal yang sulit untuk dilakukan manusia, tetapi untuk mengetahui ekspresi wajah seseorang menggunakan kecerdasan buatan merupakan suatu hal yang menantang untuk dilakukan. Pada penelitian ini melakukan klasifikasi emosi pada wajah manusia menggunakan Convolutional Neural Network (CNN) dengan membandingkan arsitektur ResNet50 dan VGG19 untuk melakukan klasifikasi emosi wajah kedalam tujuh kelas, yaitu angry, disgust, fear, happy, neutral, sad, dan surprise. Meskipun manusia dapat dengan mudah mengidentifikasi ekspresi wajah ini, untuk mengajarkan komputer melakukan hal yang sama adalah tantangan tersendiri. Penelitian ini bertujuan untuk mengetahui model yang dapat menghasilkan nilai akurasi tertinggi pada klasifikasi emosi dengan citra wajah manusia, serta mencari tau apakah perlakuan balancing data dapat mempengaruhi tingkat akurasi klasifikasi menggunakan arsitektur ResNet50 dan VGG19. Arsitektur dengan hasil tertinggi yang didapatkan untuk klasifikasi emosi wajah manusia adalah VGG19 yang dikombinasikan dengan balancing data menggunakan teknik oversampling. Nilai akurasi tertinggi yang berhasil didapatkan adalah 71.58%, penerapan teknik balancing pada dataset yang digunakan mampu meningkatkan hasil akurasi klasifikasi secara signifikan.

Kata kunci: CNN, Emosi, ResNet50, VGG19, Balancing

ABSTRACT

Emotions are a way for people to express their feelings, and this can be shown through a person's facial expressions, tone of voice, and body movements. One of the easiest ways to find out someone's emotions is to look at their facial expressions. Knowing someone's facial expressions is not difficult for humans, but knowing someone's facial expressions using artificial intelligence is challenging. In this study, we classified emotions on human faces using a convolutional neural network (CNN) by comparing ResNet50 and VGG19 architectures to classify facial emotions into seven classes, namely angry, disgust, fear, happy, neutral, sad, and surprise. While humans can easily identify these facial expressions, teaching a computer to do the same is a challenge. The goal of this research is to find the model that can produce the highest accuracy in emotion classification using human facial images. In addition, we will find out whether the data balancing treatment can affect the level of classification accuracy using the ResNet50 and VGG19 architectures. The architecture with the highest results obtained for human face emotion classification is VGG19, combined with data equalization using oversampling techniques. The highest accuracy value obtained was 71.58%, the application of balancing techniques to the dataset used was able to significantly increase the classification accuracy results.

Keyword: CNN, Emotion, ResNet50, VGG19, Balancing

BAB I

PENDAHULUAN

1.1. Latar Belakang Masalah

Emosi adalah suatu cara manusia untuk mengungkapkan perasaannya dan hal tersebut dapat ditunjukkan melalui ekspresi wajah, nada bicara, dan gerak tubuh seseorang. Salah satu cara paling mudah untuk mengetahui emosi seseorang adalah dengan melihat melalui ekspresi wajahnya. Untuk mengetahui ekspresi wajah seseorang bukanlah suatu hal yang sulit untuk dilakukan manusia, tetapi untuk mengetahui ekspresi wajah seseorang menggunakan kecerdasan buatan merupakan suatu hal yang menantang untuk dilakukan.

Pendeteksian adalah sebuah dasar penelitian dalam bidang *computer vision*, *deep learning* dan *artificial intelligence*. Deteksi objek merupakan syarat penting untuk melakukan riset *computer vision* yang lebih kompleks, seperti pelacakan target, *event detection*, analisis perilaku, dan pemahaman semantik. Hal ini bertujuan untuk menemukan target yang diinginkan dari gambar, secara akurat menentukan kategori dan memberikan *bounding box* dari setiap target. Ini telah banyak digunakan dalam mengemudi otomatis kendaraan, pengambilan video dan gambar, kamera pengawas, analisis gambar medis dan bidang lainnya (Deng et al., 2020).

Pada bidang kesehatan, *computer vision* dapat digunakan dalam melakukan segmentasi pada citra medis untuk mengidentifikasi setiap piksel dari organ atau kerusakan dari latar background gambar medis seperti pada gambar CT atau MRI.

Salah satu hal yang paling menantang untuk dilakukan adalah mengambil informasi terkait bentuk dan volume organ dari gambar CT atau MRI (Hesamian et al., 2019)

Emosi memiliki peran yang sangat besar dalam kehidupan manusia. Emosi dapat berubah seiring dengan berubahnya perasaan yang dialami oleh manusia. Deteksi emosi pada wajah manusia merupakan interaksi antara manusia dan komputer dengan komputer sebagai perantaranya. Pendeteksian emosi wajah mulai banyak digunakan di beberapa bidang diantaranya adalah kesehatan, game dan berbagai hal lainnya (H. Zhang et al., 2019).

Menurut penelitian yang dilakukan oleh (Mehendale, 2020) yang berjudul "Facial emotion recognition using convolutional neural networks (FERC)" deteksi emosi yang menggunakan vektor pada wajah dan menunjukkan bahwa hasil ekspresi yang didapatkan lebih akurat, dengan nilai akurasi yang didapatkan adalah 96%. Sebuah penelitian yang pernah dilakukan pada tahun 2021 berhasil mendeteksi empat jenis emosi dengan menggunakan metode Convolutional Neural Network dengan arsitektur MobileNet. Rata-rata akurasi yang didapatkan pada penelitian tersebut adalah sebesar 92.50%, pada hasil sensitivitas dan spesifisitas mampu mencapai nilai 85% dan 95% (Badrulhisham & Mangshor, 2021).

Deteksi emosi wajah yang dilakukan oleh (Eastern Washington University et al., n.d.) menggunakan metode *Convolutional Neural Network* (CNN) dengan augmentasi data. Penelitian tersebut menggabungkan beberapa dataset kemudian dilakukan augmentasi data. Hasil akurasi yang didapatkan tergolong tinggi yaitu sebesar 96.24% augmentasi data dengan 120 epoch dan 92.95% dengan 260 epoch.

Berdasarkan sebuah penelitian yang pernah dilakukan oleh (Afaq & Rao, n.d.) dikatakan bahwa tidak ada nilai epoch yang optimal. Hal ini dikarenakan salah satu faktor utamanya adalah kesalahan pada saat training dan validasi, nilai epoch yang optimal juga berbeda-beda tergantung dari dataset yang digunakan. Pada penelitian tersebut telah diperlihatkan bahwa masing-masing dataset memiliki nilai epoch yang berbeda untuk mendapatkan hasil akurasi yang tinggi.

Berdasarkan paparan penelitian diatas menunjukkan bahwa nilai akurasi pada deteksi kelas emosi wajah memiliki nilai akurasi yang cukup tinggi. Akan tetapi nilai akurasi tersebut hanya diperoleh dengan penggunaan 4 kelas emosi wajah saja. Selain itu, nilai akurasi dan penggunaan jumlah epoch training yang digunakan juga bergantung pada model yang dibangun. Peluang pengembangan penelitian ini ditemukan pada penggunaan jumlah data dan kelas emosi wajah yang digunakan, serta mengatasi permasalahan imbalance data pada penelitian sebelumnya. Terkait dengan penjelasan dan permasalahan diatas, penelitian yang akan dilakukan adalah melakukan peningkatan akurasi dalam klasifikasi emosi pada ekspresi wajah manusia. Penelitian ini menggunakan arsitektur ResNet-50 dan VGG19 dengan dataset yang akan digunakan adalah FER2013.

Sehingga apabila merujuk pada pemaparan diatas, salah satu cara untuk mengetahui emosi manusia dengan menggunakan gambar wajah. Sejauh ini pendeteksian emosi wajah masih dilakukan secara langsung oleh manusia tanpa menggunakan sistem yang terkomputasi. Hal tersebut menyebabkan penilaian terhadap klasifikasi emosi wajah tidak menjadi subjektif, serta terjadinya perbedaan perspektif tiap-tiap orang. Sehingga hal tersebut membutuhkan sebuah sistem yang

dapat membantu melakukan klasifikasi emosi wajah dengan cepat dan akurat, dengan menggunakan komputer.

Pada penelitian ini nantinya akan melakukan klasifikasi emosi pada wajah manusia menggunakan *Convolutional Neural Network* (CNN) dengan membandingkan arsitektur ResNet50 dan VGG19 untuk melakukan klasifikasi emosi wajah kedalam tujuh kelas, yaitu *angry, disgust, fear, happy, neutral, sad, dan surprise*. Pemilihan arsitektur ResNet50 dan VGG19 dikarenakan kedua arsitektur tersebut telah banyak digunakan oleh penelitian lain yang menggunakan dataset dalam jumlah besar, serta pada arsitektur tersebut juga dapat melakukan *pre-trained* dan *fine-tuning* pada dataset besar seperti FER2013 sehingga dapat mengurangi *computational resources* yang digunakan (Sajjad et al., 2023).

Penelitian ini diharapkan dapat membantu untuk meningkatkan hasil analisa ekspresi wajah manusia yang nantinya akan digunakan pada bidang kesehatan maupun bidang lainnya, serta dapat memberikan kontribusi terhadap penelitian di bidang *Computer Vision dan Deep Learning*.

1.2. Rumusan Masalah

Berdasarkan latar belakang masalah yang ada, maka rumusan masalah pada penelitian ini adalah:

1. Berapa tingkat akurasi klasifikasi emosi pada gambar wajah manusia menggunakan model ResNet-50 dan VGG19?
2. Apakah perlakuan *balancing* terhadap data yang digunakan dapat meningkatkan akurasi yang dihasilkan dari model ResNet-50 dan VGG19?

1.3. Batasan Masalah

Batasan masalah pada penelitian ini adalah sebagai berikut:

- a) Dataset yang digunakan adalah dataset FER2013.
- b) Nilai maksimal Epoch yang digunakan pada setiap training yang dilakukan adalah 100.
- c) Emosi yang diklasifikasikan terbagi menjadi 7 yaitu, *angry, disgust, fear, happy, neutral, sad, dan surprise*.
- d) Skenario percobaan yang dilakukan menggunakan ResNet-50 dan VGG19.

1.4. Tujuan Penelitian

Tujuan penelitian yang diangkat berdasarkan dari rumusan masalah pada penelitian ini adalah sebagai berikut:

- a. Mengetahui model yang dapat menghasilkan nilai akurasi tertinggi pada klasifikasi emosi dengan citra wajah manusia.
- b. Mengetahui apakah perlakuan balancing data dapat mempengaruhi tingkat akurasi klasifikasi.

1.5. Manfaat Penelitian

Manfaat pada penelitian ini diantaranya sebagai berikut:

- a. Dapat menjadi kontribusi ilmiah dalam peningkatan performa klasifikasi emosi wajah dengan menggunakan CNN.
- b. Dapat menjadi peluang pengembangan klasifikasi emosi wajah.

BAB II

TINJAUAN PUSTAKA

2.1. Tinjauan Pustaka

Sebuah penelitian pernah dilakukan untuk melakukan pengujian terhadap kelayakan dari sistem yang dibuat untuk mengenali emosi pada wajah seseorang yang tertutup masker yang menggunakan metode *Convolutional Neural Network* (CNN). Penelitian tersebut terbagi menjadi dua strategi, dimana pada strategi pertama dilakukan klasifikasi terhadap delapan jenis emosi yang akan digunakan kemudian dilakukan uji coba dengan menggunakan transfer learning 30 epoch dan 50 epoch untuk fine-tuning mendapatkan akurasi sebesar 97.15% untuk training dan 45.83% untuk validasi. Kemudian pada strategi kedua dilakukan penerapan InceptionResNetv2 dengan fase pelatihan tunggal (termasuk transfer learning dan fine tuning) pada dataset tervalidasi yang sudah dikategorikan ulang mendapatkan akurasi sebesar 70% pada validasi yang terlihat lebih rendah dibandingkan pada strategi pertama dengan menggunakan metode yang diusulkan (Magherini et al., 2022).

Sebuah penelitian pada tahun 2022 melakukan perbandingan dan pengujian terhadap dua belas model yang berbeda untuk melakukan klasifikasi emosi. Penelitian tersebut menggunakan CNN dengan algoritma DeepFace untuk mengklasifikasikan emosi dengan menggunakan dataset FER2013 dan CK+. Algoritma DeepFace berhasil memprediksi 18 dari 25 (72%) sampel data yang

diambil dan memberikan hasil dengan akurasi tertinggi yaitu sebesar 97% dengan menggunakan dataset FER2013 (Chiurco et al., 2022).

Berdasarkan hasil dari sebuah penelitian yang pernah dilakukan oleh (Hung et al., 2019) mengatakan bahwa kompleksitas data sangat penting dalam penyusunan model pada deep learning. Pada penelitian tersebut akurasi yang didapatkan dengan menggunakan metode yang diajukan yaitu Dense_FaceLiveNet menunjukan peningkatan yang signifikan sebesar 90.97% dan 95.89% pada dataset JAFFE dan KDFE. Dari hasil pengujian yang dilakukan, tingkat akurasi tertinggi yang berhasil didapatkan dengan menggunakan transfer learning dari emosi dasar yang ada pada wajah manusia berdasarkan dataset FER2013 adalah sebesar 84.59%.

Penelitian berikutnya yang dilakukan oleh (Nan et al., 2022) menggunakan A-MobileNet untuk melakukan dropout dengan tujuan mencegah model yang digunakan *overfitting* serta meningkatkan ekstraksi ekspresi wajah dari gambar yang digunakan. Penelitian tersebut juga menggabungkan *center loss* dan *softmax loss* untuk mengoptimalkan parameter dari model yang digunakan. Model yang digunakan berhasil memberikan akurasi sebesar 84.49% pada dataset RAF-DB dan 88.11% pada dataset FERPlus.

Penelitian lainnya yang pernah dilakukan oleh (Siam et al., 2022) bertujuan untuk mendeteksi emosi pada wajah manusia secara *realtime* dengan menggunakan robot. Algoritma yang digunakan untuk mendeteksi emosi adalah MediaPipe Face Mesh. Selain itu pada tahap dekomposisi fitur dilakukan oleh PCA dengan tujuan untuk meningkatkan akurasi dari emosi yang dideteksi. Dataset yang digunakan

pada penelitian tersebut adalah Cohn-Kanade (CK+), Japanese Female Facial Expression (JAFPE) dan Real-world Affective Faces Database (RAF-DB). Terdapat lima metode yang digunakan, diantaranya adalah Support Vector Machine (SVM), K-Nearest Neighbor (KNN), Nai'Ve Bayes (NB), Logistic Regression (LR), dan Random Forest (RF). Hasil akurasi tertinggi yang berhasil didapatkan adalah 97% dengan menggunakan dataset CK+ dan JAFPE.

Penelitian lainnya terkait deteksi menggunakan ResNet-50v2 dan Xception untuk melakukan klasifikasi pada citra Xray pernah dilakukan oleh (Rahimzadeh & Attar, 2020). Penelitian ini membagi citra Xray menjadi 3 kategori yaitu, normal, covid19 dan pneumonia dengan menggunakan dua dataset yang masing-masing berjumlah 180 dan 6054 gambar dari pasien yang terinfeksi oleh Covid19 dan pneumonia, dan 8851 hasil Xray dari orang normal. Dikarenakan pembagian data yang tidak seimbang, maka penelitian tersebut membagi set pelatihan menjadi 8 fase, dimana pada tiap fasenya berisi 633 gambar yang terdiri dari 149 gambar Covid19, 234 gambar pneumonia, dan 250 gambar normal. Hasil rata-rata yang didapatkan adalah sebesar 99.50% dan 80.53% untuk sensitivitas nya pada klasifikasi Covid19, dan hasil akurasi keseluruhan yang didapatkan adalah 91.4%.

