

TESIS
ANALISIS ALGORITMA K-NEAREST NEIGHBOR (KNN)
PADA PENGENALAN WAJAH PENYANDANG TUNANETRA
DENGAN ARSITEKTUR FACENET DAN VGG16



disusun oleh

AGUNG BUDI PRASTYO

22.55.2305

Konsentrasi : Business Intelligence

FAKULTAS ILMU KOMPUTER
UNIVERSITAS AMIKOM YOGYAKARTA
YOGYAKARTA

2025

TESIS
ANALISIS ALGORITMA K-NEAREST NEIGHBOR (KNN)
PADA PENGENALAN WAJAH PENYANDANG TUNANETRA
DENGAN ARSITEKTUR FACENET DAN VGG16

ANALYSIS OF THE K-NEAREST NEIGHBOR (KNN)
ALGORITHM ON FACE RECOGNITION FOR BLIND
PERSONS WITH FACENET AND VGG16 ARCHITECTURES

Diajukan untuk memenuhi salah satu syarat mencapai derajat Pascasarjana
Program Studi S2 PJJ Informatika



disusun oleh

AGUNG BUDI PRASTYO

22.55.2305

Konsentrasi : Business Intelligence

FAKULTAS ILMU KOMPUTER
UNIVERSITAS AMIKOM YOGYAKARTA
YOGYAKARTA

2025

HALAMAN PERSETUJUAN

**ANALISIS ALGORITMA K-NEAREST NEIGHBOR (KNN) PADA
PENGENALAN WAJAH PENYANDANG TUNANETRA DENGAN
ARSITEKTUR FACENET DAN VGG16**

**ANALYSIS OF THE K-NEAREST NEIGHBOR (KNN) ALGORITHM ON
FACE RECOGNITION FOR BLIND PERSONS WITH FACENET AND
VGG16 ARCHITECTURES**

yang disusun dan diajukan oleh

Agung Budi Prastyo

22.55.2305

telah disetujui oleh Dosen Pembimbing Tesis
pada tanggal 01 Desember 2025

Dosen Pembimbing,



Prof. Arief Setyanto, S.SI, M.T., Ph.D.

NIK. 190302036

HALAMAN PENGESAHAN

**ANALISIS ALGORITMA K-NEAREST NEIGHBOR (KNN) PADA
PENGENALAN WAJAH PENYANDANG TUNANETRA DENGAN
ARSITEKTUR FACENET DAN VGG16**

**ANALYSIS OF THE K-NEAREST NEIGHBOR (KNN) ALGORITHM ON
FACE RECOGNITION FOR BLIND PERSONS WITH FACENET AND
VGG16 ARCHITECTURES**

yang disusun dan diajukan oleh

Agung Budi Prastyo

22.55.2305

Telah dipertahankan di depan Dewan Penguji
pada tanggal 01 Desember 2025

Susunan Dewan Penguji

Nama Penguji

Dr. Ferry Wahyu Wibowo, S.Si., M.Cs.
NIK. 190302235

Robert Marco, S.T., M.T., Ph.D.
NIK. 190302228

Prof. Arief Setyanto, S.Si., M.T., Ph.D.
NIK. 190302036

Tanda Tangan



Tesis ini telah diterima sebagai salah satu persyaratan
untuk memperoleh gelar Magister Komputer
Tanggal 16 Desember 2025

DEKAN FAKULTAS ILMU KOMPUTER



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

HALAMAN PERNYATAAN KEASLIAN TESIS

Yang bertandatangan di bawah ini,

Nama mahasiswa : Agung Budi Prastyo
NIM : 22.55.2305

Menyatakan bahwa Tesis dengan judul berikut:

ANALISIS ALGORITMA K-NEAREST NEIGHBOR (KNN) PADA PENGENALAN WAJAH PENYANDANG TUNANETRA DENGAN ARSITEKTUR FACENET DAN VGG16

Dosen Pembimbing : Prof. Arief Setyanto, S.Si., M.T., 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 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, 01 Desember 2025

Yang Menyatakan,



Agung Budi Prastyo

KATA PENGANTAR

Puji syukur ke hadirat Tuhan Yang Maha Esa atas segala limpahan rahmat, hidayah, dan karunia-Nya, sehingga penulis dapat menyelesaikan penyusunan tesis yang berjudul "Analisis Algoritma K-Nearest Neighbor (KNN) pada Pengenalan Wajah Penyandang Tunanetra dengan Arsitektur FaceNet dan VGG16".

Tesis ini disusun sebagai salah satu syarat untuk memperoleh gelar Magister Komputer pada Program Studi S2 PJJ Informatika, Fakultas Ilmu Komputer, Universitas AMIKOM Yogyakarta. Penulis menyadari bahwa keberhasilan penyusunan tesis ini tidak lepas dari bantuan, bimbingan, dan dukungan dari berbagai pihak. Oleh karena itu, pada kesempatan ini penulis ingin menyampaikan rasa terima kasih dan penghargaan yang setinggi-tingginya kepada:

1. Prof. Arief Setyanto, S.Si., M.T., Ph.D., selaku Dosen Pembimbing yang dengan sabar telah meluangkan waktu, tenaga, dan pikiran untuk memberikan arahan, bimbingan, serta motivasi berharga selama proses penelitian hingga penyelesaian penulisan tesis ini.
2. Dr. Ferry Wahyu Wibowo, S.Si., M.Cs. dan Robert Marco, S.T., M.T., Ph.D., selaku Dosen Penguji yang telah memberikan saran, kritik, dan masukan yang sangat konstruktif demi penyempurnaan materi dan analisis dalam tesis ini.

Penulis menyadari bahwa tesis ini masih jauh dari kesempurnaan karena keterbatasan pengetahuan dan pengalaman penulis. Oleh karena itu, penulis mengharapkan kritik dan saran yang membangun dari semua pihak demi perbaikan di masa mendatang. Akhir kata, semoga tesis ini dapat memberikan manfaat bagi pengembangan ilmu pengetahuan dan teknologi, khususnya di bidang kecerdasan buatan.

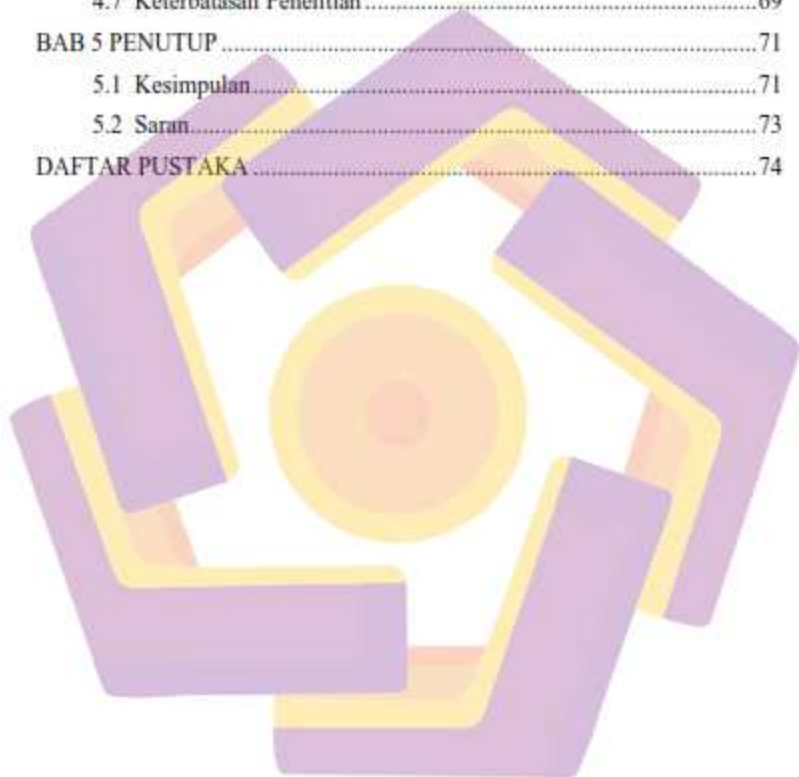
Yogyakarta, 01 Desember 2025

Penulis

DAFTAR ISI


HALAMAN JUDUL	i
HALAMAN PERSETUJUAN	ii
HALAMAN PENGESAHAN	iii
HALAMAN PERNYATAAN KEASLIAN TESIS	iv
KATA PENGANTAR	v
DAFTAR ISI	vi
DAFTAR TABEL	vii
DAFTAR GAMBAR	ix
DAFTAR SINGKATAN	xi
DAFTAR ISTILAH	xii
INTISARI	xiii
ABSTRACT	xiv
BAB 1 PENDAHULUAN	1
1.1 Latar Belakang Masalah	1
1.2 Rumusan Masalah	6
1.3 Batasan Masalah	6
1.4 Tujuan Penelitian	7
1.5 Manfaat Penelitian	7
BAB 2 TINJAUAN PUSTAKA	8
2.1 Tinjauan Pustaka	8
2.2 Keaslian Penelitian	11
2.3 Landasan Teori	13
BAB 3 METODE PENELITIAN	34
3.1 Jenis, Sifat dan Pendekatan Penelitian	34
3.2 Metode Pengumpulan Data	35
3.3 Metode Analisis Data	36
3.4 Alur Penelitian	37
BAB 4 HASIL PENELITIAN DAN PEMBAHASAN	44
4.1 Deskripsi Penelitian	44