2.2. Keaslian Penelitian

Tabel 2.1 Matriks literatur review dan posisi penelitian
PERBANDINGAN MODEL CNN UNTUK KLASIFIKASI EMOSI WAJAH

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
1	Facial emotion recognition using convolutional neural networks (FERC)	Ninad Mehendale Springer, 2020	Melakukan klasifikasi emosi wajah dengan menggunakan metode Facial Emotion Recognition (FERC) dengan melakukan 2 tahapan yaitu menghilangkan background pada gambar dan yang kedua melakukan ekstraksi vektor pada wajah untuk menemukan ekspresi wajah yang sesuai.	FERC adalah cara baru untuk mendeteksi emosi wajah yang menggunakan keunggulan dari metode CNN dan supervised learning. FERC memiliki keunggulan karena bekerja dengan orientasi yang berbeda (kurang dari 30°) karena matriks fitur EV panjang 24 digit yang unik. Penghapusan latar belakang menambahkan keuntungan besar dalam menentukan emosi secara akurat.	Untuk penelitian kedepannya diharapkan dilakukan pengujian pendeteksi ekspresi wajah bohong dengan memanfaatkan mood detector	Menerapkan model ResNet-50 dan VGG19 untuk melakukan klasifikasi emosi wajah.
2	Emotion Recognition Using Convolutional Neural Network (CNN)	Nur Alia Syahirah Badrulhisham, Nur Nabilah Abu Mangshor 2021, IOP Science	Bertujuan untuk mengembangkan aplikasi pengenalan emosi berbasis mobile yang dapat mengenali emosi berdasarkan ekspresi wajah secara real-time dengan menggunakan Deep Learning dan Convolutional Neural Network (CNN).	Aplikasi yang dikembangkan mencapai akurasi rata-rata 92,50%, dalam hal sensitivitas dan spesifisitasnya masing-masing mampu mencapai 85,00% dan 95,00%.	Melakukan pengembangan dengan mengintegrasikan CNN dengan model lainnya sehingga dapat meningkatkan performa dari aplikasi tersebut.	Melakukan klasifikasi emosi wajah menggunakan CNN yang ditambahkan dengan model ResNet-50 dan VGG19

Tabel 2.1 (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
3	Facial Expression Recognition using Convolutional Neural Network with Data Augmentation	Tawsin Uddin Ahmed, Sazzad Hossain, Mohammad Shahadat Hossain, Raihan Ul Islam, Karl Andersson 2019, IEEE Xplore	Tujuan dari penelitian ini adalah untuk mengembangkan sistem pengenalan ekspresi wajah yang dapat mengklasifikasikan suatu citra ke dalam tujuh kelas emosi yang berbeda.	CNN dengan augmentasi memiliki akurasi validasi sebesar 96,24% dengan menggunakan 120 epoch, sedangkan CNN tanpa augmentation membutuhkan 260 epoch untuk mendapatkan akurasi validasi 92,95%. Disebutkan bahwa gambar baru yang dihasilkan dari kumpulan data gambar yang ada dengan augmentasi Bersama dengan ini, Dropout dan EarlyStopping Callbacks telah digunakan sehingga terjadinya overfitting model dapat dihindari. Kinerja model telah dievaluasi dengan rasio 65% banding 35% untuk training dan testing. Akurasi tertinggi dicapai pada 95,87%. Meskipun sedikit lebih rendah dari akurasi sebelumnya (dengan rasio pemisahan 80:20), ini cukup adil karena model sedang diuji dengan data uji yang lebih besar.	Untuk penelitian kedepannya diharapkan ada pengembangan terkait klasifikasi emosi majemuk seperti, bahagia dan terkejut, marah dan sedih, dan sebagainya.	Melakukan klasifikasi emosi wajah tanpa augmentasi data untuk membandingkan akurasi dari data asli yang digunakan.

Tabel 2.1 (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
4	Three convolutional neural network models for facial expression recognition in the wild	Jie Shao, Yongsheng Qian 2019, Elsevier	Paper tersebut mengusulkan tiga model CNN baru dengan arsitektur yang berbeda. Yang pertama adalah shallow network, bernama Light-CNN, yang merupakan jaringan saraf convolutional penuh yang terdiri dari enam modul konvolusi residual yang dapat dipisahkan secara mendalam untuk memecahkan masalah topologi kompleks dan overfitting. Yang kedua adalah dual-branch CNN yang mengekstrak fitur LBP tradisional dan deep learning secara paralel. Yang ketiga adalah pre-trained CNN yang dirancang dengan teknik transfer learning untuk mengatasi kekurangan sampel pelatihan.	Hasil penelitian menunjukkan bahwa model yang lebih baik dalam memiliki kinerja yang lebih baik dalam pembelajaran fitur wajah dan klasifikasi emosi. Namun, eksperimen yang diterapkan oleh Light-CNN membuktikan bahwa shallow CNN juga dapat mencapai skor yang baik dalam pengenalan ekspresi wajah. Selain itu, menggabungkan set fitur tidak membantu meningkatkan akurasi, yang berarti bahwa convolutional neural network dapat mempelajari fitur wajah utama hanya dengan menggunakan data piksel mentah.	Menerapkan fitur yang lebih efisien untuk menggabungkan dual-branch CNN dan mengubah mode fusi. Selain itu, menggunakan cross-database training network parameter untuk mendapatkan kemampuan generalisasi yang lebih baik	Melakukan perbandingan arsitektur dengan menggunakan ResNet-50 dan VGG19 untuk mengetahui nilai terbaik dari setiap metode dalam melakukan klasifikasi emosi.

Tabel 2.1 (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
5	Emotion recognition in the times of COVID19: Coping with face masks	Roberto Magherini, Elisa Mussi, Michaela Servi, Yary Volpe 2022, Elsevier	Tujuan dari paper tersebut adalah untuk menguji kelayakan penerapan sistem berbasis CNN yang mampu mengenali beberapa kategori emosi wajah ketika wajah tertutup masker dan menggunakan menggunakan metode yang diusulkan untuk mendapatkan akurasi yang tinggi dalam mendeteksi emosi	Strategi pertama (Strategi I) mengklasifikasikan delapan emosi dalam dua tahap yaitu transfer learning dengan 30 epochs dan fine-tuning dengan 50 epochs. Hasilnya adalah akurasi pelatihan sebesar 97,15% dan akurasi validasi 45,83%. Strategi kedua (Strategi II) menggunakan arsitektur InceptionResNetv2 dengan pelatihan tunggal pada dataset yang telah dikategorikan ulang menjadi lima kelas. Akurasi pada validasi mencapai 70%, lebih rendah dari Strategi I yang menghasilkan akurasi lebih tinggi.	Diharapkan pengembangan kedepannya dapat menggunakan analisa dari video daripada menggunakan single frame agar memungkinkan untuk mempertimbangkan dan mempelajari konteks alat ini juga mempertimbangkan dan mempelajari konteksnya untuk pemilihan fitur dan peningkatan hasil dari fine-tuning.	Melakukan perbandingan akurasi terhadap model yang digunakan dengan Batasan 100 epoch pada tiap model.

Tabel 2.1 (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
6	Real-time Detection of Worker's Emotions for Advanced Human-Robot Interaction during Collaborative Tasks in Smart Factories	Alessandro Chiurcoa, Jessica Frangellaa, Francesco Longoa, Letizia Nicolettib, Antonio Padovanoa, Vittorio Solinaa, Giovanni Mirabellia, Claudia Citraroa 2022, Science Direct	Penelitian tersebut dilakukan dengan cara menguji dan membandingkan dua belas model yang berbeda, semuanya berdasarkan Deep Learning dan Convolutional Neural Networks (CNN), untuk mengenali emosi menggunakan dataset CK+ dan Fer2013.	Algoritma DeepFace menghasilkan algoritma yang paling akurat dan diuji lebih lanjut pada subjek nyata dalam konteks kerja dan industri untuk menentukan validitas aktual dan modifikasi yang diperlukan untuk aplikasi industri skala besar. Deepface berhasil memprediksi 18 dari 25 (72%) sample data yang diambil dan hasil akurasi terbesar yang berhasil didapatkan adalah 97% dengan menggunakan dataset FER2013.	Pada saat penelitian masih ditemukan beberapa kekurangan berdasarkan pengujian yang dilakukan dilapangan. Beberapa kendala yang dihadapi diantaranya adalah keakuratan algoritma sangat dipengaruhi oleh posisi wajah dalam foto, kondisi lingkungan seperti pencahayaan yang sangat terang dapat memengaruhi akurasi prediksi. Jika operator jauh dari robot dan background di belakangnya kabur sulit untuk mendeteksi wajah dan operator umumnya menggunakan helm, kacamata pelindung atau masker, hal ini dapat mencegah pengenalan ekspresi wajah.	Melakukan klasifikasi dan pengenalan emosi dengan menggunakan gambar yang ada pada dataset FER2013 dan CK+

Tabel 2.1 (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
7	A-MobileNet: An approach of facial expression recognition	Yahui Nan, Jianguo Ju, Qingyi Hua, Haoming Zhang, Bo Wang 2022, Elsevier	Paper tersebut bertujuan untuk meningkatkan efektivitas dari akurasi klasifikasi emosi pada wajah manusia dengan menggunakan dataset FERPlus dan RAF-DB tanpa menambahkan parameter dari model yang digunakan.	Menggunakan A-MobileNet untuk melakukan dropout dengan tujuan mencegah model yang digunakan overfitting serta meningkatkan ekstraksi ekspresi wajah dari gambar yang digunakan. Penelitian tersebut juga menggabungkan center loss dan softmax loss untuk mengoptimalkan parameter dari model yang digunakan. Model yang digunakan berhasil memberikan akurasi sebesar 84.49% pada dataset RAF-DB dan 88.11% pada dataset FERPlus.	Pada penelitian berikutnya diharapkan dapat menganalisa penyebab dari kesalahan pengenalan ekspresi wajah dan meningkatkan kemampuan klasifikasi dari model yang digunakan.	Menggunakan model ResNet-50 dan VGG19 untuk melakukan proses klasifikasi emosi pada gambar wajah manusia

Tabel 2.1 (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
8	Recognizing learning emotion based on convolutional neural networks and transfer learning	Jason C. Hung, Kuan-Cheng Lin, Nian-Xiang Lai 2019, ScienDirect	Tujuan dari penelitian yang akan dilakukan adalah dengan meningkatkan jaringan FaceLiveNet dengan akurasi tinggi atau rendah dalam pengenalan emosi, dan pada penelitian tersebut diusulkan framework Dense_FaceLiveNet pada dua model transfer learning	Penelitian yang dilakukan menggunakan sebuah model baru yang dinamakan Dense_FaceLiveNet, berdasarkan arsitektur CNN konvensional untuk pengenalan emosi pada wajah manusia. Dataset JAFFE dan KDEF digunakan untuk membangun model pengenalan emosi untuk mengukur efisiensi dari metode yang digunakan, yaitu Dense_FaceLiveNet. Hasil dari penelitian yang dilakukan menunjukan peningkatan akurasi yang signifikan yaitu sebesar 90.97% dan 95.89% pada dataset JAFFE dan KDEF. Penelitian tersebut juga menunjukan bahwa model FER2013 dengan tingkat akurasi 70.02% yang dirancang sesuai dengan hasil dari JAFFE dan KDEF mengindikasikan bahwa ukuran dan kompleksitas	untuk penelitian kedepannya dapat menggunakan rasio pembagian data lain agar dapat mengetahui perbedaan akurasi dari dataset yang digunakan	Menggunakan dataset FER2013 dan CK+ untuk melakukan klasifikasi emosi pada gambar wajah manusia dan mengetahui perbedaan akurasi yang dihasilkan dari tiap dataset berdasarkan model yang digunakan

Tabel 2.1 (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
				dapat mempengaruhi secara signifikan. Dari hasil pengujian yang dilakukan, tingkat akurasi tertinggi yang berhasil didapatkan dengan menggunakan transfer learning dari emosi dasar yang ada pada wajah manusia berdasarkan dataset FER 2013 adalah sebesar 84,50%. dapat disimpulkan bahwa kompleksitas data sangat penting dalam penyusunan model pada deep learning		

Tabel 2.1 (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
9	Deploying Machine Learning Techniques for Human Emotion Detection	Ali I. Siam, Naglaa F. Soliman, Abcer D. Algarni, Fathi E. Abd El-Samie, Ahmed Sedik 2022, Research Gate	Penelitian tersebut bertujuan untuk mengembangkan sebuah metode baru untuk mendeteksi emosi pada wajah manusia secara realtime dengan menggunakan robot dan menggunakan face mesh untuk menentukan titik pada gambar wajah manusia untuk mengenali ekspresi.	Paper tersebut menggunakan algoritma MediaPipe Face Mesh untuk mendeteksi emosi pada wajah manusia. Selain itu pada tahap dekomposisi fitur dilakukan oleh PCA dengan tujuan untuk meningkatkan akurasi dari emosi yang dideteksi. Dataset yang digunakan pada penelitian tersebut adalah Cohn-Kanade (CK+), Japanese Female Facial Expression (JAFPE) dan Real-world Affective Faces Database (RAF-DB). Terdapat lima metode yang digunakan, diantaranya adalah Support Vector Machine (SVM), K-Nearest Neighbor (KNN), Nai'Ve Bayes (NB), Logistic Regression (LR), dan Random Forest (RF). Hasil akurasi tertinggi yang berhasil didapatkan adalah 97% dengan menggunakan dataset CK+ dan JAFPE.	Diharapkan pengembangan kedepannya dapat melakukan deteksi emosi pada wajah manusia dengan menggunakan data berupa video, teks tertulis ataupun kata-kata yang diucapkan secara langsung.	Klasifikasi dilakukan dengan menggunakan gambar saja, dan tidak dilakukan secara realtime.

Tabel 2.1 (Lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
10	A modified deep convolutional neural network for detecting COVID-19 and pneumonia from chest X-ray images based on the concatenation of Xception and ResNet50V2	Mohammad Rahimzadeh, Abolfazl Attar 2020, Elsevier	penelitian tersebut mengusulkan metode yang menggabungkan Xception dan Resnet-50v2 untuk mendeteksi Covid-19 dan Pneumonia pada citra X-ray	Penelitian yang dilakukan membagi citra Xray menjadi 3 kategori yaitu, normal, Covid19 dan pneumonia dengan menggunakan dua dataset yang masing-masing berjumlah 180 dan 6054 gambar dari pasien yang terinfeksi oleh Covid19 dan pneumonia, dan 8851 hasil Xray dari orang normal. Dikarenakan pembagian data yang tidak seimbang, maka penelitian tersebut membagi set pelatihan menjadi 8 fase, dimana pada tiap fasenya berisi 633 gambar yang terdiri dari 149 gambar Covid19, 234 gambar pneumonia, dan 250 gambar normal. Hasil rata-rata yang didapatkan adalah sebesar 99.50% dan 80.53% untuk sensitivitas nya pada klasifikasi Covid19, dan hasil akurasi keseluruhan yang didapatkan adalah 91.4%.	Diharapkan untuk penelitian kedepannya dapat menggunakan dataset yang lebih besar sehingga tingkat akurasi yang didapatkan semakin tinggi dan misklasifikasi dapat dihindari untuk memberikan hasil terbaik.	Melakukan klasifikasi dan deteksi emosi pada gambar wajah manusia dengan menggunakan model ResNet-50 dan VGG19

2.3. Landasan Teori

2.3.1 Klasifikasi Emosi

Klasifikasi emosi merupakan pembagian emosi menjadi beberapa kelompok. Menurut (Ekman, 1992) emosi dibagi menjadi 6 kelompok dasar yaitu *happiness, sadness, anger, fear, disgust, dan surprise*. Banyak penelitian yang telah dilakukan oleh peneliti lain untuk menciptakan kategori emosi baru, namun klasifikasi emosi yang dikemukakan oleh (Ekman, 1992) masih menjadi yang paling populer. Secara umum, ekspresi atau emosi *happiness* (kebahagiaan) adalah emosi positif yang muncul saat seseorang merasa senang, puas, atau gembira. Ekspresi wajah yang terkait dengan kebahagiaan melibatkan senyuman, mata yang bercahaya, dan mungkin juga gelak tawa.

Emosi *sadness* (kesedihan) adalah emosi negatif yang timbul ketika seseorang merasa kehilangan, kecewa, atau merasa buruk. Ekspresi wajah yang umum terkait dengan kesedihan termasuk mata yang berkabut, bibir yang terkulai, dan ekspresi yang terlihat hampa. Kemudian *anger* (kemarahan) adalah emosi yang muncul ketika seseorang merasa tertekan, marah, atau merasa terganggu. Ekspresi wajah yang terkait dengan kemarahan mencakup kerutan di dahi, mata yang memicing, dan bibir yang tegang. Emosi jenis *fear* (ketakutan) adalah emosi yang muncul ketika seseorang merasa terancam atau dalam bahaya. Ekspresi wajah ketakutan melibatkan mata yang melebar, alis yang terangkat, dan mulut yang terbuka.

Berikutnya emosi *disgust* (jijik) muncul ketika seseorang merasa terganggu atau merasa tidak suka terhadap sesuatu yang tidak diinginkan. Ekspresi wajah yang

terkait dengan jijik melibatkan lipatan hidung, bibir yang terangkat, dan ekspresi yang terlihat tidak senang. Sedangkan *surprise* (keterkejutan) adalah emosi yang muncul ketika seseorang mengalami situasi yang tidak diharapkan atau tidak terduga. Ekspresi wajah keterkejutan mencakup mata yang melebar, mulut yang terbuka, dan alis yang terangkat.

Emosi dapat diklasifikasikan menjadi dua kategori utama, yaitu *Categorical* dan *Dimensional*. *Categorical* membagi emosi kedalam beberapa kelompok dan menetapkan emosi tersebut kedalam kategori yang sesuai. *Dimensional* melihat emosi dalam sebuah ruang dua dimensi maupun tiga dimensi, dimana emosi tersebut dinyatakan dalam sebuah titik dalam bidang atau ruang yang ditentukan oleh variabel yang diperhitungkan (Bruna et al., 2016). Beberapa klasifikasi emosi dapat dilihat pada Tabel 2.2.


Tabel 2.2 Kategori Emosi

Penulis	Jumlah	Klasifikasi
Ekman	6	Anger, disgust, fear, joy, sadness, surprise
Parrot	6	Anger, fear, joy, love, sadness, surprise
Frijda	6	Desire, happiness, interest, surprise, wonder, sorrow
Plutchik	8	Acceptance, anger, anticipation, disgust, joy, fear, sadness, surprise
Izard	12	Interest, joy, surprise, sadness, anger, disgust, contempt, self-hostility, fear, shame, shyness, guilt
Extended Ekman	18	Anger, disgust, fear, joy, sadness, surprise, amusement, contempt, contentment, embarrassment, excitement, guilt, pride in achievement, relief, satisfaction, sensory pleasure, shame

Pada penelitian yang dilakukan menggunakan 7 kelas emosi diantaranya adalah "*angry*" (marah), "*disgust*" (jijik), "*fear*" (ketakutan), "*happy*" (bahagia), "*neutral*" (netral), "*sad*" (sedih), dan "*surprise*" (terkejut).

2.3.2 Convolutional Neural Network

Convolutional Neural Network (CNN) adalah sebuah model pembelajaran untuk memproses data yang memiliki pola grid pada sebuah gambar dan dirancang secara otomatis dan adaptif untuk mempelajari fitur spasial dari tingkat terendah ke tingkat tertinggi (Yamashita et al., 2018). CNN sendiri merupakan sebuah konstruksi matematis yang secara umum arsitekturnya terdiri dari feature learning (*convolutional layer*, *activation layer*, dan *pooling layer*) dan structural condition classification (*flatten*, *fully connected layer*, dan *softmax*) (Wang et al., 2019) seperti yang dapat dilihat pada Gambar 2.1.



Gambar 2.1 Proses CNN

CNN adalah jenis arsitektur jaringan saraf buatan yang umumnya digunakan dalam tugas-tugas pengolahan citra, seperti pengenalan gambar atau deteksi objek. Berdasarkan gambar 2.1 diatas, Feature Learning (Pembelajaran Fitur) Convolutional Layer (Lapisan Konvolusi) adalah lapisan pertama dalam CNN yang digunakan untuk mengekstraksi fitur-fitur penting dari gambar input. Ini bekerja

dengan menerapkan berbagai filter atau kernel ke seluruh gambar untuk mengidentifikasi pola-pola seperti tepi, sudut, dan tekstur. Kemudian Activation Layer (Lapisan Aktivasi) mengaplikasikan fungsi aktivasi (seperti ReLU - Rectified Linear Unit) ke hasil konvolusi. Ini membantu dalam mengenali fitur-fitur yang lebih kompleks dalam gambar. Pooling Layer (Lapisan Pooling) digunakan untuk mengurangi dimensi data dengan mengambil nilai-nilai terbesar atau rata-rata dari wilayah-wilayah tertentu. Ini membantu dalam mengurangi overfitting dan menghemat sumber daya komputasi.

Berikutnya *Structural Condition Classification* (Klasifikasi Kondisi Struktural), terdapat Flatten (Pengubahan ke Bentuk Vektor), setelah proses ekstraksi fitur melalui lapisan konvolusi dan aktivasi, hasilnya perlu diubah menjadi vektor satu dimensi agar dapat digunakan oleh lapisan-lapisan selanjutnya. Sedangkan Fully Connected Layer (Lapisan Koneksi Penuh) adalah lapisan berikutnya setelah "flatten." Ini terdiri dari neuron-neuron yang terhubung sepenuhnya dengan neuron-neuron pada lapisan sebelumnya. Ini adalah lapisan yang memungkinkan jaringan saraf untuk memahami hubungan yang lebih kompleks dalam data. Softmax (Fungsi Softmax), lapisan terakhir ini digunakan dalam masalah klasifikasi. Fungsi softmax menghasilkan probabilitas distribusi untuk setiap kelas yang mungkin dalam tugas klasifikasi. Kelas dengan probabilitas tertinggi dianggap sebagai prediksi dari jaringan.

2.3.3 Machine Learning

Machine learning merupakan salah satu subbidang dari *artificial intelligence* (AI) yang didefinisikan sebagai kemampuan sebuah mesin untuk mempelajari kecerdasan manusia. *Machine learning* sendiri digunakan untuk memahami struktur data dan menyesuaikan data tersebut kedalam sebuah model untuk melakukan berbagai tugas kompleks (Géron, 2017). Seperti yang terlihat pada Gambar 2.2.



Gambar 2.2 Alur Kerja Machine Learning

Machine learning umumnya membagi tugas-tugas kedalam kategori yang luas. Secara umum terdapat beberapa skenario yang digunakan dalam machine learning, diantaranya adalah sebagai berikut:

a. Supervised Learning

Dalam *Supervised Learning* komputer diberikan contoh input yang diberi label sesuai dengan output yang diinginkan. Tujuan dari digunakannya metode ini adalah agar algoritma yang digunakan dapat mempelajari data dengan membandingkan output aktual yang telah dipelajari sebelumnya untuk menemukan kesalahan dan memodifikasinya sesuai dengan model yang digunakan.

b. Unsupervised Learning

Pada *Unsupervised Learning* dilakukan pengolahan data yang tidak memiliki label. Algoritma yang digunakan akan mempelajari data yang diinputkan untuk mengelompokkan data yang memiliki karakteristik yang sama. Sederhananya tujuan utama dari *Unsupervised Learning* adalah untuk menemukan pola tersembunyi pada data yang diinputkan untuk melakukan pembelajaran terhadap model yang digunakan.

2.3.4 Deep Learning


Deep Learning merupakan salah satu bagian dari machine learning yang biasanya memiliki tiga atau lebih lapisan. Jaringan ini berfungsi untuk menirukan perilaku berpikir pada otak manusia, meskipun jauh dari kemampuannya yang memungkinkan untuk mempelajari sejumlah besar data (A. Zhang et al., 2021). Sementara sebuah jaringan masih membuat prediksi, lapisan tersembunyi tambahan dapat membantu dan mengoptimalkan dan memperbaiki akurasi seperti yang terlihat pada Gambar 2.3.



Gambar 2.3 Cara Kerja Deep Learning

2.3.5 Convolution Layer

Convolution Layer adalah sebuah istilah matematis yang merupakan blok struktur utama pada CNN. *Convolutional layer* biasanya terdiri dari filter berbeda yang kemudian ditumpuk diatas satu sama lain untuk membuat peta fitur 3 dimensi dimana kedalamannya ditentukan oleh jumlah filter (Ke et al., 2018). Parameter *convolutional layer* telah ditentukan dan akan digunakan selama proses *learning* berlangsung secara berulang. Tujuan utama dari digunakannya *convolutional layer* adalah untuk melakukan ekstraksi fitur dari citra (A. Zhang et al., 2021). Output dari *convolutional layer* terdiri dari sejumlah matriks atau volume yang disebut *feature map* atau *activation map*. Setiap elemen dalam *feature map* merepresentasikan respons dari kernel terhadap suatu bagian input. Kernel tersebut dilatih (*learned*) selama proses pelatihan jaringan saraf sehingga dapat mengekstraksi fitur-fitur yang relevan. Ilustrasi dari *convolution layer* dapat dilihat pada Gambar 2.4.



Gambar 2.4 Proses Convolutional Layer

2.3.6 Activation Function

Activation Function adalah sebuah proses matematis yang berfungsi untuk mengaktifkan atau menonaktifkan neuron. *Activation Function* sendiri juga biasa

disebut sebagai *transfer function* atau nonlinear dikarenakan pada prosesnya mengubah fungsi linear dari jumlah berbobot menjadi model non-linear (Mohamed Elgendy, 2020). Tujuan dari fungsi aktivasi adalah untuk memperkenalkan non-linearitas ke dalam jaringan saraf, memungkinkan jaringan saraf untuk mempelajari hubungan yang kompleks antara input dan output.

Fungsi aktivasi umumnya diterapkan setelah operasi linier pada setiap neuron dalam jaringan saraf. Operasi linier ini melibatkan penjumlahan bobot input dengan bias yang kemudian diaplikasikan ke neuron tersebut. Fungsi aktivasi kemudian mengubah output dari operasi linier tersebut menjadi nilai yang akan diteruskan ke lapisan berikutnya dalam jaringan saraf. Salah satu contoh fungsi aktivasi yang umum digunakan dalam jaringan saraf adalah *Rectified Linear Unit* (ReLU). ReLU adalah fungsi aktivasi yang sangat populer. Fungsi ini menghasilkan output 0 jika input negatif, dan menghasilkan input tersebut langsung jika inputnya positif.

$$f(x) = \max(0, x)$$


Keterangan :

$f(x_i)$ = nilai dari ReLU activation

X_i = nilai matriks dari citra

2.3.7 Pooling Layer


Pooling layer merupakan sebuah layer yang berfungsi untuk mengurangi kompleksitas komputasi model dengan cara mereduksi *noise* atau mengurangi resolusi dari sebuah gambar. Terdapat dua jenis *pooling* yang ada, yaitu *max pooling* dan *average pooling* (Yingge et al., 2020). *Max pooling* adalah nilai tertinggi dari tiap sub patch pada konvolusi layer sebelumnya. *Average pooling* merupakan nilai rata-rata dari setiap bagian dari *feature map*. Ilustrasi *pooling layer* dapat dilihat pada Gambar 2.5.



Gambar 2.5 Ilustrasi Max Pooling dan Average Pooling

2.3.8 Fully Connected Layer

Fully Connected Layer merupakan sebuah *neural network multilayer perceptron* (MLP). *Fully connected layer* berfungsi untuk mendapatkan hasil dari ekstraksi fitur yang telah dilakukan sebelumnya dengan cara menentukan fitur mana yang saling berkorelasi dan menyatukan semua *node* menjadi satu dimensi (Mohamed Elgendy, 2020). Ilustrasi *fully connected layer* dapat dilihat pada Gambar 2.6.



Gambar 2.6 Contoh Fully Connected Layer

2.3.9 Fine Tuning


Fine-tuning merupakan sebuah metode yang dimana data yang telah digunakan untuk pelatihan akan dilatih kembali menggunakan layer yang tidak dibekukan. Proses ini biasanya digunakan dalam deep learning untuk meningkatkan kinerja model pada tugas tertentu, terutama ketika jumlah data pelatihan yang tersedia terbatas. Penggunaan *fine tuning* dapat meningkatkan performa dari model yang digunakan (Ian Goodfellow et al., 2016).

2.3.10 ResNet-50

Residual Network atau yang biasa dikenal juga dengan sebutan ResNet merupakan salah satu arsitektur yang cukup populer. ResNet merupakan sebuah model *Deep Neural Network* (DNN) yang dikemukakan oleh (He et al., 2016) pada IEEE Conference on Computer Vision and Pattern Recognition pada tahun 2016.

Terobosan dari ResNet-50 adalah memiliki lebih dari 150 lapisan (*layer*) sehingga memungkinkan untuk dilakukan pelatihan jaringan syaraf yang lebih dalam.

ResNet50 adalah versi yang dipersingkat dari jaringan residual dirancang dengan tujuan utama memanfaatkan koneksi pintas (*shortcut connection*) untuk melewati seluruh blok lapisan konvolusi. Untuk mengatasi penurunan kinerja dan peningkatan kesalahan yang terjadi saat lapisan tambahan ditambahkan, tautan pintas disediakan untuk setiap pasangan filter tiga kali tiga saat membuat blok residual (Mahmud et al., 2023). Ilustrasi proses ResNet-50 dapat dilihat pada Gambar 2.7.




Gambar 2.7 Alur Proses ResNet-50

2.3.11 VGG19

VGG19 merupakan penerus dari model VGG16 yang berisi 19 lapisan filter kecil yang berukuran 3×3 conv dengan penyatuan periodik diseluruh model jaringan. VGG19 memiliki 16 lapisan konvolusi dan 3 lapisan *fully connected*. Lapisan input awal berukuran 224×224 dengan kedalaman 3. Layer 1 dan 2 dari CNN Conv2D memiliki kedalaman 64. Kedalamannya mewakili jumlah filter yang digunakan untuk menghasilkan *feature map*. Setiap filter sesuai dengan pola yang berbeda dalam konvolusi *input* di sekitar gambar dan menghasilkan *feature map*.

(Vidhya & Uthra, 2021). Pada model VGG19, terdapat tiga lapisan *Dense* yang ditempatkan di akhir. Lapisan-lapisan *Dense* ini berperan penting dalam melakukan klasifikasi berdasarkan fitur-fitur yang telah diekstraksi dari gambar. Jumlah unit pada lapisan *Dense* dapat disesuaikan tergantung pada jumlah kelas yang ingin diprediksi. Lapisan *dense* terakhir menggunakan fungsi aktivasi *softmax* untuk menghasilkan probabilitas dari setiap kelas yang mungkin. Dengan menggunakan lapisan - lapisan *dense* ini, model dapat mempelajari pola-pola yang lebih kompleks dan melakukan prediksi terhadap kelas-kelas yang ada dalam dataset yang digunakan (Lagunas & Garces, 2017). Model arsitektur VGG19 dapat dilihat pada Gambar 2.8.



Gambar 2.8 Arsitektur VGG19

BAB III

METODE PENELITIAN

3.1. Jenis, Sifat, dan Pendekatan Penelitian

Penelitian yang dilakukan merupakan penelitian komputasi eksperimental yang bertujuan untuk menguji dan membandingkan performa model ResNet-50 dan VGG19 dalam deteksi dan klasifikasi emosi wajah. Dalam penelitian ini, peneliti melakukan serangkaian pengujian yang bersifat eksperimental terhadap kedua model tersebut. Dengan mengimplementasikan dan menguji kedua model menggunakan dataset yang relevan yang berisi gambar wajah dengan emosi yang berbeda. Melalui eksperimen ini, peneliti dapat memperoleh pemahaman yang lebih baik mengenai keefektifan dan keandalan dari masing-masing model dalam melakukan deteksi dan klasifikasi emosi wajah.

Penelitian ini didasarkan pada pendekatan kuantitatif, di mana hasil penelitian dinyatakan dalam bentuk angka yang dapat diukur, seperti akurasi (*accuracy*), presisi (*precision*), dan *recall*. Pendekatan ini memungkinkan peneliti untuk secara objektif mengevaluasi performa kedua model dan melakukan perbandingan yang dapat diandalkan.