4.2 Pengumpulan Data Wajah.....	44
4.3 Prapemrosesan.....	46
4.4 Ekstraksi Fitur Wajah.....	49
4.5 Klasifikasi.....	50
4.6 Uji Model.....	51
4.7 Keterbatasan Penelitian.....	69
BAB 5 PENUTUP.....	71
5.1 Kesimpulan.....	71
5.2 Saran.....	73
DAFTAR PUSTAKA.....	74



DAFTAR TABEL


Tabel 2. 1 Matriks literatur review dan posisi penelitian.....	11
Tabel 4. 1 Sebaran Dataset Penelitian.....	44
Tabel 4. 2 Hasil Uji Model FaceNet-MTCNN.....	52
Tabel 4. 3 Hasil Uji Model FaceNet-Haarcascade	55
Tabel 4. 4 Hasil Uji Model VGG16-MTCNN	57
Tabel 4. 5 Hasil Uji Model VGG16-Haarcascade.....	60
Tabel 4. 6 Hasil Uji Model dengan Data Baru.....	63
Tabel 4. 7 Ringkasan Hasil Confusion Matriks.....	69




DAFTAR GAMBAR

Gambar 2. 1 Citra Warna	19
Gambar 2. 2 Citra Warna (<i>true color</i>)	20
Gambar 2. 3 Citra skala keabuan (<i>greyscale</i>).....	20
Gambar 2. 4 Citra biner dan representasinya dalam data pixel.....	21
Gambar 2. 5 Hasil <i>Thresholding</i>	21
Gambar 2. 6 Logo aplikasi OpenCV	27
Gambar 2. 7 Operasi Konvolusi	29
Gambar 2. 8 Operasi <i>Max-Polling</i>	30
Gambar 2. 9 Struktur P-Net.....	31
Gambar 2. 10 Struktur R-Net	31
Gambar 2. 11 Struktur O-Net.....	31
Gambar 2. 12 Ekstraksi fitur FaceNet.....	32
Gambar 2. 13 <i>Triplet Loss</i>	32
Gambar 3. 1 Alur Penelitian	38
Gambar 3. 2 Struktur direktori dataset.....	39
Gambar 4. 1 Struktur Penyimpanan Dataset	45
Gambar 4. 2 Deteksi Wajah dengan MTCNN	46
Gambar 4. 3 Deteksi Wajah dengan Haarcascade.....	46
Gambar 4. 4 Cropping Citra Wajah dari Hasil Deteksi MTCNN	47
Gambar 4. 5 Cropping Citra Wajah dari Hasil Deteksi Haarcascade.....	47
Gambar 4. 6 Konversi Gambar.....	47
Gambar 4. 7 Hasil Deteksi MTCNN	48
Gambar 4. 8 Hasil Deteksi Haarcascade	49
Gambar 4. 9 Hasil Eksraksi Fitur	50
Gambar 4. 10 Visualisasi 2 Dimensi Uji Model FaceNet-MTCNN.....	53
Gambar 4. 11 Confusion Matriks FaceNet-MTCNN	54
Gambar 4. 12 Visualisasi 2 Dimensi Uji Model FaceNet-Haarcascade	56
Gambar 4. 13 Confusion Matriks FaceNet-Haarcascade.....	56
Gambar 4. 14 Visualisasi 2 Dimensi Uji Model VGG16-MTCNN	58

Gambar 4. 15 Confusion Matriks VGG16-MTCNN59
Gambar 4. 16 Visualisasi 2 Dimensi Hasil Uji Model VGG16-Haarcascade61
Gambar 4. 17 Confusion Matriks VGG16-Haarcascade62



DAFTAR SINGKATAN



KNN	K-Nearest Neighbors
CNN	Convolution Neural Network
DCNN	Deep Convolution Neural Network
VGG16	Visual Geometry Group 16
MTCNN	Multi-task Cascaded Convolutional Network
ABK	Anak Berkebutuhan Khusus
RGB	Red Green Blue
OpenCV	Open Source Computer Vision Library
XML	eXtensible Markup Language
MLP	Multilayer Perceptron
JPEG	Joint Photographic Experts Group
K	n_neighbors
N	Kelas Negatif (Citra Normal)
P	Kelas Positif (Citra Tunanetra)
TN	True Negatif
TP	True Positif
FN	False Negatif
FP	False Positif

DAFTAR ISTILAH

Citra	Representasi gambar digital yang terdiri dari susunan pixel
Vector	Larik satu dimensi yang menyimpan representasi fitur
Array	Struktur data yang menyimpan data terurut
Konvolusi	Operasi filter dalam CNN untuk mengekstrak fitur visual
Embedding	Vektor yang mewakili ciri unik suatu objek untuk dibandingkan
Ekstraksi fitur	Proses mengambil informasi paling penting dari citra
Training	Proses melatih model ML menggunakan data berlabel
Testing	Proses menguji performa model menggunakan data baru
Layer	Lapisan dalam jaringan saraf tiruan
Dataset	Kumpulan data yang dipakai untuk melatih dan menguji model
Tunanetra	Seseorang dengan gangguan penglihatan yang parah
Grayscale	Citra dalam skala abu-abu (hanya intensitas, tanpa warna)
Biner	Citra hitam-putih (hanya dua nilai 0 dan 1)
Pixel	Titik terkecil pembentuk citra digital
thresholding	Ambang batas
Face Detection	Proses menemukan lokasi wajah dalam citra
Face recognition	Proses mengidentifikasi pemilik wajah yang ditemukan.
Direktori	Folder atau lokasi penyimpanan file
n_neighbors	Jumlah tetangga terdekat yang dihitung
Matrix	Susunan angka berbentuk tabel
Rasio	Perbandingan pembagian data
Confusion Metric	Matriks yang menunjukkan hasil benar dan salah prediksi model
Noise	gangguan yang muncul pada citra

INTISARI

Penelitian ini mengkaji efektivitas algoritma K-Nearest Neighbor (KNN) dalam sistem pengenalan wajah penyandang tunanetra menggunakan arsitektur FaceNet dan VGG16. Fokus utama studi adalah mengkomparasi tingkat akurasi kedua arsitektur tersebut dalam mengidentifikasi fitur wajah tunanetra yang memiliki karakteristik khusus, seperti ketidaksempurnaan pada area mata yang sering menjadi kendala deteksi.

Menggunakan pendekatan eksperimental komparatif pada 160 dataset citra wajah, proses penelitian meliputi tahap deteksi wajah menggunakan MTCNN dan HaarCascade, ekstraksi fitur, serta klasifikasi KNN. Untuk menentukan model terbaik, dilakukan uji iterasi nilai K dari 1 hingga 20, di mana nilai K dengan akurasi tertinggi dari iterasi tersebut dipilih sebagai model final.

Temuan riset menunjukkan bahwa pemilihan metode deteksi sangat krusial; MTCNN terbukti superior dengan keberhasilan deteksi 100%, melampaui HaarCascade yang hanya mampu mendeteksi 90% data. Dalam analisis akurasi validasi, kombinasi FaceNet-MTCNN mencatatkan performa puncak 96,88%, namun pengujian pada data gambar baru menunjukkan dinamika berbeda dengan tingkat keberhasilan prediksi sebesar 85% untuk VGG16-MTCNN, 80% untuk VGG16-HaarCascade, 70% untuk FaceNet-MTCNN, dan 55% untuk FaceNet-HaarCascade.