3.2. Metode Pengumpulan Data

Pada penelitian ini, dilakukan pengumpulan data menggunakan dataset FER2013 yang diperoleh dari Kaggle. Dataset FER2013 berisi lebih dari 35.000 gambar wajah dengan berbagai ekspresi emosi. Dengan menggunakan kedua

dataset ini, peneliti dapat melakukan pengujian yang representatif terhadap model ResNet-50 dan VGG19 dalam deteksi dan klasifikasi emosi wajah. Data yang digunakan dibuat oleh Pierre-Luc Carrier dan Aaron Courville dari Université de Montréal pada tahun 2013 (Goodfellow et al., 2013).

3.3. Metode Analisis Data

Setelah data yang dibutuhkan terkumpul maka, langkah selanjutnya yang akan dilakukan adalah mengolah dataset yang didapat menjadi sebuah informasi. Untuk melakukan analisa perbandingan performa dalam penerapan model ResNet-50 dan VGG19 dalam klasifikasi dan pengenalan emosi wajah menggunakan CNN, dan melakukan perbandingan hasil. Pada tahap Pra-pemrosesan data, data wajah akan diproses dengan tahap resizing gambar untuk menyeragamkan ukuran yang konsisten, normalisasi intensitas piksel, serta pembersihan dan penyesuaian data yang tidak relevan atau terdapat kecacatan.

Selanjutnya data akan dibagi menjadi data latih (*training set*) dan data uji (*testing set*). Dataset yang digunakan dibagi menjadi 90% data *training* dan 10% data *testing* (90:10). Sebelum memasukkan data ke dalam model, dilakukan ekstraksi fitur dari setiap gambar wajah. Dalam kasus pengenalan emosi wajah, fitur-fitur yang dapat digunakan misalnya adalah bentuk bibir, mata, atau alis. Arsitektur ResNet50 dan VGG19 digunakan untuk melakukan ekstraksi terhadap fitur-fitur yang ada.

Merujuk pada penelitian yang dilakukan oleh Tianyi Liu yang menyatakan mengenai konektivitas layer menjelaskan bahwa ResNet50 dan VGG19 serupa

dikarenakan keduanya merupakan *convolutional neural network* yang penggunaannya ditujukan untuk pengenalan objek, tetapi ResNet menggunakan *shortcut connection* untuk melewati dari satu lapisan ke lapisan lainnya, sedangkan VGG tidak (Liu et al., 2019).

Ekstraksi fitur yang dilakukan pada arsitektur ResNet50 menggunakan koneksi lewati yang melewati transformasi non-linier dengan fungsi identitas, dimana ResNet-50 sendiri adalah arsitektur jaringan saraf konvolusi yang menggunakan pendekatan "*residual learning*" untuk ekstraksi fitur pada gambar. Dalam ResNet-50, fitur-fitur diekstraksi melalui lapisan konvolusi berturut-turut dalam blok-blok. Pendekatan *residual learning* memungkinkan aliran langsung dari input ke output dalam blok-blok tersebut. Dengan demikian, informasi asli dapat diteruskan melalui lapisan-lapisan dengan sedikit distorsi, memungkinkan jaringan yang lebih dalam untuk dilatih dan mencapai tingkat akurasi yang lebih baik dalam pengenalan objek.

Sedangkan VGG menampilkan 19 lapisan dengan satu koneksi antara setiap lapisan dan lapisan berikutnya. Dimana VGG19 adalah arsitektur jaringan saraf konvolusi lainnya yang digunakan untuk ekstraksi fitur pada gambar. Dalam VGG19, fitur-fitur diekstraksi melalui serangkaian lapisan konvolusi dan *max pooling*. Arsitektur VGG19 terdiri dari beberapa blok konvolusi, di mana setiap blok terdiri dari beberapa lapisan konvolusi berturut-turut diikuti oleh lapisan *max pooling*. Dengan konvolusi bertingkat, VGG19 secara bertahap mengekstraksi fitur-fitur dari gambar dengan memperkecil dimensi spasial dan meningkatkan

kedalaman fitur. Pendekatan ini menghasilkan representasi fitur yang lebih rinci dan kompleks.

3.4. Dataset

Dataset yang digunakan untuk pengenalan ekspresi wajah dan terdiri dari lebih dari 35.000 gambar wajah manusia. Setiap gambar dalam dataset FER2013 memiliki resolusi rendah sebesar 48x48 piksel dan dalam skala abu-abu (*grayscale*). Contoh dataset yang digunakan dapat dilihat pada Gambar 3.1.



Gambar 3.1 Tampilan Dataset

Gambar-gambar ini merepresentasikan wajah manusia dengan berbagai ekspresi emosi yang meliputi *happy*, *sad*, *angry*, *surprise*, dan lain sebagainya. Dataset FER2013 terbagi menjadi dua set utama:

1. Set Pelatihan (*Training Set*):

Set pelatihan berisi sekitar 28.000 gambar wajah yang digunakan untuk melatih model pengenalan ekspresi wajah. Gambar-gambar ini digunakan untuk mengajarkan algoritma atau model pembelajaran mesin bagaimana mengenali dan mengklasifikasikan berbagai ekspresi emosi yang terdapat pada wajah manusia.

2. Set Pengujian (*Test Set*):

Set pengujian berisi sekitar 7.000 gambar wajah yang digunakan untuk menguji performa model atau algoritma yang telah dilatih. Gambar-gambar ini digunakan untuk mengukur seberapa baik model dapat menggeneralisasi dan mengenali ekspresi emosi pada data yang belum pernah dilihat sebelumnya.

Data yang digunakan dalam pembuatan dataset FER2013 diambil dari berbagai sumber, termasuk video, film, dan internet. Untuk menjaga privasi dan hak cipta, pemilik asli gambar memberikan izin atau gambar yang telah diizinkan penggunaannya digunakan dalam dataset ini. Setelah data dikumpulkan, gambar-gambar tersebut dianotasi oleh sekelompok orang untuk menentukan ekspresi emosi yang terkandung dalam setiap gambar.

FER2013 telah menjadi salah satu dataset yang populer dan banyak digunakan oleh para peneliti dan praktisi dalam bidang pengenalan ekspresi wajah dan pembelajaran mesin. Dataset ini telah memberikan kontribusi yang signifikan dalam pengembangan teknologi pengenalan emosi komputer dan aplikasinya dalam berbagai bidang, seperti pengenalan emosi pada video, pengenalan emosi pada interaksi manusia-komputer, dan sebagainya.

Data yang digunakan diambil dari Kaggle, dataset FER2013 merupakan kumpulan data yang berisi gambar wajah manusia yang ditunjukkan dalam bentuk ekspresi emosi tertentu. Data ini dikumpulkan dan dibuat tersedia oleh Pierre-Luc Carrier dan Aaron Courville dari Université de Montréal pada tahun 2013 (Goodfellow et al., 2013).


Dataset FER2013 yang digunakan memiliki tujuh kelas yang terbagi menjadi data *training* dan *testing*, proporsi pembagian data yang digunakan pada penelitian ini dapat dilihat pada Tabel 3.1.

Tabel 3.1 Pembagian dataset tiap kelas

	Training	Testing
Angry	3995	958
Disgust	436	111
Fear	4097	1024
Happy	7215	1774
Neutral	4965	1233
Sad	4830	1247
Surprise	3171	831

3.5. Alur Penelitian

Alur penelitian dibentuk untuk mempermudah proses pada penelitian. Alur penelitian dimulai dari persiapan awal, pengumpulan data, pemrosesan data, pemodelan, dan evaluasi. Alur penelitian yang dilakukan dimulai dari pengumpulan data, pemrosesan data, pemodelan, klasifikasi emosi dan evaluasi. Alur dari penelitian ini dapat dilihat pada Gambar 3.2 dibawah ini:



Gambar 3.2 Alur Penelitian


Pada penelitian ini terdapat 5 tahapan yang akan dilalui, yaitu sebagai berikut:

1. Tahapan pertama yang dilakukan pada penelitian ini adalah melakukan studi literatur, studi literatur dilakukan dengan membaca buku atau jurnal yang relevan dengan masalah yang diangkat sebagai rujukan untuk memilih metode dan algoritma yang sesuai untuk objek penelitian yang dilakukan.
2. Tahapan yang kedua adalah pengolahan data yang dimulai dari pengumpulan data. Pengumpulan data dilakukan dengan mengambil dataset dari Kaggle.

Dataset yang digunakan pada penelitian ini adalah FER2013 yang memiliki 35887 gambar.

3. Tahapan ketiga adalah *pre-processing*, dimana pada tahap ini dilakukan beberapa augmentasi terlebih dahulu sebelum gambar memasuki proses training. Augmentasi yang dilakukan yaitu *rotation*, *shear*, *width shift range*, *height shift range*, *zoom* dan *horizontal flip*.
4. Tahapan keempat adalah pemrosesan data. Pada tahap ini akan dilakukan proses pelatihan data *training* dari dataset FER2013 yang telah diaugmentasi pada tahapan sebelumnya. Proses pelatihan atau training ini dilakukan terhadap 4 skenario yaitu menggunakan arsitektur ResNet50, VGG19, ResNet50 yang dikombinasikan dengan *balancing* data dan VGG19 yang dikombinasikan dengan *balancing* data. Proses pelatihan dengan algoritma CNN akan melalui proses *features extraction* yang akan ditangani oleh 2 lapisan dalam arsitektur CNN yaitu lapisan *convolutional layer* dan *pooling layer*. Setelah dilakukan pengurangan dimensi dan didapatkan fitur-fitur yang dominan pada citra, berikutnya akan dilakukan proses pelatihan atau *training* yang terjadi pada lapisan selanjutnya yaitu *fully connected layer* hingga terbentuk model klasifikasi yang siap untuk dievaluasi melalui proses *testing*.
5. Pada tahap ini hasil dari pelatihan yang dilakukan menggunakan model ResNet50 dan VGG19 akan dievaluasi berdasarkan nilai *accuracy*, *precision*, dan *recall* dari tiap skenario yang diujikan. Pada tahap evaluasi ini juga membahas kecepatan proses dari tiap skenario yang digunakan dan melakukan analisis terhadap hasil tersebut.

6. Tahapan yang terakhir adalah membuat kesimpulan dengan menyajikan hasil dari percobaan yang dilakukan serta perlakuan terhadap dataset yang digunakan terhadap tingkat akurasi klasifikasi dari arsitektur yang memiliki hasil tertinggi.



BAB IV

HASIL PENELITIAN DAN PEMBAHASAN

Pada bab ini akan dijelaskan tentang analisa dan implementasi dari rancangan tahapan alur penelitian. Terdapat beberapa tahapan proses mulai dari pengumpulan dataset, preprocessing data dan penentuan arsitektur, perlakuan awal terhadap dataset sebelum dilakukan proses pembelajaran dengan arsitektur CNN, proses pembuatan model dan evaluasi hasil percobaan.

4.1 Pengumpulan Data

Data yang digunakan adalah FER-2013 dataset ini didapatkan dari Kaggle yang berisi lebih dari 35000 gambar yang terbagi menjadi 7 kelas pada data *training* dan data *testing*. Dataset tersebut juga digunakan oleh beberapa penelitian diantaranya (Hung et al., 2019), (Chiurco et al., 2022), dan (Nan et al., 2022). Persebaran data yang digunakan pada penelitian adalah sebesar 4953 data pada kelas *angry*, 547 data pada kelas *disgust*, 5121 data pada kelas *fear*, 8989 data pada kelas *happy*, 6198 data pada kelas *neutral*, 6077 data pada kelas *sad*, dan 4002 data pada kelas *surprise*. Dataset ini memiliki persebaran data yang tidak seimbang (*imbalanced data*), yang berarti jumlah data yang tersedia untuk setiap kelas emosi berbeda-beda. Persebaran dataset yang digunakan dapat dilihat pada Gambar 4.1.



Gambar 4.1 Persebaran Dataset

4.2 Analisa Data

Tahapan selanjutnya setelah data terkumpul adalah pembentukan model klasifikasi. Proses ini menggunakan dua arsitektur CNN yaitu ResNet50 dan VGG19 yang dikombinasikan dengan augmentasi serta *preprocessing* data untuk mendapatkan hasil tertinggi dari tiap skenario yang diujikan.

4.3 Fine Tuning

Sebelum dilakukan proses pembelajaran menggunakan ResNet50 dan VGG19, tahapan yang harus dilakukan sebelumnya adalah melakukan *fine tuning* terhadap arsitektur yang digunakan. Proses ini merupakan tahap untuk melatih model yang digunakan dengan menggunakan bobot dari dataset ImageNet. Proses *fine tuning* juga digunakan untuk menyesuaikan kelas pada layer konvolusi terhadap dataset yang akan dilatih. Pada penelitian ini proses *fine tuning* yang akan dilakukan adalah dengan memodifikasi lapisan akhirnya dan menambahkan lapisan baru setelah lapisan kedua terakhir.

block4_conv4 (Conv2D)	(None, 6, 6, 512)	2359808
block4_pool (MaxPooling2D)	(None, 3, 3, 512)	0
block5_conv1 (Conv2D)	(None, 3, 3, 512)	2359808
block5_conv2 (Conv2D)	(None, 3, 3, 512)	2359808
block5_conv3 (Conv2D)	(None, 3, 3, 512)	2359808
block5_conv4 (Conv2D)	(None, 3, 3, 512)	2359808
block5_pool (MaxPooling2D)	(None, 1, 1, 512)	0
Total params: 20,024,384		
Trainable params: 20,024,384		
Non-trainable params: 0		

Gambar 4.2 Model VGG19 sebelum fine tuning

Pada Gambar 4.2 ditunjukkan output model yang digunakan pada arsitektur VGG19 sebelum dilakukan *fine tuning*. Pada arsitektur VGG19 terdapat 5 blok *feature extraction* pada VGG19. Setiap blok terdiri dari beberapa *convolution layer* dan diikuti oleh *pooling layer*. Arsitektur ini memiliki 1000 kelas pada *layer dense* yang sesuai dengan kelas pada dataset ImageNet. Jumlah parameter yang digunakan pada arsitektur VGG19 mulanya adalah 143,667,240 parameter, akan tetapi dikarenakan perubahan pada *input shape* (ukuran input gambar) hal tersebut mempengaruhi dimensi dan ukuran lapisan-lapisan dalam model. Sehingga parameternya berubah menjadi 20,024,384 parameter.

block4_pool (MaxPooling2D)	(None, 3, 3, 512)	0
block5_conv1 (Conv2D)	(None, 3, 3, 512)	2359808
block5_conv2 (Conv2D)	(None, 3, 3, 512)	2359808
block5_conv3 (Conv2D)	(None, 3, 3, 512)	2359808
block5_conv4 (Conv2D)	(None, 3, 3, 512)	2359808
global_average_pooling2d (GlobalAveragePooling2D)	(None, 512)	0
out_layer (Dense)	(None, 7)	3591
Total params: 20,827,975		
Trainable params: 20,827,975		
Non-trainable params: 0		

Gambar 4.3 Model VGG19 setelah fine tuning


Pada Gambar 4.3 ditampilkan model history dari arsitektur VGG19 setelah dilakukan *fine tuning*. Perubahan pada layer dense yang semula memiliki 1000 kelas menjadi 7 kelas adalah sebuah transformasi penting dalam pengembangan model. Awalnya, model ini mungkin dirancang untuk tugas yang melibatkan 1000 kelas yang berbeda, tetapi sekarang diarahkan untuk tugas yang memerlukan pemahaman dan klasifikasi emosi, yang hanya memerlukan 7 kelas emosi yang berbeda. Perubahan ini mengharuskan model untuk memodifikasi representasi internalnya agar dapat mengidentifikasi dan membedakan antara emosi-emosi yang berbeda dengan lebih baik.

Selain itu, penambahan layer Global Average Pooling sebelum masuk ke layer dense juga merupakan langkah yang sangat relevan. Layer Global Average Pooling membantu mengurangi overfitting, yang merupakan kondisi di mana model terlalu "mengingat" data pelatihan dan kinerjanya menjadi buruk pada data yang belum pernah dilihat sebelumnya. Dengan merata-ratakan fitur-fitur pada seluruh

agar sesuai dengan tugas spesifik yang dihadapi. Output dari model yang telah di fine-tuning ini menjadi sangat relevan dalam konteks tugas yang dihadapi. Arsitektur ResNet50 sendiri terdiri dari beberapa blok yang kompleks, dengan jumlah total parameter yang signifikan, yaitu sebanyak 25,636,712 parameter. Dari jumlah tersebut, 25,583,592 parameter bersifat trainable, yang berarti mereka dapat disesuaikan atau diubah selama proses pelatihan, sedangkan 53,120 parameter lainnya adalah non-trainable, yang cenderung tetap pada nilai mereka.

Namun, perubahan pada input shape (bentuk masukan) dapat memiliki dampak besar pada dimensi dan ukuran lapisan-lapisan dalam ResNet50. Dalam konteks fine-tuning, ini adalah langkah yang penting karena mungkin ingin menggunakan model yang awalnya dirancang untuk tugas umum, seperti pengenalan gambar, dan mengubahnya agar dapat berkinerja optimal dalam tugas yang lebih khusus, seperti klasifikasi emosi. Akibatnya, jumlah total parameter berubah menjadi 23,587,712, dengan 23,534,592 parameter yang dapat dilatih (trainable) dan 53,120 parameter yang tetap (non-trainable).

Dengan demikian, fine-tuning arsitektur ResNet50 dan penyesuaian parameter yang dihasilkan dari perubahan input shape adalah langkah-langkah kunci dalam menghasilkan model yang lebih spesifik dan dapat mengatasi tugas klasifikasi emosi dengan baik. Hal ini menunjukkan pentingnya adaptasi model yang kuat dan skalabel dalam pemrosesan data gambar yang beragam dan berubah-ubah.



```

conv5_block3_2_conv (Conv2D) (None, 2, 2, 512) 270000 ['conv5_block3_2_conv[0][0]']
conv5_block3_2_bn (BatchNormal) (None, 2, 2, 512) 2000 ['conv5_block3_2_bn[0][0]']
conv5_block3_2_relu (Activation) (None, 2, 2, 512) 0 ['conv5_block3_2_relu[0][0]']
conv5_block3_3_conv (Conv2D) (None, 2, 2, 2048) 1696000 ['conv5_block3_3_conv[0][0]']
conv5_block3_3_bn (BatchNormal) (None, 2, 2, 2048) 8192 ['conv5_block3_3_bn[0][0]']
conv5_block3_3_act (Add) (None, 2, 2, 2048) 0 ['conv5_block3_3_act[0][0]',
conv5_block3_3_bn[0][0]]
conv5_block3_out (Activation) (None, 2, 2, 2048) 0 ['conv5_block3_act[0][0]']
global_average_pooling2d (GlobalAveragePooling2D) (None, 2048) 0 ['conv5_block3_out[0][0]']
out_layer (Dense) (None, 7) 14141 ['global_average_pooling2d[0][0]']

total params: 23,602,055
trainable params: 23,602,055
non-trainable params: 15,130

```

Gambar 4.5 Model ResNet50 setelah fine tuning

Pada Gambar 4.5, terlihat perubahan yang signifikan pada model ResNet50 setelah dilakukan fine-tuning dalam konteks pengenalan emosi. Awalnya, model ResNet50 memiliki lapisan dense (fully connected layer) dengan 1000 neuron yang sesuai dengan jumlah kelas dalam dataset ImageNet, yang terkenal memiliki 1000 kelas yang berbeda. Namun, dalam penelitian pengenalan emosi, hanya ada 7 kelas emosi yang relevan, yaitu kemarahan, jijik, ketakutan, kebahagiaan, netral, kesedihan, dan keterkejutan. Oleh karena itu, lapisan dense ini diubah agar hanya memiliki 7 neuron yang sesuai dengan jumlah kelas emosi yang digunakan. Hal ini sangat penting karena output dari lapisan dense ini akan menjadi prediksi model untuk setiap kelas emosi.

Selain perubahan pada lapisan dense, jumlah parameter dalam model juga mengalami penurunan signifikan setelah penyesuaian. Jumlah parameter dalam model yang telah disesuaikan menjadi 23,602,055, terdiri dari dua komponen utama: trainable parameters (parameter yang dapat disesuaikan selama pelatihan)

sebanyak 23,548,935 dan non-trainable parameters (parameter yang tidak dapat disesuaikan, biasanya berkaitan dengan lapisan konvolusi yang telah dipretrained) sebanyak 53,120. Reduksi jumlah parameter ini adalah langkah krusial untuk mengurangi kompleksitas model dan menghemat sumber daya komputasi.

Selanjutnya, juga ditambahkan lapisan Global Average Pooling pada model. Lapisan ini dirancang untuk mengatasi masalah dimensi spasial dalam output blok konvolusi ResNet50. Blok konvolusi tersebut menghasilkan keluaran dalam tiga dimensi, yaitu tinggi (height), lebar (width), dan kedalaman (depth) atau jumlah kanal. Global Average Pooling berfungsi dengan cara mengambil rata-rata dari nilai-nilai dalam setiap kanal secara global, menghasilkan tensor satu dimensi yang menggambarkan representasi fitur yang lebih kompak dari gambar yang dimasukkan ke dalam jaringan. Selain itu, lapisan ini membantu mengurangi jumlah parameter dalam jaringan, menghasilkan model yang lebih efisien secara komputasi.

Perubahan pada model tersebut juga berperan dalam mengurangi potensi overfitting. Overfitting terjadi ketika model terlalu kompleks dan mampu "menghafal" data pelatihan, tetapi tidak dapat melakukan generalisasi dengan baik pada data yang tidak pernah dilihat sebelumnya. Dengan mengurangi jumlah parameter dan menggunakan lapisan Global Average Pooling untuk mengagregasi informasi dengan cara yang lebih bijak, model cenderung lebih baik dalam memahami pola umum dalam data dan mampu melakukan prediksi emosi dari gambar yang tidak hanya berdasarkan pada data pelatihan, tetapi juga mampu beradaptasi dengan data yang belum pernah dilihat sebelumnya dengan lebih baik.

4.3.1 Skenario Percobaan

Pada penelitian ini dilakukan beberapa skenario percobaan yang akan diterapkan untuk arsitektur ResNet50 dan VGG19. Penelitian ini menggunakan 4 skenario yang akan diujikan dengan menggunakan 100 epoch dengan rasio pembagian datanya adalah 90% *training* dan 10% *testing*. Skenario yang dilakukan dapat dilihat pada Tabel 4.1.

Tabel 4.1 Skenario Percobaan

NO	Skenario	Keterangan
1	S1	ResNet50
2	S2	VGG19
3	S3	ResNet50 + Balancing Data
4	S4	VGG19 + Balancing Data

4.3.2 Preprocessing Data (Augmentasi dan Balancing)

Sebelum dataset yang digunakan dijadikan input untuk dalam proses pembelajaran, diperlukan tahapan *preprocessing* data. Tujuan dari dilakukannya *preprocessing* ini adalah untuk mengolah dataset yang digunakan dengan beberapa perlakuan, diantaranya adalah *rotation*, *width shift range*, *height shift range*, *shear range*, *zoom range* dan *horizontal flip*.

```

train_datagen = ImageDataGenerator(rotation_range = 15,
                                   width_shift_range = 0.15,
                                   height_shift_range = 0.15,
                                   shear_range = 0.15,
                                   zoom_range = 0.15,
                                   horizontal_flip = True,)

```

Gambar 4.6 Sintaks Augmentasi Gambar


Sintaks pada Gambar 4.6 menggunakan *ImageDataGenerator* dari Keras untuk melakukan augmentasi pada gambar. Augmentasi adalah teknik yang digunakan untuk memperluas dataset pelatihan dengan mengubah gambar-gambar yang ada menggunakan transformasi terkontrol. Dalam contoh ini, terdapat beberapa parameter yang digunakan. Pertama, *rotation_range* mengatur rentang rotasi gambar dalam derajat. Kemudian, *width_shift_range* dan *height_shift_range* mengontrol pergeseran horizontal dan vertikal gambar. Selanjutnya, *shear_range* mengatur rentang transformasi pergeseran yang diterapkan pada gambar, *zoom_range* mengendalikan perbesaran acak yang diterapkan pada gambar, sementara *horizontal_flip* mengindikasikan apakah akan menerapkan pencerminan horizontal acak atau tidak.


Penggunaan *ImageDataGenerator* dari library Keras dalam bahasa pemrograman Python untuk melakukan augmentasi gambar pada data pelatihan. *rotation_range* merupakan parameter yang mengontrol kisaran rotasi gambar dalam derajat. *rotation_range* diatur ke 15, yang berarti gambar dapat dirotasi dalam kisaran antara -15 derajat dan +15 derajat. *width_shift_range* dan *height_shift_range* merupakan parameter untuk mengontrol sejauh berapa gambar dapat digeser secara horizontal dan vertikal. Dalam contoh Anda, keduanya diatur

ke 0.15, yang berarti gambar dapat digeser sejauh 15% dari lebar atau tinggi gambar.

`shear_range` merupakan parameter yang mengontrol kemiringan (`shear`) gambar. Dalam contoh Anda, `shear_range` diatur ke 0.15, yang berarti gambar dapat mengalami `shear` hingga 15 derajat. `zoom_range` sebagai parameter untuk mengontrol tingkat zoom pada gambar. Dalam contoh yang digunakan adalah `zoom_range` diatur ke 0.15, yang berarti gambar dapat diperbesar atau diperkecil hingga 15%. Kemudian `horizontal_flip` merupakan parameter yang mengontrol apakah gambar akan di-flip secara horizontal atau tidak. `horizontal_flip` diatur ke `True`, yang berarti gambar dapat di-flip secara horizontal dengan probabilitas 50%. Contoh augmentasi gambar berdasarkan sintaks diatas dapat dilihat pada Gambar

4.7.





Gambar 4.7 Augmentasi Data

Dengan menggunakan *ImageDataGenerator*, penulis dapat membuat iterator yang menghasilkan batch gambar dengan transformasi acak sesuai parameter yang ditentukan. Iterator ini memungkinkan untuk melatih model dengan dataset yang diperluas melalui augmentasi data. Dengan memvariasikan *rotation*, *shear*, *zoom*, *horizontal flip*, *width shift range* dan *height shift range*, peneliti dapat meningkatkan variasi data yang digunakan dalam pelatihan model. Hal ini membantu model untuk belajar pola-pola yang lebih umum dan dapat mengurangi kemungkinan *overfitting* pada data pelatihan.

Setelah dilakukan augmentasi data, tahapan selanjutnya adalah melakukan balancing data dengan menggunakan teknik *oversampling*. *Oversampling* berfungsi untuk Meningkatkan jumlah sampel pada kelas minoritas dengan menduplikasi atau menghasilkan sampel baru dari sampel yang ada pada kelas tersebut.

```
oversampler = RandomOverSampler(random_state=42)
X_train_balanced, y_train_balanced = oversampler.fit_resample(X_train.reshape(len(X_train), -1),
np.argmax(y_train, axis=1))
X_train_balanced = X_train_balanced.reshape(-1, img_width, img_height, img_depth)
y_train_balanced = np_utils.to_categorical(y_train_balanced, num_classes)
```


Gambar 4.8 Sintaks Balancing Dataset

Potongan sintaks pada Gambar 4.8 di atas digunakan untuk mengatasi masalah ketidakseimbangan kelas dalam data pelatihan. Masalah ini umumnya terjadi ketika jumlah sampel dalam setiap kelas tidak seimbang, yang dapat menyebabkan model cenderung mempelajari kelas mayoritas dengan baik dan mengabaikan kelas minoritas. Untuk mengatasi hal ini, dilakukan proses *oversampling* menggunakan metode *RandomOverSampler*. *Oversampling* dilakukan dengan menciptakan sampel sintesis dari kelas minoritas sehingga setiap kelas memiliki jumlah sampel yang seimbang. Hal ini membantu memastikan bahwa model dapat mempelajari dengan baik semua kelas dan meningkatkan performa model pada kelas-kelas yang kurang representatif dalam data pelatihan.

Langkah pertama adalah membuat objek oversampler menggunakan *RandomOverSampler* dari pustaka *scikit-learn*, dengan mengatur parameter `random_state=42` untuk memastikan hasil yang konsisten ketika kode dijalankan ulang. Objek oversampler ini akan digunakan untuk mengatur keseimbangan antara kelas-kelas dalam dataset. Selanjutnya, data training yang akan dioversampling, yang dalam hal ini adalah `X_train` (gambar-gambar), diubah bentuknya menjadi

matriks satu dimensi. Hal ini diperlukan karena `RandomOverSampler` membutuhkan data dalam bentuk matriks dua dimensi atau lebih. Penggunaan `-1` dalam fungsi `reshape` mengizinkan NumPy untuk secara otomatis menentukan ukuran dimensi yang sesuai agar jumlah elemen tetap sama. Selanjutnya, oversampling dilakukan dengan menggunakan metode `fit_resample` dari objek `oversampler`. Ini menghasilkan `X_train_balanced` dan `y_train_balanced`, yang merupakan data training yang telah dioversampling. `X_train_balanced` berisi gambar-gambar yang telah diubah kembali ke bentuk aslinya, sementara `y_train_balanced` berisi label kelas yang telah diubah menjadi bentuk one-hot encoding.

Setelah melakukan *oversampling*, data pelatihan dan label yang seimbang digunakan untuk melatih model jaringan saraf. Dengan *oversampling*, model dapat belajar lebih baik dari kelas-kelas yang kurang representatif dan menghasilkan hasil yang lebih baik dalam pengklasifikasi pada data validasi. Proses *oversampling* membantu meningkatkan kemampuan model dalam mengenali kelas minoritas yang seringkali sulit dibedakan. Oleh karena itu, penggunaan *oversampling* menjadi strategi penting dalam mengatasi ketidakseimbangan kelas dalam dataset dan meningkatkan kinerja model dalam tugas klasifikasi. Gambar 4.9 menunjukkan hasil penanganan ketidakseimbangan data sehingga pada akhirnya data menjadi seimbang dan siap digunakan untuk beberapa skenario tertentu.



Gambar 4.9 Data Sebelum dan Setelah Oversampling

4.3.3 Proses Pembelajaran data

Setelah *preprocessing* selesai dilakukan maka dataset yang digunakan telah siap untuk proses pembelajaran dalam dan klasifikasi. Proses pembelajaran (*training*) pada penelitian ini melalui beberapa tahapan, diantaranya adalah tahapan untuk melakukan ekstraksi fitur dan tahapan untuk melakukan klasifikasi. Proses ekstraksi fitur dilakukan pada *convolutional layer* dan *pooling layer*. Sedangkan untuk proses klasifikasinya dilakukan pada *fully connected layer*.

4.3.4 Ekstraksi Fitur VGG19

VGG19 (Visual Geometry Group 19) adalah arsitektur jaringan saraf konvolusi (*Convolutional Neural Network/CNN*) yang sangat populer untuk tugas-tugas pengolahan citra. Proses ekstraksi fitur menggunakan VGG19 melibatkan beberapa langkah. Pertama, jaringan menerima gambar sebagai input dengan ukuran yang telah ditentukan, misalnya 224x224 piksel. Sebelum gambar dimasukkan ke dalam model VGG19, dilakukan pra-pemrosesan untuk mengubah skala piksel menjadi rentang yang sesuai.

Arsitektur VGG19 terdiri dari beberapa lapisan konvolusi dan lapisan pooling. Setiap lapisan konvolusi diikuti oleh lapisan aktivasi ReLU, yang membantu dalam pemodelan fitur non-linear. Proses ekstraksi fitur terjadi pada lapisan-lapisan konvolusi. Pada setiap lapisan konvolusi, filter konvolusi diterapkan pada gambar input untuk menghasilkan fitur-fitur yang lebih kompleks. Setiap lapisan konvolusi mengidentifikasi pola atau fitur tertentu dalam gambar.

Setelah lapisan konvolusi, dilakukan lapisan *pooling* untuk mengurangi dimensi fitur dan menyederhanakan representasi yang dihasilkan. VGG19 menggunakan lapisan *pooling* maksimum, di mana nilai maksimum diambil dari setiap jendela yang bergeser di seluruh fitur yang dihasilkan oleh lapisan konvolusi sebelumnya.

Setelah lapisan konvolusi dan pooling, fitur-fitur yang diekstraksi diteruskan ke lapisan *fully connected*. Lapisan ini terdiri dari beberapa neuron yang terhubung secara penuh, dan bertugas menghubungkan fitur-fitur yang diekstraksi dengan label kelas yang diinginkan.