Berdasarkan evaluasi stabilitas dan konsistensi deteksi keseluruhan, disimpulkan bahwa integrasi FaceNet dan MTCNN tetap menjadi model yang paling direkomendasikan untuk pengembangan sistem ini, dengan saran penelitian mendatang untuk menambah jumlah dan memperkaya variasi dataset yang diharapkan dapat meningkatkan generalisasi model pada data baru supaya mendapatkan akurasi prediksi yang lebih baik.

Kata kunci: Pengenalan Wajah, Tunanetra, FaceNet, VGG16, KNN.

ABSTRACT

This study evaluates the effectiveness of the KNN algorithm within a face recognition system for blind persons, utilizing FaceNet and VGG16 architectures. The primary focus of this research is to compare the accuracy of these two architectures in identifying facial features of blind persons, which possess unique characteristics such as imperfections in the eye area that often present challenges for detection.

Employing a comparative experimental approach on a dataset of 160 facial images, the research process encompasses face detection using MTCNN and HaarCascade, feature extraction, and KNN classification. To determine the optimal model, an iterative test of K-values ranging from 1 to 20 was conducted, where the K-value yielding the highest accuracy was selected as the final model.

The findings indicate that the selection of the detection method is crucial; MTCNN proved superior with a 100% detection success rate, surpassing HaarCascade, which only detected 90% of the data. In the validation accuracy analysis, the FaceNet-MTCNN combination achieved a peak performance of 96.88%. However, testing on new image data revealed different dynamics, with prediction success rates of 85% for VGG16-MTCNN, 80% for VGG16-HaarCascade, 70% for FaceNet-MTCNN, and 55% for FaceNet-HaarCascade.

Based on an evaluation of overall stability and detection consistency, it is concluded that the integration of FaceNet and MTCNN remains the most recommended model for the development of this system. Future research is suggested to increase the volume and enrich the diversity of the dataset, which is expected to enhance model generalization on new data and improve prediction accuracy.

Keywords: Face Recognition, Blind Persons, FaceNet, VGG16, KNN.

BAB 1

PENDAHULUAN

1.1. Latar Belakang Masalah

Deteksi wajah merupakan langkah awal dalam proses mengenali fitur wajah. Proses deteksi wajah merupakan hal yang sangat penting karena kualitas deteksi wajah yang baik akan berpengaruh pada proses berikutnya seperti ekstraksi fitur wajah dan proses mengenali suatu wajah. Deteksi wajah merupakan tahap awal yang sangat penting sebelum melakukan proses pengenalan wajah. Deteksi wajah juga dapat didefinisikan sebagai pendeteksian objek tertentu, dalam hal ini objek yang dideteksi atau wajah manusia sering disebut sebagai fitur. Fitur-fitur tersebut meliputi bagian-bagian wajah manusia yang memiliki karakteristik unik, seperti mata, hidung, mulut, pipi, dahi, dan dagu (Satwikayana, Wibowo, & Vendyansyah, 2021). Banyak peneliti yang meneliti di bidang ini karena deteksi untuk mengenali wajah sangat penting dalam banyak aplikasi seperti berbasis konten pengambilan gambar, interaksi manusia dengan computer (*Human Computer Communication*), keamanan sistem, pengenalan wajah dan sistem pengawasan kerumunan manusia (Yusuf, Mohamad, & Sufyanu, 2017).

Untuk mendapatkan hasil yang bagus dalam mengenali wajah saat proses deteksi banyak sekali *noise* yang harus dihadapi. *Noise* (derau) tersebut dapat disebabkan oleh banyak faktor seperti kurangnya pencahayaan saat pengambilan gambar, keterbatasan kamera dalam menangkap gambar bergerak, inferensi gelombang elektromagnetik, dan sebagainya (Kristanto, Riyadi, & Yudi, 2023).

Pada penelitian ini diusulkan dengan dua metode pengenalan wajah yang terkenal, yaitu metode *FaceNet* dan VGG16. Metode yang digunakan dalam sistem *FaceNet* adalah metode *deep learning CNN (Convolutional Neural Network)* yang dilatih dengan fungsi *triplet loss* yang membuat vektor dengan identitas yang sama menjadi semakin serupa (jarak semakin kecil), sedangkan vektor dengan identitas yang berbeda menjadi semakin tidak serupa (jarak semakin jauh). Fokus dari pelatihan model ini adalah untuk membuat *embedding* secara langsung yang merupakan sebuah inovasi penting pada pembuatan sistem *FaceNet* (Christyanto, Jonemaron, & Yudistira, 2022). Sedangkan Karen Simoyan dan Andrew Zisserman membangun VGG16, yang muncul sebagai juara kedua dalam ILSVRC 2014 (Lab 2018). Arsitektur ini menunjukkan bahwa kedalaman jaringan sangat penting untuk menghasilkan kinerja yang tinggi. Dengan kata lain, jaringan CNN yang lebih dalam seharusnya lebih akurat. *Networking* arsitektur VGG16 yang paling baik terdiri dari enam belas lapisan convolutional atau penuh terhubung yang memiliki arsitektur yang sama. Dari lapisan awal hingga lapisan akhir, mereka hanya melakukan konvolusi tiga kali tiga dan pooling dua kali dua.

Beberapa penelitian yang menggunakan metode *FaceNet* adalah penelitian (Cahyini, 2020) dengan hasil untuk memvalidasi model, digunakan validasi silang 5 dan 10 kali lipat. Hasil akurasi *FaceNet* yang diperoleh semakin tinggi dengan akurasi yang sempurna 100%, sedangkan Openface akurasinya hanya 93,33%, namun dalam waktu pembuatan facial fitur (*embedding*), Openface empat kali lebih cepat dari *FaceNet*. Itu implementasi menggunakan model dengan akurasi tertinggi

(*FaceNet*) memiliki hal yang sama hasil sebagai pengujian model yaitu 100% menggunakan ambang batas pengenalan probabilitas 0,25.

Penelitian selanjutnya yang menggunakan metode *FaceNet* adalah (Evelyn, Adipranata, & Gunadi, 2022) yang mendapatkan hasil sistem presensi mahasiswa menggunakan berbasis Android dengan menggunakan *FaceNet* sebagai model untuk sistem pengenalan wajah. Untuk mengukur hasil dari pengenalan wajah menggunakan dan membandingkan nilai hasil dari rumus L2Norm dan *Cosine Similarity* dengan *threshold* berbeda. Hasil dari pengenalan wajah menunjukkan bahwa rumus *Cosine Similarity* paling optimal ketika menggunakan *threshold* 0.5f dengan score terbaik 0.5104218 dengan score akurasi 0.77162087. Sedangkan rumus L2Norm paling optimal ketika menggunakan *threshold* 8.0f dengan score terbaik 5.8973804 dan skor akurasi 5.8973804.

Beberapa penelitian yang menggunakan VGG16 adalah penelitian (Mogan, Lee, Lim, & Muthu, 2022) dengan metode yang diusulkan memperoleh akurasi 99,10%, yang menunjukkan skalabilitas dan kemampuan generalisasi dari VGG16 yang diusulkan metode. Kinerja yang baik juga tidak lepas dari teknik yang diterapkan yaitu penyempurnaan model terlatih, *perceptron multilayer*, penghentian awal, *dropout* teknik, dan normalisasi *batch*.

Penelitian lainnya yang menggunakan arsitektur VGG16 adalah penelitian (Margolang, Riyadi, Rosnelly, & Wanayumini, 2023) yang mendapatkan hasil kombinasi fungsi aktivasi ReLu dengan fungsi optimasi Adam yang dirancang menggunakan tiga hidden layer dengan konfigurasi 50-50-50 neuron menghasilkan model terbaik. Nilai *accuracy* sebesar 98,1%, *precision*

sebesar 98,1%, dan *recall* sebesar 98,1% membuktikan bahwa model tersebut memiliki performa yang lebih unggul dibandingkan model lainnya. Dari hasil evaluasi klasifikasi juga dapat disimpulkan bahwa jumlah neuron yang semakin banyak pada masing-masing *hidden layer* tidak mempengaruhi peningkatan performa klasifikasi. Hal ini terlihat dari model dengan kombinasi fungsi aktivasi RBF dan fungsi optimasi Adam, performa terbaik diperoleh pada model dengan jumlah neuron 50. Sementara pada model dengan kombinasi fungsi aktivasi RBF dan fungsi optimasi SGD, performa terbaik diperoleh pada model dengan jumlah neuron 100.