Terakhir, pada lapisan akhir, output dari lapisan *fully connected* dihubungkan ke lapisan *softmax* yang menghasilkan probabilitas prediksi untuk setiap kelas. Kategori kelas dengan probabilitas tertinggi kemudian dianggap sebagai prediksi akhir dari model.

Secara ringkas, VGG19 melakukan ekstraksi fitur dengan menggunakan lapisan konvolusi untuk mengidentifikasi pola-pola penting dalam gambar, diikuti oleh lapisan *pooling* untuk mengurangi dimensi fitur, dan lapisan *fully connected* untuk menghubungkan fitur-fitur dengan label kelas. Hasil akhirnya adalah

probabilitas prediksi untuk setiap kelas yang dapat digunakan untuk melakukan klasifikasi gambar.

4.3.5 Ekstraksi Fitur ResNet50

Proses ekstraksi fitur yang dilakukan menggunakan arsitektur ResNet50 melibatkan beberapa tahapan. Pertama, dilakukan *pre-processing* data di mana gambar input dipersiapkan sesuai dengan format yang diharapkan oleh model ResNet50 meliputi perubahan ukuran gambar menjadi (224, 224) piksel dan normalisasi nilai piksel agar berada dalam rentang 0 hingga 1.

Selanjutnya, dilakukan penginisiasian arsitektur model dengan menginstansiasi model ResNet50 tanpa lapisan teratas (lapisan klasifikasi). Dengan mengatur `"include_top=False"`, hanya lapisan konvolusi dari model yang diikutsertakan, sehingga model berperan sebagai ekstraktor fitur. Setelah itu, model ResNet50 dasar ditambahkan sebagai lapisan dalam model sekuensial, yang berfungsi sebagai ekstraktor fitur dengan menerima gambar input dan menghasilkan peta fitur dari lapisan konvolusi.

Setelah proses ekstraksi fitur, dilakukan penyesuaian dimensi dengan menambahkan lapisan Flatten yang mengubah keluaran dari lapisan konvolusi menjadi vektor satu dimensi. Hal ini dilakukan untuk mempersiapkan fitur agar dapat dimasukkan ke dalam lapisan terhubung penuh (*fully connected layers*). Selanjutnya, dua lapisan dense ditambahkan di atas lapisan *flatten*. Lapisan dense pertama terdiri dari 256 unit dan menggunakan fungsi aktivasi ReLU, sedangkan lapisan *dense* kedua memiliki jumlah unit yang sama dengan jumlah kelas dalam

dataset. Keluaran dari lapisan terakhir ini diaktivasi menggunakan fungsi softmax untuk menghasilkan probabilitas kelas.

Setelah menentukan arsitektur model, dilakukan kompilasi model dengan menggunakan optimizer Adam, fungsi *loss categorical cross-entropy*, dan akurasi sebagai matrik evaluasi. Ini menentukan cara model akan dilatih dan dievaluasi. Secara keseluruhan, tahapan-tahapan ini mengilustrasikan proses ekstraksi fitur, pelatihan, evaluasi, dan analisis menggunakan model ResNet50, memberikan wawasan tentang kinerja model dan kemampuannya dalam mengklasifikasikan gambar dengan akurat.

4.4 Pembahasan hasil penelitian

Setelah dilakukan preprocessing dan pembelajaran terhadap masing-masing skenario, diperoleh beberapa hasil klasifikasi sebanyak skenario yang digunakan. Model yang dihasilkan merupakan representasi pengetahuan terhadap pembelajaran emosi pada citra wajah manusia. Model yang digunakan dapat mengidentifikasi emosi manusia berdasarkan ciri dari masing-masing kelas. Proses identifikasi citra dilakukan pada layer konvolusi yang dimana pada layer ini dilakukan ekstraksi fitur dari citra yang kemudian selanjutnya akan dilakukan pengecilan dimensi pada *pooling layer* untuk menampilkan ciri pada tiap citra dengan lebih jelas.

Setelah didapatkan fitur pada citra, tahapan selanjutnya yang akan dilakukan adalah proses pengenalan dan pengidentifikasian pada *fully connected layer* yang akan menentukan kelas dari citra wajah. Kemudian akan dilakukan

pengujian untuk mengetahui tingkat akurasi dan kinerja masing-masing model. Hasil pengujian yang dilakukan terhadap model yang dilakukan dapat dilihat pada Tabel 4.2.

Tabel 4.2 Hasil Percobaan

Hasil Percobaan							
Skenario	Time (s)	Training Loss	Testing loss	Training Acc	Testing Acc	Precision	Recall
S1	2712.19	0.1004	1.7128	0.9651	0.6698	0.6700	0.6700
S2	598.72	0.3450	1.0980	0.8741	0.7074	0.7000	0.6800
S3	2295.23	0.0951	1.7361	0.9664	0.6707	0.6800	0.6600
S4	3755.91	0.0692	1.8085	0.9737	0.7158	0.7300	0.6900


Pada Tabel 4.2 diperlihatkan hasil dari pengujian yang telah dilakukan terhadap arsitektur ResNet50 dan VGG19. Tabel hasil eksperimen ini menggambarkan performa berbagai skenario model yang diuji. Terdapat beberapa poin penting yang harus diperhatikan dalam analisis ini. Pertama, waktu yang diperlukan untuk melatih (training) masing-masing skenario berbeda secara signifikan. Skenario S2 memiliki waktu pelatihan yang paling singkat, sekitar 598.72 detik, sementara Skenario S4 memiliki waktu pelatihan terlama, sekitar 3755.91 detik.

Kedua, dalam hal kualitas pelatihan, Skenario S4 menunjukkan training loss yang paling rendah, yaitu 0.0692. Ini mencerminkan kemampuan model ini untuk menyesuaikan diri secara efektif dengan data pelatihan. Skenario S2 juga memiliki training loss yang rendah, yaitu 0.3450. Ketiga, dalam konteks kemampuan generalisasi, Skenario S2 mencapai testing loss yang relatif rendah, sekitar 1.0980, dan akurasi testing yang baik sekitar 0.7074. Terakhir, jika mempertimbangkan

presisi (precision) dan recall, Skenario S4 unggul dengan nilai presisi sekitar 0.7300 dan recall sekitar 0.6900. Ini menunjukkan bahwa model S4 mampu mengidentifikasi positif yang sebenarnya dengan baik dan memiliki kemampuan untuk mencakup sebagian besar instance positif. Meskipun begitu, Skenario S2 juga menunjukkan hasil yang kompetitif dengan nilai presisi sekitar 0.7000 dan recall sekitar 0.6800. Untuk melihat perbandingan hasil yang lebih detail, penulis membuat perbandingan dalam bentuk grafik.

4.4.1 Perbandingan Waktu Komputasi

Dalam penelitian ini dilakukan pencatatan terhadap berapa lama waktu yang dibutuhkan untuk menyelesaikan komputasi pada tiap skenarionya. Berikut adalah grafik perbandingan waktu komputasi pada skenario yang diujikan.



Gambar 4.10 Perbandingan Waktu Komputasi


Pada Gambar 4.10 diatas ditunjukan perbandingan waktu yang digunakan pada tiap skenario yang dilakukan. Grafik diatas merepresentasikan konsumsi waktu yang dibutuhkan untuk menyelesaikan tiap skenario yang diujikan. Pada gambar diatas terlihat bahwa skenario 2 memiliki waktu paling singkat dalam menyelesaikan proses komputasinya selama 598.72. Waktu tertinggi yang dibutuhkan untuk menyelesaikan komputasi berada pada skenario 4 sebesar 3755.9.

Perbedaan waktu komputasi yang terlihat antara skenario-skenario tersebut dapat dijelaskan oleh beberapa faktor kunci. Pertama-tama, kompleksitas tugas menjadi faktor penting yang memengaruhi waktu komputasi. Skenario-skenario yang melibatkan tugas atau komputasi yang lebih kompleks cenderung memerlukan waktu lebih lama untuk menyelesaikannya. Sebagai contoh, skenario 4 mungkin melibatkan pemrosesan data yang lebih rumit atau tugas yang lebih intensif dibandingkan dengan skenario lainnya.

Selain itu, ukuran data juga berpengaruh; skenario dengan data yang lebih besar atau lebih banyak mungkin memerlukan waktu lebih lama untuk diproses. Faktor lain yang signifikan adalah spesifikasi perangkat keras yang digunakan, seperti jumlah inti CPU, RAM, dan pengolahan GPU, yang dapat memengaruhi kecepatan komputasi. Selain itu, optimisasi algoritma dan pemanfaatan teknik paralelisasi juga dapat mempercepat waktu komputasi. Dengan mempertimbangkan dan memahami faktor-faktor ini, peneliti dapat memilih pendekatan yang paling efisien dan relevan dengan kebutuhan mereka untuk menyelesaikan tugas komputasi dengan efisien.

4.4.2 Perbandingan *Training Loss* dan *Testing Loss*

Pada penelitian ini dilakukan perbandingan terhadap nilai *loss/error* pada saat melakukan *training* dan *testing*. Grafik *loss* dari tiap skenario yang dilakukan dapat dilihat pada Gambar 4.11.



Gambar 4.11 Grafik Validation Loss. (a) Loss validation Skenario 1, (b) Loss validation Skenario 2, (c) Loss validation Skenario 3, (d) Loss validation Skenario 4

Pada Gambar 4.11 diatas diperlihatkan grafik dari nilai *loss* untuk tiap skenario yang dilakukan. Pada gambar 4.11 (a) menggunakan ResNet-50 tanpa dilakukan *balancing* pada datasetnya, terlihat pada gambar tersebut skalanya berbeda dibandingkan dengan gambar lainnya, hal tersebut terjadi karena pada saat dilakukan pengujian dengan skenario tersebut nilai *loss* yang dihasilkan sangat tinggi, sehingga skala yang ditampilkan pada grafik berbeda dengan gambar

lainnya. Pada grafik ini, terlihat bahwa skenario menggunakan ResNet-50 tanpa data balancing memiliki skala loss yang jauh lebih tinggi dibandingkan dengan skenario lainnya. Ini menunjukkan bahwa model mengalami kesulitan yang signifikan dalam pelatihan dan mungkin menghasilkan hasil yang sangat buruk dalam hal prediksi. Tingginya loss ini bisa menjadi indikasi bahwa model tidak dapat menyesuaikan diri dengan baik dengan data yang tidak seimbang, di mana beberapa kelas mungkin memiliki jumlah sampel yang jauh lebih sedikit daripada yang lain.

Pada gambar 4.11 (b) menggunakan VGG19 tanpa dilakukan *balancing* pada datasetnya, terlihat pada Grafik ini menunjukkan bahwa pada awalnya, nilai loss pada skenario menggunakan VGG19 tanpa data balancing sangat tinggi, sekitar 1.4 (140%). Namun, ada tren penurunan yang signifikan pada training loss seiring berjalannya waktu, terutama pada epoch ke-45, di mana nilai training loss turun drastis menjadi 0.18 (18%). Ini mungkin menandakan bahwa model secara bertahap mulai memahami pola-pola dalam data pelatihan.

Namun, pada sisi validasi (testing loss), terlihat bahwa pada awalnya terjadi penurunan yang signifikan hingga sekitar epoch ke-15, namun kemudian ada peningkatan kembali pada loss. Hal ini bisa menunjukkan bahwa model kesulitan dalam menggeneralisasi fitur dari data yang tidak seimbang. Model mungkin mulai "menghafal" data pelatihan daripada benar-benar memahami fitur-fitur yang relevan. Ini adalah masalah umum yang dikenal sebagai *overfitting*, di mana model menjadi terlalu sesuai dengan data pelatihan dan kehilangan kemampuan untuk memprediksi data yang belum pernah dilihat sebelumnya.

Pada gambar 4.11 (c) menggunakan ResNet-50 dengan menerapkan *balancing* pada datasetnya. Terlihat perbedaan pada grafik ini, terlihat perbedaan yang mencolok dibandingkan dengan grafik (a) dan (b). Awalnya, nilai training loss sangat tinggi, mencapai 1.6 (160%) pada awal pelatihan. Namun, terjadi penurunan yang sangat signifikan pada epoch ke-71, di mana nilai training loss turun tajam menjadi 0.07 (7%). Ini menunjukkan bahwa model ResNet-50 dengan *balancing* data mampu menyesuaikan diri secara efektif dengan data pelatihan yang telah diubah untuk menciptakan keseimbangan antara kelas-kelas.

Namun, ketika kita memeriksa nilai loss pada validasi (testing loss), terlihat bahwa pada awalnya nilai loss sangat tinggi, mencapai 3.73 (373%) pada epoch pertama. Namun, ada tren penurunan signifikan pada loss testing seiring berjalannya waktu, terutama pada epoch ke-10, di mana nilai loss turun menjadi 0.91 (91%). Namun, pada akhir pelatihan, terjadi peningkatan kembali pada testing loss, mencapai 1.08 (108%). Perbandingan antara training loss dan testing loss ini mengindikasikan bahwa model ini mungkin mengalami *overfitting* pada tahap akhir pelatihan. Meskipun model dapat dengan baik menyesuaikan diri dengan data pelatihan yang seimbang, kemampuannya dalam menggeneralisasi ke data testing belum tentu sebaik yang diinginkan.

Selanjutnya pada Pada gambar 4.11 (d) menggunakan VGG19 dengan menerapkan *balancing* pada datasetnya. Grafik ini memperlihatkan bahwa, meskipun ada penurunan yang signifikan dalam training loss pada tahap awal pelatihan, yaitu dari 1.4 (140%) ke 0.18 (18%) sekitar epoch ke-45, nilai loss testing justru menunjukkan peningkatan yang cukup mencolok. Pada dataset yang telah

diimbangi, testing loss meningkat dari 1.6 (160%) menjadi 3.73 (373%) pada epoch pertama, dan meskipun terjadi penurunan signifikan, tetapi masih tinggi dengan nilai loss mencapai 0.91 (91%) pada epoch ke-10, lalu meningkat lagi menjadi 1.08 (108%) pada akhir pelatihan.

Hal ini bisa dijelaskan dengan efek dari balancing data. Saat dataset diseimbangkan, jumlah sampel dari kelas minoritas ditingkatkan untuk mencocokkan jumlah sampel dari kelas mayoritas. Ini berarti model diberikan lebih banyak data yang sebelumnya mungkin tidak ada atau sangat sedikit. Namun, dengan data yang lebih banyak dan beragam, kompleksitas tugas pelatihan juga meningkat.

Peningkatan nilai loss pada testing mungkin disebabkan oleh kesulitan model dalam mengenali fitur-fitur khusus dari gambar-gambar yang semakin kompleks. Model mungkin cenderung "menghafal" atau mencoba mengatasi noise dalam gambar-gambar ini daripada benar-benar memahami fitur-fitur yang relevan. Secara keseluruhan, strategi balancing data dapat meningkatkan jumlah sampel dari kelas minoritas, tetapi juga dapat menghadirkan tantangan baru dalam hal pelatihan model yang lebih kompleks. Oleh karena itu, pemilihan strategi pelatihan harus dipertimbangkan secara hati-hati untuk mengoptimalkan kinerja model.



Gambar 4.12 Perbandingan Training Loss dan Testing Loss

Gambar 4.12 mempresentasikan hasil perbandingan Training Loss dan Testing Loss berdasarkan empat skenario yang diujikan dalam penelitian tersebut. Hasil pengujian ini memberikan wawasan tentang seberapa baik model atau algoritma yang digunakan dalam skenario-skenario tersebut mampu menggeneralisasi dari data pelatihan ke data uji. Pada skenario 1 dan skenario 3, terlihat bahwa terjadi peningkatan nilai Loss sebesar 0.0233 atau 2.33%. Ini mengindikasikan bahwa model pada kedua skenario tersebut mungkin mengalami sedikit overfitting, yaitu kemampuan model untuk memahami data pelatihan dengan baik, tetapi kesulitan dalam generalisasi pada data yang belum pernah dilihat sebelumnya (data uji).

Sementara itu, perhatian khusus perlu diberikan kepada skenario 2 dan skenario 4 yang menunjukkan peningkatan yang lebih tinggi dalam nilai Loss, yaitu sebesar 0.7105 atau 71.05%. Peningkatan Loss yang signifikan ini mengindikasikan

bahwa model pada kedua skenario ini mungkin mengalami *overfitting* yang lebih serius. *Overfitting* terjadi ketika model "menghafal" data pelatihan dengan sangat baik, tetapi kehilangan kemampuan untuk menggeneralisasi pada data uji, sehingga kinerjanya menjadi buruk.

Penjelasan mengapa *Training Loss* lebih rendah daripada *Validation Loss* adalah karena terjadinya *overfitting* pada model yang digunakan. *Overfitting* adalah masalah umum dalam *machine learning* yang terjadi ketika model terlalu kompleks dan mulai menyesuaikan diri dengan noise atau variasi yang tidak relevan pada data pelatihan, bukan hanya dengan pola yang mendasari data tersebut. Dalam proses pelatihan, model diberikan data pelatihan untuk belajar pola-pola yang ada dalam data tersebut. Ketika model menjadi terlalu kompleks atau memiliki kapasitas yang lebih besar daripada yang diperlukan, ia dapat "menghafal" data pelatihan dengan sangat baik. Akibatnya, *Training Loss*, yang mengukur sejauh mana model cocok dengan data pelatihan, menjadi sangat rendah karena model mampu mengikuti setiap detail data pelatihan.

Namun, masalah timbul ketika model ini diuji pada data yang belum pernah dilihat sebelumnya, seperti data validasi atau data uji. Model yang *overfitting* mungkin gagal dalam menggeneralisasi pola yang dipelajari dari data pelatihan ke data baru. Hasilnya, *Validation Loss*, yang mengukur sejauh mana model dapat melakukan prediksi yang baik pada data baru, menjadi lebih tinggi daripada *Training Loss*. Dalam konteks ini, perbedaan antara *Training Loss* dan *Validation Loss* yang signifikan menunjukkan bahwa model mungkin terlalu rumit dan perlu disederhanakan atau diatur ulang. Solusi untuk mengatasi *overfitting* bisa termasuk

pengurangan kompleksitas model, penambahan regularisasi, atau pengumpulan lebih banyak data pelatihan jika memungkinkan. Tujuannya adalah untuk mencapai keseimbangan antara pelatihan yang baik pada data pelatihan dan kemampuan model untuk melakukan generalisasi yang baik pada data baru, sehingga menghasilkan model yang lebih robust dan akurat.

Analisis tersebut sesuai dengan penelitian yang telah dilakukan sebelumnya, yang dijelaskan dalam artikel berjudul "Addressing Overfitting Problem in Deep Learning-Based Solutions for Next Generation Data-Driven Networks". Dalam penelitian tersebut, peneliti juga mengamati bahwa *overfitting* terjadi ketika model menjadi terlalu kompleks dan lebih fokus pada *noise* dalam data pelatihan, bukan pada pola yang lebih umum (Xiao et al., 2021).


Hasil penelitian tersebut sejalan dengan konsep umum tentang *overfitting* dalam *machine learning* dan *deep learning*. *Overfitting* merupakan tantangan yang sering dihadapi oleh para peneliti ketika mereka mencoba mengembangkan model yang dapat melakukan generalisasi yang baik pada data yang tidak pernah dilihat sebelumnya. Solusi untuk mengatasi *overfitting*, seperti yang diungkapkan dalam artikel tersebut, dapat mencakup pendekatan yang lebih sederhana dalam desain model, penggunaan teknik regularisasi, atau penambahan data pelatihan yang lebih banyak.

Dengan demikian, pemahaman tentang *overfitting* yang diungkapkan dalam penelitian sebelumnya memberikan dasar yang kuat untuk menjelaskan mengapa perbedaan antara *Training Loss* dan *Validation Loss* dapat menjadi tanda keberadaan *overfitting* dalam model *deep learning*, seperti yang dijelaskan dalam

analisis sebelumnya. Hal ini juga menekankan pentingnya mengoptimalkan model dan proses pelatihan agar dapat menghasilkan model yang lebih robust dan mampu melakukan generalisasi yang baik pada berbagai jenis data.

4.4.3 Perbandingan *Training Accuracy* dan *Testing Accuracy*

Dalam penelitian ini, akurasi menjadi parameter paling penting dalam membandingkan arsitektur dengan performa tertinggi. Akurasi dapat menjadi sebuah indikator untuk mengetahui bagus atau tidaknya suatu model dalam memprediksi sebuah data atau objek baru. Grafik akurasi dari tiap skenario yang dilakukan dapat dilihat pada Gambar 4.13.



Gambar 4.13 Grafik Akurasi. (a) Nilai Akurasi Skenario 1, (b) Nilai Akurasi Skenario 2, (c) Nilai Akurasi Skenario 3, (d) Nilai Akurasi Skenario 4

Grafik akurasi pada Gambar 4.13 memberikan pemahaman yang menarik tentang dampak penerapan teknik balancing data terhadap hasil pelatihan model dalam berbagai skenario. Dalam analisisnya, kita dapat mengamati beberapa hal yang menarik. Pertama, dalam skenario yang tidak menggunakan *balancing* data (Gambar 4.13 a dan b), terlihat bahwa nilai akurasi pelatihan (*Training Accuracy*) cenderung tinggi, yang berarti model berhasil "menghafal" data pelatihan dengan baik. Namun, saat kita melihat grafik akurasi validasi (*Testing Accuracy*), perbedaan yang mencolok terlihat. Grafik akurasi validasi dalam skenario-skenario tersebut cenderung tidak stabil, dengan fluktuasi yang signifikan. Hal ini mengindikasikan bahwa model mungkin mengalami kesulitan dalam menggeneralisasi dari data pelatihan ke data uji, yang dapat menjadi tanda *overfitting*.

Di sisi lain, skenario yang menerapkan teknik *balancing* data (Gambar 4.13 c dan d) menunjukkan perbedaan yang mencolok dalam stabilitas grafik akurasi validasi. Grafik tersebut cenderung lebih stabil, dengan fluktuasi yang lebih terkendali. Hal ini mengindikasikan bahwa model dalam skenario ini mampu melakukan generalisasi yang lebih baik pada data yang tidak pernah dilihat sebelumnya. Teknik *balancing* data, seperti peningkatan jumlah data pada kelas minoritas, membantu model untuk mempelajari pola dari setiap kelas dengan lebih seimbang, yang dapat meningkatkan kemampuan model untuk mengenali berbagai jenis data.

Pada pengembangan analisis ini, perlu dicatat bahwa meskipun skenario yang menerapkan teknik balancing data menghasilkan grafik akurasi validasi yang

lebih stabil, dengan fluktuasi yang lebih terkendali, hasil akurasi yang terbatas pada tingkat tertentu, yaitu sekitar 71.58%, menyiratkan beberapa insight penting. Hal ini dapat menjadi indikasi bahwa data yang digunakan dalam penelitian tersebut memiliki kompleksitas yang tinggi. Tingkat akurasi tersebut mungkin mencapai batasan tertentu karena kompleksitas data itu sendiri. Data yang kompleks dapat mengandung variasi yang signifikan, *noise*, atau faktor-faktor lain yang sulit diprediksi. Bahkan dengan teknik *balancing data*, ada batasan pada sejauh mana model dapat memahami dan mengatasi kompleksitas tersebut. Model mungkin masih menghadapi kesulitan dalam membedakan pola-pola yang lebih halus atau variasi kecil dalam data yang tidak relevan.



Gambar 4.14 Training Accuracy dan Testing Accuracy

Hasil nilai akurasi yang terlihat dalam Gambar 4.14 memberikan gambaran yang menarik tentang kinerja model dalam berbagai skenario percobaan. Dalam pengembangan penjelasan ini, kita dapat mengeksplorasi lebih lanjut faktor-faktor

yang memengaruhi perbedaan dalam akurasi antara skenario-skenario tersebut. Pertama, dalam percobaan ini, nilai akurasi tidak mengalami peningkatan yang signifikan dari satu skenario ke skenario lainnya. Ini bisa menunjukkan beberapa hal. Pertama, dataset yang digunakan mungkin memiliki tingkat kompleksitas yang tinggi, sehingga model sulit untuk mencapai tingkat akurasi yang sangat tinggi. Kedua, mungkin diperlukan upaya lebih lanjut dalam hal desain model atau teknik pelatihan untuk mengatasi kompleksitas data yang tinggi ini.

Skenario 4 menonjol sebagai skenario dengan nilai akurasi tertinggi, yaitu 71.58%. Ini dapat disebabkan oleh beberapa faktor, termasuk penggunaan teknik balancing data yang membantu mengatasi ketidakseimbangan kelas dalam dataset. Teknik ini memungkinkan model untuk mempelajari pola dari setiap kelas dengan lebih seimbang, yang dapat Skenario 3 juga mencapai nilai akurasi yang lebih tinggi dibandingkan dengan skenario 1 dan 2, juga karena penerapan teknik balancing data yang sama. Teknik ini membantu meningkatkan akurasi model dengan mengatasi ketidakseimbangan kelas, meningkatkan kemampuan model dalam mengenali berbagai jenis data.

Fakta tersebut sangat relevan dengan konsep umum dalam machine learning, terutama dalam konteks penanganan ketidakseimbangan kelas atau fitur dalam data pelatihan. Konsep ini juga sesuai dengan apa yang dijelaskan dalam buku "The Elements of Statistical Learning." Dalam buku tersebut, penekanan diberikan pada pentingnya menyeimbangkan distribusi kelas atau fitur dalam data pelatihan. Jika distribusi ini tidak seimbang, model cenderung memprioritaskan

kelas atau fitur yang lebih dominan, yang dapat mengakibatkan masalah dalam generalisasi ke data yang belum pernah dilihat sebelumnya.

Teknik-teknik seperti oversampling (penambahan sampel dari kelas minoritas) atau undersampling (pengurangan sampel dari kelas mayoritas) adalah salah satu cara untuk mengatasi ketidakseimbangan ini. Dengan menggunakan teknik-teknik ini, distribusi kelas dapat diubah sehingga setiap kelas memiliki representasi yang lebih seimbang dalam data pelatihan. Ini membantu model untuk mempelajari pola dari setiap kelas dengan lebih baik dan meningkatkan kemampuan model untuk mengenali pola-pola yang muncul pada kelas atau fitur yang kurang umum.

Penerapan teknik *balancing* data, seperti yang dijelaskan dalam buku tersebut, juga dapat mengurangi perbedaan antara *Training Accuracy* (akurasi pelatihan) dan *Testing Accuracy* (akurasi pengujian). Ini karena model tidak hanya mengutamakan kelas atau fitur mayoritas saat melakukan pelatihan, tetapi juga memperhatikan kelas atau fitur minoritas dengan lebih baik. Dalam konteks penelitian ini, penerapan teknik balancing data seperti yang dijelaskan dalam buku "The Elements of Statistical Learning" sesuai dengan temuan bahwa skenario-skenario yang menerapkan balancing data menghasilkan perbedaan yang lebih terkendali antara Training Accuracy dan Testing Accuracy, yang memberikan wawasan yang lebih baik tentang kemampuan model dalam menggeneralisasi dari data pelatihan ke data uji (Hastie et al., 2009).

Temuan dari penelitian yang menunjukkan bahwa penambahan teknik balancing pada dataset dapat meningkatkan hasil akurasi merupakan temuan yang

sangat konsisten dengan penelitian-penelitian sebelumnya dalam bidang *machine learning* dan *data mining*. Hal ini terutama berlaku ketika kita memiliki dataset yang mengalami ketidakseimbangan, di mana beberapa kelas memiliki representasi yang jauh lebih sedikit daripada yang lain. Dalam penelitian yang dilakukan oleh (Masana et al., 2020), penekanannya pada ketidakseimbangan dataset yang dapat menyebabkan performa klasifikasi yang buruk pada kelas minoritas sangat relevan. Ketidakseimbangan ini dapat membuat model cenderung memprioritaskan kelas mayoritas, yang mengakibatkan kesalahan yang tinggi pada kelas minoritas. Teknik *balancing data* seperti *oversampling* atau *undersampling* membantu mengatasi masalah ini dengan memberikan representasi yang lebih seimbang untuk setiap kelas dalam data pelatihan.

Dengan demikian, penelitian Anda mengonfirmasi pentingnya mengatasi ketidakseimbangan dataset dalam pengembangan model klasifikasi yang efektif, dan temuan tersebut sejalan dengan temuan-temuan sebelumnya yang telah dilakukan dalam bidang ini. Hal ini memberikan landasan yang kuat untuk penggunaan teknik *balancing data* sebagai bagian dari strategi pemrosesan data dalam tugas-tugas klasifikasi yang melibatkan dataset yang tidak seimbang.

Untuk memudahkan perbandingan dengan penelitian serupa yang pernah dilakukan dapat dilihat pada Gambar 4.15 yang merupakan grafik perbandingan dengan penelitian terdahulu terkait penelitian yang dilakukan dalam klasifikasi emosi wajah dengan menggunakan dataset FER2013.



Gambar 4.15 Perbandingan Nilai Akurasi dengan Penelitian Sebelumnya

Berdasarkan hasil dari 3 penelitian yang ditampilkan pada Gambar 4.15 diatas, penggunaan *balancing* pada dataset yang digunakan memiliki pengaruh terhadap peningkatan akurasi klasifikasi yang dihasilkan. Penelitian yang dilakukan mengungguli nilai akurasi dari penelitian sebelumnya yang menggunakan 7 kelas emosi wajah yang sama.

Pengembangan penelitian ini menggambarkan kemajuan penelitian dalam klasifikasi emosi wajah menggunakan dataset FER2013, dengan fokus pada pengaruh penerapan teknik *balancing* data terhadap hasil klasifikasi. Dua penelitian yang telah Anda sebutkan, yaitu (Kusuma et al., 2020) dan (Collins Oguine et al., 2022), memberikan pandangan yang menarik tentang bagaimana *balancing* data dapat memengaruhi hasil klasifikasi.

Pada penelitian pertama oleh (Kusuma et al., 2020), penekanannya pada penggunaan balancing data untuk meningkatkan akurasi klasifikasi emosi wajah di dataset FER2013. Hasil penelitian tersebut berhasil mencapai akurasi sebesar 69.40%, yang menunjukkan peningkatan yang signifikan setelah menerapkan teknik balancing. Namun, hal yang menarik adalah bahwa meskipun akurasi tersebut meningkat, hasil klasifikasi masih memiliki kecenderungan tertinggi pada kelas mayoritas. Ini dapat menunjukkan bahwa meskipun teknik balancing membantu meningkatkan akurasi global, model masih lebih cenderung untuk mengenali emosi-emosi yang lebih umum dalam data.

Pada penelitian berikutnya oleh (Collins Oguine et al., 2022), akurasi tertinggi yang berhasil dicapai adalah 70%, yang menunjukkan peningkatan lebih lanjut dari penelitian sebelumnya. Namun, hal yang tetap relevan adalah hasil klasifikasi masih memiliki kecenderungan tertinggi pada kelas mayoritas. Hal ini menggambarkan bahwa, meskipun terdapat peningkatan dalam akurasi, tantangan dalam klasifikasi emosi wajah dengan dataset yang tidak seimbang adalah bagaimana menghadapi kelas-kelas minoritas yang memiliki representasi yang lebih sedikit.

Temuan ini menegaskan pentingnya pemahaman yang mendalam tentang karakteristik data dan tantangan kelas minoritas dalam tugas klasifikasi semacam ini. Meskipun teknik balancing data dapat membantu, penelitian dan pengembangan model yang lebih canggih dan strategi yang lebih cerdas mungkin diperlukan untuk mengatasi tantangan ini. Dalam konteks ini, penelitian-penelitian


ini memberikan landasan yang kuat untuk penelitian masa depan dalam upaya meningkatkan klasifikasi emosi wajah dengan lebih baik.