Pada saat mengenali wajah terdapat bagian-bagian wajah yang akan dideteksi seperti bagian depan dari kepala, dalam bagian wajah terdiri dari hidung, mulut, mata, pipi, dahi, bibir dan dagu. Kegunaan dari itu sendiri meliputi, ekspresi wajah, penampilan, dan identitas diri. Dalam wajah manusia tidak satupun yang mempunyai kesamaan yang mutlak, bahkan pada seseorang yang kembar sekaligus (Rahmawati, Pratama, & Wibisono, 2021). Hal yang terpenting dalam pengenalan wajah adalah ekstraksi semua informasi yang relevan pada citra wajah. Ekstraksi fitur ciri wajah dibagi menjadi dua, yaitu Holistik (mengenal wajah secara keseluruhan) dan Parsial (mengenal wajah secara bagian per bagian, misalnya mata, hidung, mulut dan sebagainya) (Budi, Inna, & Maulana, 2016).

Dalam penelitian sebelumnya belum terdapat deteksi wajah pada tunanetra. Tunanetra dapat dikategorikan menjadi dua yaitu buta total dan kurang penglihatan (*low vision*). Karena pada tunanetra terdapat bagian wajah yang tidak sempurna yaitu bagian mata yang mungkin akan menghambat dalam proses deteksi.

Berdasarkan penelitian sebelumnya, penelitian ini menggunakan subjek tunanetra untuk mengenali wajah dengan menggunakan metode CNN dengan arsitektur *FaceNet* dan VGG16. Penelitian sistem pengenalan wajah dengan metode CNN dengan arsitektur *FaceNet* menunjukkan bahwa tingkat akurasi pelatihan data dengan metode CNN dan *FaceNet* mencapai 100%, tetapi intensitas pencahayaan sangat mempengaruhi kemampuan sistem dalam mendeteksi dan mengenali wajah. Pada pencahayaan 99 lux, sistem tidak mampu mengenali wajah dari jarak 25 cm hingga 1 meter. Pada 108 lux, sistem menunjukkan konsistensi yang lebih baik dengan deteksi hingga 1 meter, meskipun kepercayaan prediksi menurun di atas jarak tersebut. Pada 118 lux, meskipun deteksi wajah lebih baik, kualitas pembacaan wajah menurun di atas jarak 1 meter. Sistem ini terdiri dari tiga kamera dan tiga pintu portal. *Servo* pada setiap pintu portal berhasil menggerakkan pintu berdasarkan hasil pengenalan wajah. Jika wajah terdeteksi, *servo* bergerak 90 derajat untuk membuka pintu, dan tetap pada posisi awal jika wajah tidak terdeteksi. Hasil penelitian ini menunjukkan bahwa sistem yang dikembangkan memberikan solusi efektif dan nyaman untuk kontrol akses otomatis, meningkatkan keamanan, dan mengurangi risiko tindakan kriminal, meskipun dipengaruhi oleh jarak dan kondisi pencahayaan (Fahreza, Rabi, & Dirgantara, 2024).

Penelitian yang menggunakan metode VGG16 adalah penelitian (Prastiwi, 2024) dengan hasil terbukti efektif dalam mengenali fitur wajah dan memberikan rekomendasi kacamata yang dipersonalisasi. Hasil eksperimen menunjukkan bahwa model yang dikembangkan mampu mencapai akurasi yang baik, dengan akurasi validasi mencapai 93%. Grafik pelatihan dan validasi juga menunjukkan

peningkatan akurasi seiring dengan jumlah epoch. Setelah model dianggap siap, langkah terakhir adalah mengintegrasikannya ke dalam sistem web sehingga dapat diakses secara *online*. Hal tersebut menimbulkan pertanyaan bagaimana hasil akurasi pengenalan wajah pada penyandang tunanetra menggunakan metode KNN dengan arsitektur FaceNet dan VGG16.

1.2. Rumusan Masalah

Berdasarkan identifikasi latar belakang masalah yang telah dipaparkan, penelitian ini berfokus pada pengenalan wajah penyandang tunanetra menggunakan pendekatan pembelajaran mesin berbasis deep learning. Untuk mengarahkan penelitian secara sistematis, dirumuskan beberapa pertanyaan penelitian (*research questions*) sebagai berikut:

- a. Berapa tingkat akurasi yang dicapai dalam mengenali wajah tunanetra menggunakan metode KNN dengan arsitektur FaceNet dan VGG16?
- b. Bagaimana perbandingan akurasi metode KNN dengan arsitektur FaceNet dan VGG16 dalam mengenali penyandang tunanetra?

1.3. Batasan Masalah

Untuk memfokuskan penelitian ini, beberapa batasan masalah ditetapkan sebagai berikut:

- a. Penelitian ini hanya menggunakan dua arsitektur yaitu FaceNet dan VGG16 untuk pengenalan wajah serta KNN sebagai metode klasifikasinya.

- b. Metode deteksi wajah yang digunakan dibatasi pada MTCNN dan HaarCascade.
- c. Evaluasi model dilakukan menggunakan metrik akurasi, precision, recall, dan F1-score.
- d. Penelitian fokus pada analisis perbandingan kedua arsitektur dalam mengenali wajah penyandang tunanetra.

1.4. Tujuan Penelitian

Tujuan penelitian ini adalah sebagai berikut :

- a. Mengetahui tingkat akurasi mengenali wajah tunanetra dengan metode KNN pada arsitektur FaceNet dan VGG16
- b. Mengetahui perbandingan tingkat akurasi metode KNN dari arsitektur FaceNet dan VGG16 pada orang normal dan penyandang tunanetra

1.5. Manfaat Penelitian

Manfaat penelitian ini adalah sebagai berikut :

- a. Mengetahui tingkat keakuratan metode KNN dengan arsitektur FaceNet dan VGG16 dalam mengenali wajah tunanetra
- b. Penelitian ini dapat dimanfaatkan untuk sistem keselamatan dan interaksi manusia dengan komputer
- c. Dapat digunakan untuk penelitian lebih lanjut dalam mengenali wajah penyandang tunanetra

BAB 2

TINJAUAN PUSTAKA

2.1. Tinjauan Pustaka

Sebelumnya sudah ada penelitian yang membahas mengenai analisis akurasi metode CNN dengan arsitektur *FaceNet* dan VGG16 dalam mengenali wajah tunanetra. Berikut ini adalah beberapa penelitian yang terkait dengan hal tersebut. Penelitian yang menggunakan metode *FaceNet* adalah penelitian (Sugeng & Barus, 2023) yang mendapatkan hasil pengujian *training* model *FaceNet* telah menghasilkan model terbaik dengan akurasi 97,48% terhadap 6107 *dataset* dan untuk testing gambar didapat akurasi gambar sebesar 97% dengan citra uji 412 dan untuk pengujian secara *realtime* didapat hasil untuk kondisi wajah normal sebesar 90%, kondisi wajah menggunakan kacamata sebesar 83%, kondisi wajah menggunakan masker sebesar 70%, kondisi wajah menggunakan topi sebesar 81% dan kondisi wajah menggunakan semua aksesoris sebesar 66%. Dengan begitu sistem telah berjalan sesuai dengan yang diharapkan dan metode *Facenet* telah dapat diimplementasikan secara *realtime* pada sistem pengenalan wajah dengan akurasi pengenalan wajah yang sangat baik.


Penelitian lainnya yang menggunakan metode *FaceNet* adalah penelitian (Evelyn, Adipranata, & Gunadi, 2022) yang mendapatkan hasil sistem presensi mahasiswa menggunakan berbasis Android dengan menggunakan *FaceNet* sebagai model untuk sistem pengenalan wajah. Untuk mengukur hasil dari pengenalan wajah menggunakan dan membandingkan nilai hasil dari rumus L2Norm dan

Cosine Similarity dengan *threshold* berbeda. Hasil dari pengenalan wajah menunjukkan bahwa rumus *Cosine Similarity* paling optimal ketika menggunakan *threshold* 0.5f dengan score terbaik 0.5104218 dengan score akurasi 0.77162087. Sedangkan rumus L2Norm paling optimal ketika menggunakan *threshold* 8.0f dengan score terbaik 5.8973804 dan skor akurasi 5.8973804.