Pengembangan dari hasil dan pembahasan penelitian yang telah dipaparkan menggarisbawahi pencapaian utama serta arah perkembangan yang masih terbuka dalam studi klasifikasi emosi pada wajah manusia dengan dataset FER2013. Studi ini berhasil mencapai tujuannya dengan menunjukkan bahwa penerapan teknik *balancing* pada dataset mampu meningkatkan hasil akurasi klasifikasi secara signifikan. Hal ini memberikan kontribusi penting terhadap pemahaman praktis dalam penanganan ketidakseimbangan kelas dalam tugas klasifikasi, terutama ketika berurusan dengan dataset yang kompleks seperti dataset emosi wajah.

Meskipun penelitian ini mencapai hasil yang positif, penekanannya juga ditempatkan pada tantangan yang masih ada dalam klasifikasi emosi pada wajah manusia. Anda menggarisbawahi bahwa ini masih merupakan tantangan yang sulit dan memiliki ruang untuk peningkatan lebih lanjut. Poin ini sangat realistis, mengingat klasifikasi emosi adalah tugas yang rumit karena berhubungan dengan interpretasi ekspresi wajah yang bisa sangat subjektif. Selain itu, Anda mencatat pentingnya mengatasi bias dalam klasifikasi emosi. Hal ini adalah hal yang sangat penting, terutama dalam konteks AI dan machine learning, untuk memastikan bahwa model tidak memperkuat bias yang ada dalam data pelatihan.

Dalam keseluruhan, penelitian ini memberikan kontribusi yang berharga dalam pemahaman klasifikasi emosi pada wajah manusia dengan dataset FER2013, dengan menunjukkan bahwa teknik *balancing* data dapat meningkatkan hasil akurasi. Namun, studi ini juga memberikan dorongan untuk penelitian lanjutan

dalam upaya meningkatkan pemahaman kita tentang klasifikasi emosi dan mengatasi tantangan yang ada. Dengan upaya terus-menerus dalam penelitian ini, kita dapat berharap untuk melihat perkembangan lebih lanjut dalam kemampuan kita untuk membaca jenis emosi yang beragam pada wajah manusia dan mengatasi bias yang mungkin ada dalam proses tersebut.



BAB V

PENUTUP

5.1. Kesimpulan

Berdasarkan hasil pada percobaan yang telah dilakukan terhadap dua arsitektur yang digunakan dengan empat skenario percobaan dapat disimpulkan bahwa:

1. Arsitektur dengan hasil tertinggi yang didapatkan untuk klasifikasi emosi wajah manusia adalah VGG19 yang dikombinasikan dengan *balancing* data menggunakan teknik *oversampling*. Nilai akurasi tertinggi yang berhasil didapatkan adalah 71,58%. Arsitektur model yang paling berhasil dalam penelitian ini adalah VGG19. VGG19 adalah salah satu arsitektur Convolutional Neural Network (CNN) yang terkenal dan memiliki kedalaman yang cukup besar. Arsitektur ini terdiri dari 19 lapisan konvolusi dan pooling, yang memungkinkan model untuk memahami fitur-fitur kompleks dalam gambar dengan lebih baik. Selain arsitektur VGG19 yang kuat, penelitian ini juga mengimplementasikan teknik *balancing* data menggunakan *oversampling*. *Oversampling* adalah salah satu metode dalam *balancing* data yang melibatkan penambahan sampel tambahan dari kelas minoritas. Dengan melakukan *oversampling* pada kelas minoritas, dataset menjadi lebih seimbang, dan model memiliki kesempatan yang lebih baik untuk mempelajari pola-pola yang muncul pada kelas

minoritas. Dalam keseluruhan, pencapaian ini menegaskan bahwa pemilihan arsitektur model yang tepat dan penggunaan teknik balancing data dapat memiliki dampak besar dalam meningkatkan kinerja model dalam tugas klasifikasi yang rumit seperti klasifikasi emosi wajah manusia. Ini memberikan kontribusi yang berharga dalam pengembangan solusi untuk membaca dan memahami emosi manusia melalui ekspresi wajah

2. Penggunaan *oversampling* dapat meningkatkan nilai *loss* pada skenario yang menggunakan *balancing* data. Pada skenario 2, yang menggunakan arsitektur VGG19 tanpa menerapkan teknik balancing data, nilai *loss* yang dicapai adalah 1.0980. Ini adalah nilai *loss* yang lebih rendah, yang dapat diinterpretasikan sebagai seberapa baik model berkinerja dalam membuat prediksi yang mendekati label sebenarnya pada data pelatihan. Namun, pada skenario 4, yang menerapkan balancing data menggunakan *oversampling*, nilai *loss* meningkat menjadi 1.8085. Peningkatan nilai *loss* yang terjadi adalah sebesar 0.7105 atau 71.05%. Peningkatan nilai *loss* yang terlihat pada skenario 4 setelah menerapkan balancing data sebenarnya bisa dijelaskan sebagai konsekuensi dari *oversampling*. *Oversampling* meningkatkan jumlah sampel dari kelas minoritas, yang berarti model menjadi lebih terpapar pada variasi dan noise dalam kelas tersebut. Oleh karena itu, model mungkin tidak bisa menghasilkan prediksi yang sangat dekat dengan label sebenarnya pada data pelatihan, yang mengakibatkan peningkatan

nilai loss. Namun, yang menarik adalah meskipun terjadi peningkatan nilai loss, terdapat peningkatan yang signifikan dalam nilai akurasi model setelah penerapan balancing data. Sebelum dilakukan balancing, nilai akurasi pada skenario 2 adalah 0.7074, dan setelah menerapkan balancing pada skenario 4, nilai akurasi meningkat menjadi 0.7158. Ini menunjukkan bahwa meskipun nilai loss meningkat, model tetap berhasil mengidentifikasi emosi dengan lebih baik setelah dilakukan balancing data. Peningkatan nilai akurasi ini dapat dijelaskan oleh fakta bahwa oversampling membantu model untuk lebih baik dalam mengenali pola-pola yang muncul pada kelas minoritas. Meskipun nilai loss naik, model mampu membuat prediksi yang lebih akurat pada kelas minoritas, yang pada gilirannya meningkatkan akurasi secara keseluruhan.

5.2. Saran

Adapun beberapa saran yang dapat direkomendasikan untuk penelitian selanjutnya pada topik penelitian yang sama adalah sebagai berikut.

1. Memaksimalkan penggunaan *fine tuning* agar mendapatkan hasil yang lebih maksimal dengan model yang digunakan. Dalam penelitian selanjutnya, peneliti dapat mempertimbangkan untuk lebih memaksimalkan penggunaan fine tuning. Ini mencakup penyesuaian parameter-model yang sudah dilatih (pre-trained) agar lebih cocok dengan dataset khusus yang digunakan dalam penelitian. Dengan

melakukan fine tuning yang lebih cermat, model dapat menjadi lebih sesuai dengan karakteristik data tertentu dan menghasilkan hasil yang lebih maksimal.

2. Diharapkan pada penelitian berikutnya dapat menambahkan variasi dalam skenario percobaan adalah ide yang bagus. Selain penggunaan ukuran citra yang bervariasi dan pembagian rasio data uji dan data latih, peneliti dapat mempertimbangkan untuk mengganti atau mencampur arsitektur model yang berbeda. Ini dapat memberikan wawasan yang lebih mendalam tentang seberapa efektif berbagai model dan pengaturan dalam tugas klasifikasi emosi wajah.
3. Harapannya, Penelitian selanjutnya dapat mempertimbangkan untuk mengeksplorasi sudut pandang yang berbeda dalam mengidentifikasi emosi wajah manusia. Misalnya, mengintegrasikan informasi kontekstual atau menggunakan pendekatan multi-modal dengan mempertimbangkan ekspresi wajah bersama dengan suara atau bahasa tubuh. Hal ini dapat memberikan hasil yang lebih akurat dan lengkap dalam membaca emosi manusia.

DAFTAR PUSTAKA

PUSTAKA BUKU

- Géron, A. (2017). *Hands-On Machine Learning with Scikit-Learn and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems*. <http://oreilly.com/safari>
- Mohamed Elgendy. (2020). *Deep Learning for Vision Systems*. Manning Publications.
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning*. Springer New York. <https://doi.org/10.1007/978-0-387-84858-7>

PUSTAKA MAJALAH, JURNAL ILMIAH ATAU PROSIDING

- Afaq, S., & Rao, S. (n.d.). *Significance Of Epochs On Training A Neural Network*. www.ijstr.org
- Badrulhisham, N. A. S., & Mangshor, N. N. A. (2021). Emotion Recognition Using Convolutional Neural Network (CNN). *Journal of Physics: Conference Series*, 1962(1). <https://doi.org/10.1088/1742-6596/1962/1/012040>
- Chiurco, A., Frangella, J., Longo, F., Nicoletti, L., Padovano, A., Solina, V., Mirabelli, G., & Citraro, C. (2022). Real-time Detection of Worker's Emotions for Advanced Human-Robot Interaction during Collaborative Tasks in Smart Factories. *Procedia Computer Science*, 200, 1875–1884. <https://doi.org/10.1016/j.procs.2022.01.388>

- Collins Oguine, O., Oguine, K. J., Bisallah, H. I., & Ofuani, D. (2022). *Hybrid Facial Expression Recognition (FER2013) Model for Real-Time Emotion Classification and Prediction*. <https://doi.org/2206.09509>
- Deng, J., Xuan, X., Wang, W., Li, Z., Yao, H., & Wang, Z. (2020). A review of research on object detection based on deep learning. *Journal of Physics: Conference Series*, 1684(1). <https://doi.org/10.1088/1742-6596/1684/1/012028>
- Eastern Washington University, Institute of Electrical and Electronics Engineers, IEEE Computer Society., International Conference on Imaging, V. & P. R. (3rd: 2019: S., & International Conference on Activity and Behavior Computing (1st : 2019 : Spokane, Wash.). (n.d.). *2019 Joint 8th International Conference on Informatics, Electronics & Vision (ICIEV) ; 3rd International Conference on Imaging, Vision & Pattern Recognition (icIVPR) ; International Conference on Activity and Behavior Computing (ABC) : venue: Eastern Washington University, Spokane, Washington, USA ; date: May - June 2, 2019.*
- Ekman, P. (1992). An Argument for Basic Emotions. *Cognition and Emotion*, 6(3–4), 169–200. <https://doi.org/10.1080/02699939208411068>
- Géron, A. (2017). *Hands-On Machine Learning with Scikit-Learn and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems*. <http://oreilly.com/safari>
- Goodfellow, I. J., Erhan, D., Carrier, P. L., Courville, A., Mirza, M., Hamner, B., Cukierski, W., Tang, Y., Thaler, D., Lee, D.-H., Zhou, Y., Ramaiah, C., Feng,

- F., Li, R., Wang, X., Athanasakis, D., Shawe-Taylor, J., Milakov, M., Park, J., ... Bengio, Y. (2013). *Challenges in Representation Learning: A report on three machine learning contests*. <http://arxiv.org/abs/1307.0414>
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning*. Springer New York. <https://doi.org/10.1007/978-0-387-84858-7>
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2016-December*, 770–778. <https://doi.org/10.1109/CVPR.2016.90>
- Hesamian, M. H., Jia, W., He, X., & Kennedy, P. (2019). Deep Learning Techniques for Medical Image Segmentation: Achievements and Challenges. *Journal of Digital Imaging*, 32(4), 582–596. <https://doi.org/10.1007/s10278-019-00227-x>
- Hung, J. C., Lin, K. C., & Lai, N. X. (2019). Recognizing learning emotion based on convolutional neural networks and transfer learning. *Applied Soft Computing Journal*, 84. <https://doi.org/10.1016/j.asoc.2019.105724>
- Ian Goodfellow, Yoshua Bengio, & Aaron Courville. (2016). *Deep learning*. MIT Press.
- Ke, Q., Liu, J., Bennamoun, M., An, S., Sohel, F., & Boussaid, F. (2018). Computer vision for human-machine interaction. In *Computer Vision For Assistive Healthcare* (pp. 127–145). Elsevier Inc. <https://doi.org/10.1016/B978-0-12-813445-0.00005-8>

- Kusuma, G. P., Jonathan, A., & Lim, P. (2020). Emotion recognition on FER-2013 face images using fine-tuned VGG-16. *Advances in Science, Technology and Engineering Systems*, 5(6), 315–322. <https://doi.org/10.25046/aj050638>
- Lagunas, M., & Garces, E. (2017). Transfer Learning for Illustration Classification. *27th Spanish Computer Graphics Conference, CEIG 2017*, 77–85. <https://doi.org/10.2312/ceig.20171213>
- Liu, T., Chen, M., Zhou, M., Du, S. S., Zhou, E., & Zhao, T. (2019). *Towards Understanding the Importance of Shortcut Connections in Residual Networks*. <http://arxiv.org/abs/1909.04653>
- Magherini, R., Mussi, E., Servi, M., & Volpe, Y. (2022). Emotion recognition in the times of COVID19: Coping with face masks. *Intelligent Systems with Applications*, 15. <https://doi.org/10.1016/j.iswa.2022.200094>
- Mahmud, I., Mamun, M., & Abdelgawad, A. (2023). *A Deep Analysis of Transfer Learning Based Breast Cancer Detection Using Histopathology Images*.
- Masana, M., Liu, X., Twardowski, B., Menta, M., Bagdanov, A. D., & van de Weijer, J. (2020). *Class-Incremental learning: survey and performance evaluation on image classification*. <http://arxiv.org/abs/2010.15277>
- Mehendale, N. (2020). Facial emotion recognition using convolutional neural networks (FERC). *SN Applied Sciences*, 2(3). <https://doi.org/10.1007/s42452-020-2234-1>
- Mohamed Elgendy. (2020). *Deep Learning for Vision Systems*. Manning Publications.

- Nan, Y., Ju, J., Hua, Q., Zhang, H., & Wang, B. (2022). A-MobileNet: An approach of facial expression recognition. *Alexandria Engineering Journal*, 61(6), 4435–4444. <https://doi.org/10.1016/j.aej.2021.09.066>
- Rahimzadeh, M., & Attar, A. (2020). A modified deep convolutional neural network for detecting COVID-19 and pneumonia from chest X-ray images based on the concatenation of Xception and ResNet50V2. *Informatics in Medicine Unlocked*, 19. <https://doi.org/10.1016/j.imu.2020.100360>
- Sajjad, M., Ullah, F. U. M., Ullah, M., Christodoulou, G., Alaya Cheikh, F., Hijji, M., Muhammad, K., & Rodrigues, J. J. P. C. (2023). A comprehensive survey on deep facial expression recognition: challenges, applications, and future guidelines. In *Alexandria Engineering Journal* (Vol. 68, pp. 817–840). Elsevier B.V. <https://doi.org/10.1016/j.aej.2023.01.017>
- Siam, A. I., Soliman, N. F., Algarni, A. D., Abd El-Samie, F. E., & Sedik, A. (2022). Deploying Machine Learning Techniques for Human Emotion Detection. *Computational Intelligence and Neuroscience*, 2022. <https://doi.org/10.1155/2022/8032673>
- Vidhya, J. V., & Uthra, R. A. (2021). *Violence detection in videos using Conv2D VGG-19 architecture and LSTM network*.
- Wang, Y., Li, Y., Song, Y., & Rong, X. (2019). Facial expression recognition based on random forest and convolutional neural network. *Information (Switzerland)*, 10(12). <https://doi.org/10.3390/info10120375>
- Xiao, M., Wu, Y., Zuo, G., Fan, S., Yu, H., Shaikh, Z. A., & Wen, Z. (2021). Addressing Overfitting Problem in Deep Learning-Based Solutions for Next

Generation Data-Driven Networks. *Wireless Communications and Mobile Computing*, 2021.

Yingge, H., Ali, I., & Lee, K. Y. (2020). Deep neural networks on chip - A survey. *Proceedings - 2020 IEEE International Conference on Big Data and Smart Computing, BigComp* 2020, 589–592. <https://doi.org/10.1109/BigComp48618.2020.00016>

Zhang, A., Lipton, Z. C., Li, M., & Smola, A. J. (2021). *Dive into Deep Learning*. <http://arxiv.org/abs/2106.11342>

Zhang, H., Jolfaei, A., & Alazab, M. (2019). A Face Emotion Recognition Method Using Convolutional Neural Network and Image Edge Computing. *IEEE Access*, 7, 159081–159089. <https://doi.org/10.1109/ACCESS.2019.2949741>