Selanjutnya adalah penelitian dari (Tanuwijaya & Roseanne, 2021) arsitektur modifikasi VGG 16 memiliki 10-layer yang terdiri dari 7-layer *convolution* dan 3-layer *fully connected*. Untuk fase latih model modifikasi VGG 16 ini menggunakan *dataset* rempah yang disediakan oleh Kaggle. Validasi model yang digunakan adalah akurasi, *loss*, *precision*, dan *recall* untuk membandingkan model mana yang memiliki nilai yang terbaik. Untuk model modifikasi VGG 16 yang dibuat untuk melakukan klasifikasi, mendapatkan hasil evaluasi rata-rata akurasi sebesar 81%, nilai *recall* sebesar 76%, dan nilai *precision* sebesar 81% untuk fase *training* dan untuk fase validasi, akurasi sebesar 85%, nilai *recall* sebesar 80%, dan nilai *precision* sebesar 84%.

Selanjutnya adalah penelitian dari (Wardani, Suryalim, Engel, & Christian, 2023) dengan hasil untuk akurasi model disimpulkan bahwa proses MCLAHE meningkatkan akurasi model terjadi pada skenario yaitu, dataset Yale+MCLAHE untuk kedua model mendapatkan *macro f1-score* tertinggi pada optimizer AdaDelta, untuk model *Inception* skor 0.97 dan VGG 0.90. Dataset Komnet+MCLAHE mendapatkan *macro f1-score* tertinggi pada model VGG16 optimizer AdaGrad 0.94 sedangkan *Inception* tertinggi adalah pada optimizer AdaGrad dan AdaDelta 0.98. Secara keseluruhan hasil pengujian akurasi, model

Yale+MCLAHE dan Komnet+MCLAHE memiliki tingkat volatilitas lebih rendah dibandingkan dengan *dataset origin*. Disimpulkan bahwa metode MCLAHE ini membantu mengurangi tingkat overfitting suatu model.



2.2. Keaslian Penelitian

Tabel 2. 1 Matriks literatur review dan posisi penelitian

Analisis Metode CNN dengan Arsitektur FaceNet dan VGG16 dalam Mengenali Wajah Penyandang Tunanetra

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
1	Face Recognition Using Facenet Deep Learning Network for Attendance System	Rutuja Bankar, Nikita Bargat, Isha Hanmante, Prof. Hemlata Dakore. IJSRCSEIT. 2022	Mengimplementasikan sistem kehadiran otomatis menggunakan teknologi pengenalan wajah dengan metode FaceNet.	Metode FaceNet, dikombinasikan dengan MTCNN (Multi-Task Cascaded Convolutional Neural Network) dan SVM (Support Vector Machine), berhasil mencatat kehadiran secara otomatis dengan akurasi yang sangat baik.		Dataset yang digunakan hanya citra wajah orang tanpa gangguan penglihatan.
2	Face and Face-mask Detection System using VGG-16 Architecture based on Convolutional Neural Network	Chamandeep Vimal & Neeraj Shirivastava. IJCA. 2022.	Mengembangkan model deteksi wajah dan masker wajah berbasis arsitektur VGG-16 pada Convolutional Neural Network (CNN) untuk	Dapat mengidentifikasi wajah dengan atau tanpa masker dengan akurasi tinggi (93%).	Peneliti menyarankan untuk meningkatkan presisi dan efisiensi model dengan memperbesar ukuran dataset hingga sekitar 25.000 gambar.	Hanya mengidentifikasi dengan atau tanpa masker.

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
			deteksi wajah real-time, termasuk deteksi wajah yang tertutup masker.			
3	Pengenalan Ekspresi Wajah Berbasis Convolutional Neural Network Dengan Model Arsitektur VGG16	Rizqy Joventus Gunawan, Budhi Irawan, Casi Setianingsih. EPROC. 2021.	Meningkatkan akurasi pengenalan emosi manusia pada dataset FER2013 yang terdiri dari 35.887 gambar wajah dalam tujuh kategori emosi	Hasil penelitian menunjukkan bahwa model Modified VGG16 berhasil mencapai akurasi 70,63% pada data uji, yang lebih tinggi dibandingkan dengan penelitian sebelumnya yang menggunakan model VGG16 dan dataset FER2013.	Meningkatkan akurasi dan efisiensi model, penelitian mendatang disarankan untuk menggunakan dataset yang lebih beragam dan besar, serta mencoba algoritma pengoptimalan lain.	Dataset yang digunakan merupakan wajah tanpa gangguan penglihatan, serta digunakan untuk mengenali ekspresi wajah.

2.3. Landasan Teori

Terdapat beberapa landasan teori yang dibutuhkan pada penelitian ini, mulai dari landasan teori tunanetra, citra, pengolahan citra, deteksi wajah, pengenalan wajah, database, login, dan metode CNN, arsitektur *FaceNet*, dan VGG16.

2.3.1. Tunanetra

Tunanetra merupakan salah satu tipe anak berkebutuhan khusus (ABK), yang mengacu pada hilangnya fungsi indera visual seseorang. Untuk melakukan kegiatan kehidupan atau berkomunikasi dengan lingkungannya mereka menggunakan indera non-visual yang masih berfungsi, seperti indera pendengaran, perabaan, pembau, dan perasa (pengecapan). Definisi Tunanetra menurut Kaufman & Hallahan adalah individu yang memiliki lemah penglihatan atau akurasi penglihatan kurang dari 6/60 setelah dikoreksi atau tidak lagi memiliki penglihatan. Karena tunanetra memiliki keterbatasan dalam indera penglihatan maka proses pembelajaran menekankan pada alat indera yang lain yaitu indera peraba dan indera pendengaran.

2.3.1.1. Klasifikasi Tunanetra

a. Berdasarkan Tingkat Ketajaman Penglihatan

Tingkat ketajaman penglihatan dihasilkan dari TES SNELLEN, yang dikelompokkan menjadi berbagai tingkatan. Subjek duduk dengan jarak 20 kaki (1 kaki = 12 inci, 1 inci = 2,5 cm) dari sejumlah deretan huruf-huruf balok. Semua huruf dalam satu deret berukuran sama dan ukuran huruf mengecil semakin kebawah deretannya. Hasil tes Snellen dalam mengklasifikasi tingkat ketajaman penglihatan:

- 1) Ketajaman penglihatan 20/20 feet atau 6/6 meter menunjukkan bahwa penglihatannya normal atau tidak ada gangguan.
 - 2) Tunanetra dengan ketajaman penglihatan 6/20 m - 6/60 m atau 20/70 feet - 20/200 feet. Tingkat ketajaman penglihatan seperti ini pada umumnya dikatakan tunanetra (*low vision*). Pada taraf ini, para penderita masih mampu melihat dengan bantuan alat khusus.
 - 3) Tunanetra dengan ketajaman penglihatan antara 6/60 m atau 20/200 feet atau kurang. Tingkat ketajaman seperti ini sudah dikatakan tunanetra berat atau secara umum dapat dikatakan buta (*blind*). Kelompok ini masih dapat diklasifikasikan lagi menjadi berikut ini:
 - Kelompok tunanetra yang masih dapat melihat gerakan tangan.
 - Kelompok tunanetra yang hanya dapat membedakan terang dan gelap.
 - 4) Tunanetra yang memiliki visus 0 sudah tidak mampu lagi melihat rangsangan cahaya atau dapat dikatakan tidak dapat melihat apapun. Kelompok ini sering disebut buta total (*totally blind*).
- b. Berdasarkan Kemampuan Daya Penglihatan
- 1) Tunanetra ringan (*defective vision/low vision*); yakni mereka yang memiliki hambatan dalam penglihatan akan tetapi mereka masih dapat mengikuti program-program pendidikan dan mampu melakukan pekerjaan/kegiatan yang menggunakan fungsi penglihatan.
 - 2) Tunanetra setengah berat (*partially sighted*); yakni mereka yang kehilangan sebagian daya penglihatan, hanya dengan menggunakan kaca pembesar mampu mengikuti pendidikan biasa atau mampu membaca tulisan yang bercetak tebal.

3) Tunanetra berat (*totally blind*); yakni mereka yang sama sekali tidak dapat melihat.

c. Berdasarkan Saat Terjadinya Ketunaan

1) Tunanetra sebelum dan sejak lahir yang terdiri dari orang yang mengalami ketunanetraan pada saat dalam kandungan atau sebelum usia satu tahun.

2) Tunanetra balita yaitu orang yang mengalami ketunanetraan pada saat ia berusia dibawah tiga tahun.

3) Tunanetra balita Tunanetra balita yaitu orang yang mengalami ketunanetraan pada saat ia berusia antara 3-5 tahun.

4) Tunanetra pada usia sekolah yang meliputi anak yang mengalami ketunanetraan pada usia anak 6 -12 tahun.

5) Tunanetra remaja adalah orang yang mengalami ketunanetraan pada saat usia remaja atau antara usia 13-19 tahun.

6) Tunanetra dewasa yaitu orang yang mengalami ketunanetraan pada usia dewasa atau usia 19 tahun keatas.

d. Berdasarkan Adaptasi Pendidikan

Klasifikasi tunanetra ini tidak didasarkan pada hasil tes ketajaman tetapi didasarkan adaptasi/penyesuaian pendidikan khusus yang sangat penting dalam membantu mereka belajar atau diperlukan dalam menentukan pelayanan pendidikan yang sesuai dengan kemampuan penglihatannya. Klasifikasi ini dikemukakan oleh Kirk, yaitu sebagai berikut:

1) Ketidakmampuan melihat taraf sedang

2) Ketidakmampuan melihat taraf berat

3) Ketidakmampuan melihat taraf sangat berat

2.3.1.2. Gejala Tingkah Laku

Gejala tingkah laku yang tampak dalam mengenal anak yang mengalami gangguan penglihatan secara dini adalah sebagai berikut:

- 1) Menggosok mata secara berlebihan.
- 2) Menutup atau melindungi mata sebelah
- 3) Memiringkan kepala atau mencondongkan kepala ke depan.
- 4) Sukar membaca atau dalam mengerjakan pekerjaan lain yang sangat memerlukan penggunaan mata.
- 5) Berkedip lebih banyak daripada biasanya atau lekas marah apabila mengerjakan suatu pekerjaan. ' Membawa bukunya ke dekat mata.
- 6) Tidak dapat melihat benda-benda yang agak jauh.
- 7) Menyipitkan mata atau mengkerutkan dahi.
- 8) Tidak tertarik perhatiannya pada objek penglihatan atau pada tugas-tugas yang memerlukan penglihatan seperti melihat gambar atau membaca.
- 9) Janggal dalam bermain yang memerlukan kerjasama tangan dan mata.
- 10) Menghindar dari tugas-tugas yang memerlukan penglihatan atau memerlukan penglihatan jarak jauh

2.3.1.3. Faktor Penyebab Tunanetra

a. Faktor Internal

Faktor internal merupakan penyebab ketunanetraan yang timbul dari dalam diri individu, yang sering disebut juga faktor keturunan. Faktor ini kemungkinan besar terjadi pada perkawinan antarkeluarga dekat dan perkawinan antartunanetra.

b. Faktor Eksternal

- 1) Penyakit *rubella* dan *syphilis* merupakan suatu penyakit yang disebabkan oleh virus yang sering berbahaya dan sulit di diagnosa secara klinis.
- 2) *Glaukoma* merupakan suatu kondisi dimana terjadi tekanan yang berlebihan pada bola mata. Kondisi ini ditandai dengan pembesaran pada bola mata, kornea menjadi keruh, banyak mengeluarkan air mata, dan merasa silau.
- 3) *Diabetik Retinopathy* yaitu gangguan pada retina yang disebabkan karena diabetes. Retina penuh dengan pembuluh-pembuluhdarah dan dapat dipengaruhi oleh kerusakan sistem sirkulasi hingga merusak penglihatan
- 4) *Retinoblastoma* merupakan tumor ganas yang terjadi pada retina dan sering ditemukan pada anak-anak.
- 5) *Trachoma* yaitu penyakit mata karena virus *chilimidezoon trachomatis*.
- 6) *Catarac* yaitu penyakit mata yang menyerang bola mata sehingga lensa mata menjadi keruh, akibatnya terlihat dari luar mata menjadi putih.
- 7) *Macular Degeneration* adalah kondisi umum yang agak baik, dimana daerah tengah dari retina secara berangsur memburuk. Anak dengan retina degenerasi masih memiliki penglihatan *perifer* akan tetapi kehilangan kemampuan untuk melihat secara jelas objek-objek di bagian tengah bidang penglihatan.

- 8) Kekurangan vitamin A (*Xerophthalmia*) Vitamin A berperan dalam ketahanan tubuh terhadap infeksi. Kekurangan vitamin A akan menyebabkan kerusakan pada matanya, yaitu kerusakan pada sensitivitas retina terhadap cahaya (rabun senja) dan terjadi kekeringan pada konjungtiva bulbi yang terdapat pada celah kelopak mata, disertai pengerasan dan penebalan pada epitel.
- 9) Terkena zat kimia Zat-zat kimia juga dapat merusak apabila penggunaannya tidak hati-hati.
- 10) Kecelakaan benturan keras mengenai syaraf mata atau tekanan yang keras terhadap bola mata, dapat menyebabkan gangguan penglihatan, bahkan ketunanetraan.

2.3.2. Citra

Citra merupakan suatu *representasi* (gambar), kemiripan, atau imitasi dari suatu objek. Citra sebagai keluaran suatu sistem perekaman data dapat bersifat optik berupa foto, bersifat analog berupa sinyal-sinyal video seperti gambar pada monitor televisi, atau bersifat digital yang dapat langsung disimpan pada suatu media penyimpanan. Secara harfiah, citra (*image*) merupakan gambar pada bidang dwimatra (dua dimensi). Jika dilihat dari sudut pandang matematis, fungsi menerus (*continue*) dari suatu intensitas cahaya pada bidang dwimatra merupakan sebuah citra. Sumber cahaya yang menerangi objek, kemudian objek memantulkan kembali sebagai dari berkas cahaya tersebut. Pantulan cahaya tersebut kemudian ditangkap oleh alat-alat optik, seperti mata pada manusia, kamera, pemindai (*scanner*), dan sebagainya. Sehingga citra yang terekam merupakan sebuah bayangan objek.

Citra pada beberapa standar umumnya merupakan tampilan suatu titik yang

berada pada ruang tiga dimensi. Ada beberapa standar yang digunakan pada citra antara lain RGB (*Red, Green, Blue*), HSV (*Hue, Saturation, Value*) dan HLS (*Hue, Luminosity, Saturation*). Standar yang akan digunakan pada penelitian ini adalah RGB yang memiliki tiga indeks warna yang terdiri dari merah, hijau, dan biru. Indeks masing-masing warna memiliki antara 0-255 atau 0-256 bit. Dari citra berwarna yang memiliki tiga ruang dimensi dapat disederhanakan menjadi satu dimensi grayscale. *Grayscale* adalah citra keabuan yang memiliki nilai antara 0-255. Nilai tersebut menunjukkan tingkat derajat keabuan atau kecerahan dari citra (0 = hitam / gelap dan 255 = putih / terang). Untuk mengkonversi dari citra RGB ke *Grayscale* dapat dilakukan dengan perhitungan mencari nilai rata-rata antara ketiga indeks dalam citra RGB. Dari hasil konversi citra ke dalam RGB maka nilai dalam indeks Grayscale di asumsikan mewakili nilai dan informasi yang terkandung dalam citra RGB.

a. Citra Warna

Citra berwarna direpresentasikan dalam beberapa kanal (*channel*) yang menyatakan komponen-komponen warna penyusunnya.



Gambar 2. 1 Citra Warna

Banyaknya kanal yang digunakan tergantung pada model warna yang akan digunakan pada citra tersebut. Kemudian intensitas suatu titik pada sebuah citra berwarna adalah suatu kombinasi dari tiga intensitas yaitu suatu derajat keabuan

merah ($f_{merah}(x,y)$), hijau ($f_{hijau}(x,y)$), dan biru ($f_{biru}(x,y)$) (Wiryadinata, Sagita, Wardoyo, & Priswanto, 2016).

b. Citra Warna *Berindeks*

Pada format citra warna indeks merupakan suatu format yang memberikan informasi setiap titik yang merupakan indeks dari suatu tabel yang berisi informasi warna yang tersedia, yang disebut palet warna (*color map*). Adapun untuk gambar warna citra berindeks seperti dibawah ini:



Gambar 2. 2 Citra Warna (*true color*)

Jumlah bit yang dibutuhkan untuk mendapatkan informasi setiap titik bergantung pada jumlah warna yang tersedia dalam palet warna.

c. Citra *Grayscale*

Grayscale merupakan warna-warna pixel yang memiliki rentang gradiasi warna hitam dan putih.



Gambar 2. 3 Citra skala keabuan (*greyscale*)

Derajat keabuan merupakan format pada citra ini, karena terdapat warna abu-abu diantara warna minimum (hitam) dan warna maksimum (putih) (Wiryadinata, Sagita, Wardoyo, & Priswanto, 2016).

d. Citra Biner

Suatu citra biner hanya memiliki dua nilai keabuan yaitu 0 dan 1. Maka 1 bit sudah cukup untuk merepresentasikan nilai pixel.



Gambar 2. 4 Citra biner dan representasinya dalam data pixel

Citra biner didapat dari proses pemisahan pixel berdasarkan derajat keabuan yang dimilikinya. Pada proses pemineran dilakukan dengan cara membulatkan ke atas ataupun ke bawah untuk setiap nilai setiap nilai suatu keabuan dari pixel yang berada di atas atau bawah harga ambang. *Thersholding* adalah suatu metode untuk menentukan besarnya nilai ambang. Apabila nilai yang terdeteksi masih didalam nilai batas ambang maka bias diumpankan nilainya 1 (putih). Namun apabila nilai diluar ambang batas maka diumpankan nilai tersebut 0 (hitam). Maka hasil citra setelah di *thresholding* tersebut akan hitam putih karena terdapat batas ambang (Wiryadinata, Sagita, Wardoyo, & Priswanto, 2016).



Gambar 2. 5 Hasil *Thresholding*

2.3.3. Pengolahan Citra

Pengolahan citra digital (*Digital Image Processing*) merupakan ilmu yang mempelajari tentang teknik-teknik mengolah citra. Sebuah citra yang dimaksud adalah gambar yang diam (foto) ataupun gambar yang bergerak yang berasal dari *webcam*/kamera. Yang dimaksud digital disini merupakan pengolahan citra atau gambar yang dilakukan secara digital menggunakan komputer. Pada dasarnya sebuah sistem pengolahan citra terdiri dari objek yang akan diproses, yang akan digunakan untuk merepresentasikan objek dalam bentuk citra digital, akan menghasilkan suatu citra digital baru untuk dianalisa, sehingga proses Analisa citra untuk mendapatkan hasil yang diinginkan.

Pengolahan citra digital memiliki beberapa tujuan antara lain adalah memperbaiki kualitas gambar dilihat dari aspek radiometrik (peningkatan kontras, transformasi warna, restorasi citra) dan dari aspek geometrik (rotasi, translasi, skala, transformasi geometrik), melakukan proses penarikan informasi dan deskripsi objek atau pengenalan objek yang terkandung pada citra, melakukan kompresi atau reduksi data untuk tujuan penyimpanan data, transmisi data, dan waktu proses data.

2.3.4. Deteksi Wajah

Deteksi wajah (*Face Detection*) adalah teknologi komputer yang digunakan untuk beberapa sistem dan aplikasi yang digunakan untuk mendeteksi wajah. Teknologi ini dibangun menggunakan algoritma tertentu yang berfokus pada deteksi manusia. Pada teknologi pengenalan wajah proses deteksi wajah (*face detection*) merupakan tahap awal pemrosesan untuk mengenali wajah seseorang. Face detection ini akan menentukan dimana bagian wajah yang muncul pada citra

masukannya. Keberhasilan dari proses *face detection* ini memiliki tingkat pengaruh yang tinggi dalam performa dan kegunaan dari suatu sistem pengenalan wajah (Alexander, Sentinuwo, & Sambul, 2017).

2.3.5. Pengenalan Wajah

Wajah merupakan bagian dari tubuh manusia yang menjadi fokus perhatian di dalam interaksi sosial. Wajah memainkan peranan vital dengan menunjukkan identitas seseorang. Wajah terutama digunakan untuk ekspresi wajah, penampilan, serta identitas. Tidak ada satu wajahpun yang serupa mutlak, bahkan pada manusia kembar identik sekalipun. Ada beberapa pengertian dan definisi wajah berdasarkan sudut pandang bidang keilmuan. Definisi wajah menurut kamus besar bahasa Indonesia merupakan bagian dari kepala; roman muka; muka. Wajah atau muka adalah bagian depan dari kepala pada manusia meliputi wilayah dari dahi hingga dagu. Bagian-bagian yang termasuk wilayah wajah yaitu rambut, dahi, alis, mata, hidung, pipi, mulut, bibir, gigi, kulit, dan dagu. Bagian dari tubuh manusia yang menjadi fokus perhatian didalam interaksi sosial yaitu wajah, wajah dapat memainkan peranan dalam menunjukkan identitas dan emosi. Kita dapat mengenali ribuan wajah karena frekuensi interaksi yang sangat sering ataupun hanya sekilas bahkan dalam rentang waktu yang sangat lama. Dan kita dapat mengenali seseorang walaupun terjadi perubahan pada orang tersebut karena bertambahnya usia atau pemakaian kacamata atau perubahan gaya rambut. Oleh karena sistem pengenalan seseorang banyak menggunakan wajah sebagai indikasi pengenalan atau *face recognition*.

Pengenalan wajah (*Face Recognition*) merupakan suatu pengembangan dari teknologi deteksi wajah (*Face Detection*) yang mana teknologi ini dapat menghasilkan wajah dari hasil tangkapan kamera dan akan melakukan deteksi persamaan wajah dengan data wajah yang telah disimpan di database pada komputer, sehingga komputer dapat mengenali dan mengetahui identitas wajah seseorang tersebut (Alexander, Sentinuwo, & Sambul, 2017).

Pengenalan wajah adalah salah satu teknologi biometrik yang telah banyak diaplikasikan dalam sistem keamanan selain pengenalan retina mata, pengenalan sidik jari dan iris mata. Dalam aplikasinya sendiri pengenalan wajah menggunakan sebuah kamera untuk menangkap wajah seseorang kemudian dibandingkan dengan wajah yang sebelumnya telah disimpan di dalam database tertentu. Cara kerja pengenalan wajah (*face recognition*) secara umum yaitu dengan mengkonversikan foto, sketsa, dan gambar video menjadi serangkaian angka, yang disebut dengan *faceprint* yang kemudian akan membandingkan dengan angkaian angka yang lain yang mewakili wajah-wajah yang sudah dikenal. Proses pengenalan citra wajah oleh sistem secara garis besar dapat dibagi menjadi lima tahap seperti deteksi, pengenalan posisi, normalisasi, pengkodean, perbandingan (Wiryadinata, Sagita, Wardoyo, & Priswanto, 2016).

Pengenalan wajah melibatkan banyak variabel, misalnya citra sumber, cira hasil pengolahan citra, citra hasil ekstraksi dan data profil seseorang. Dibutuhkan juga alat pengindra berupa sensor kamera dan metode untuk menentukan apakah citra yang ditangkap oleh *webcam* tergolong wajah manusia atau bukan, sekaligus untuk menentukan informasi profil yang sesuai dengan citra wajah yang dimaksud.

Dalam perangkat lunak pengenalan wajah yang mengenali wajah seseorang setelah sebelumnya dilakukan proses pendeteksian wajah berdasarkan penanda- penanda tertentu seperti jarak antara mata, lebar hidung dan bentuk dari pipi tulang. Suatu proses deteksi wajah (*face detection*) merupakan tahapan awal dari suatu proses yang disebut pengenalan wajah (*face recognition*). Pengenalan wajah termasuk teknologi yang memiliki metode yang tidak seratus persen aman.

Ada beberapa sistem-sistem yang menggunakan metode ini dapat diretas dengan menggunakan foto target pengguna. Tetapi tidak semua sistem memiliki kelemahan tersebut. Pada metode pengenalan wajah aspek tunggal dan kenyamanan bukanlah masalah. Tetapi yang lebih penting dalam metode ini adalah sebuah perangkat lunak yang digunakan. Yang lebih spesifiknya adalah bagaimana perangkat lunak yang digunakan mampu untuk mengenali wajah pada berbagai kondisi pencahayaan dan pada saat wajah terdapat berbagai aksesoris seperti penggunaan kacamata dan topi.

2.3.6. Dataset

Dataset merupakan kumpulan data terstruktur yang diorganisir secara sistematis untuk tujuan penelitian, analisis, atau pembelajaran mesin. Dataset harus *Findable* (dapat ditemukan), *Accessible* (dapat diakses), *Interoperable* (dapat dioperasikan), dan *Reusable* (dapat digunakan kembali).

Dalam praktiknya, dataset memiliki peran fundamental dalam berbagai bidang. Di dunia penelitian, dataset memungkinkan validasi hasil penelitian dan replikasi eksperimen. Dalam bisnis, dataset digunakan untuk analisis pasar, prediksi tren, dan pengambilan keputusan strategis. Di bidang kecerdasan buatan, dataset berfungsi

sebagai bahan pelatihan untuk model machine learning. Kualitas dan kelengkapan dataset sangat menentukan akurasi hasil analisis dan keandalan kesimpulan yang dihasilkan.

2.3.7. Open CV (Open Computer Vision)

OpenCV (Open Computer Vision) merupakan sebuah *open source library* dari fungsi pemrograman yang terutama fungsi ini ditujukan untuk keperluan pengolahan citra secara *realtime*, yang dimana *openCV* ini dikembangkan oleh sebuah pusat penelitian Intel Rusia di Nizhny Novgorod, dan sekarang sudah didukung oleh Willow Garage dan Itseez. *OpenCV* sendiri sudah memiliki lebih dari 500 algoritma yang sudah dioptimalkan untuk keperluan pengolahan citra dan video.

OpenCV (Open Computer Vision) adalah *library open source* yang memiliki tujuan yang dikhususkan untuk melakukan pengolahan citra. Maksudnya yaitu agar sebuah computer memiliki kemampuan yang mirip dengan cara pengolahan visual pada manusia. *OpenCV* sendiri telah menyediakan banyak algoritma visi computer dasar. *OpenCV* juga telah menyediakan modul pendeteksian sebuah objek yang menggunakan algoritma Viola Jones (Prasetya & Nurviyanto, 2012).

OpenCV dibuat untuk menyelesaikan kebanyakan masalah computer vision yang sudah ditentukan. Untuk mencapai tingkat optimasi yang tinggi diperlukan ketegasan yang merupakan aspek dari *OpenCV*. Hal tersebut dimaksudkan untuk aplikasi *real-time* dan dirancang untuk sebuah proses eksekusi yang sangat cepat.

Intel Open Source Computer Vision Library merupakan kepanjangan dari *OpenCV* yang sekurang-kurangnya terdiri dari tiga ratus fungsi-fungsi C, bahkan bias lebih. *OpenCV* dapat dioperasikan pada computer berbasis windows ataupun linux. Ada beberapa contoh aplikasi dari *OpenCV* adalah pada *Human Computer Interaction* (interaksi manusia computer) antara lain *Object Identification* (identifikasi objek), *Segmentation* (segmentasi) dan *Recognition* (pengenalan), *Face Recognition* (pengenalan wajah), *Gesture Recognition* (pengenalan gerak isyarat), *Motion Tracking* (penjajakan gerakan), *Ego Motion* (gerakan ego) dan *Motion Understanding* (pemahaman gerakan), *Structure From Motion* (gerakan dari struktur), *Mobile Robotics* (robot-robot yang bergerak).

OpenCV menggunakan sebuah tipe face detector yang disebut *Haarcascade Classifier*. *Face detector* akan bekerja jika ada sebuah *image* yang berasal dari file gambar atau live video, *face detector* tersebut akan menguji tiap lokasi *image* dan akan mengklasifikasi file *image* atau *live video* tersebut sebagai wajah atau bukan wajah. Dalam mengklasifikasi wajah tersebut digunakan sebuah pemisalan skala yang tetap, contohnya 50×50 pixel.



Gambar 2. 6 Logo aplikasi *OpenCV*

Dalam melakukan tugasnya, *classifier* menggunakan data yang sudah disimpan pada file XML untuk memutuskan bagaimana cara mengklasifikasi tiap lokasi

image. *OpenCV* akan menggunakan 4 data XML untuk mendeteksi wajah depan, dan satu untuk wajah profil.

2.3.8. Metode CNN


CNN (*Convolution Neural Network*) adalah jenis jaringan saraf yang terdiri dari lapisan komputasi yang berurutan, dengan lapisan konvolusi dan sub sampling (penyatuan) yang saling bergantian. CNN relatif lebih mudah dilatih menggunakan algoritma *backpropagation*, terutama karena memiliki konektivitas yang jarang di setiap lapisan konvolusi. Dalam lapisan konvolusi, digunakan filter linier untuk melakukan konvolusi pada masukan. Parameter utama dalam CNN adalah bobot dari filter yang digunakan. Untuk mengurangi jumlah parameter yang dibutuhkan, strategi pembagian parameter dapat digunakan. Meskipun pembagian parameter mengurangi kapasitas jaringan, namun dapat meningkatkan kemampuan generalisasinya. Hal ini terjadi karena pembagian parameter memungkinkan jaringan untuk mengekstraksi fitur yang lebih umum dan lebih invariant terhadap variasi data yang tidak relevan (Pang, Sun, Jiang, & Li, 2018).

Sebuah CNN tersusun dari beberapa lapisan/ layer antara lain *convolution*, *subsampling/ pooling layer*, dan *fully connected layer*.

Convolution Layer

Konvolusi adalah operasi matematis yang diterapkan pada data citra atau sinyal menggunakan sebuah kernel. Dalam pengolahan citra, konvolusi dilakukan dengan menggeser kernel secara berulang-ulang

pada seluruh area citra untuk menghasilkan citra konvolusi atau *feature map* seperti yang ditunjukkan pada Gambar 2.7.



Gambar 2.7 Operasi Konvolusi

Tujuan utama dari konvolusi dalam pengolahan citra, terutama dalam CNN, adalah untuk mengekstraksi fitur penting dari citra masukan. Bobot atau parameter pada lapisan konvolusi CNN menentukan kernel konvolusi yang digunakan. Selama pelatihan, bobot tersebut disesuaikan agar CNN dapat mempelajari fitur-fitur yang relevan dan kompleks dari data citra (A, 2022).

Sub-sampling Layer


Sub-sampling, atau reduksi ukuran, adalah proses yang digunakan dalam pengolahan citra untuk mengurangi dimensi data citra. Salah satu metode *sub-sampling* yang umum digunakan dalam CNN adalah metode max-pooling. Max-pooling membagi keluaran dari lapisan konvolusi menjadi beberapa *grid* kecil, lalu memilih nilai maksimum dari setiap *grid* untuk membentuk matriks citra yang telah direduksi. *Grid* yang berwarna merah, hijau, kuning dan biru merupakan kelompok *grid* yang akan dipilih nilai maksimumnya. Dengan menggunakan max pooling, fitur-fitur penting dari citra tetap dipertahankan dengan in variansi terhadap posisi objek.

Sehingga, fitur-fitur tersebut akan tetap terdeteksi meskipun terjadi pergeseran atau translasi pada objek citra (Pang, Sun, Jiang, & Li, 2018).

Fully Connected Layer

Fully connected layer biasanya digunakan dalam *Multilayer Perceptron* (MLP) dan bertujuan untuk melakukan transformasi dimensi data agar dapat diklasifikasikan secara linear. Namun, sebelum data dapat dimasukkan ke dalam *fully connected layer*, setiap neuron pada lapisan konvolusi perlu ditransformasikan menjadi data satu dimensi terlebih dahulu. Hal ini menyebabkan kehilangan informasi spasial yang tidak dapat dikembalikan. Oleh karena itu, metode tersebut hanya dapat ditempatkan di akhir jaringan (Kamencay, Benco, Mizdos, & Radil, 2017).


Convolution layer dengan ukuran kernel 1×1 melakukan fungsi yang sama dengan sebuah *fully connected layer* namun dengan tetap mempertahankan karakter spasial dari data. Hal tersebut membuat penggunaan *fully connected layer* pada CNN sekarang tidak banyak dipakai (Cahyono, Wirawan, & Rachmadi, 2020).




Gambar 2. 8 Operasi Max-Polling

2.3.9. FaceNet


FaceNet dibangun oleh para peneliti Google menggunakan *Deep convolutional neural network* (DCNN) yang memetakan gambar wajah seseorang ke dalam ruang euclidean (kumpulan titik geometris) yang juga disebut *embedding*. *Embedding* diperoleh dari tingkat kesamaan dan perbedaan wajah, sehingga jika wajah memiliki kesamaan nilainya akan semakin dekat, dan jika wajah berbeda nilainya akan semakin jauh. Secara umum, ekstraksi fitur



Gambar 2. 9 Struktur P-Net



Gambar 2. 10 Struktur R-Net




Gambar 2. 11 Struktur O-Net

menggunakan model *FaceNet* ditunjukkan pada Gambar 6.12, citra masukan akan masuk ke arsitektur *deep learning* kemudian dinormalisasi L2 dan hasilnya berupa fitur wajah (*embedding*) yang dilatih menggunakan *Triplet Loss* (Cahyono, Wirawan, & Rachmadi, 2020). Ekstraksi fitur model arsitektur *FaceNet* menggunakan fungsi *Triplet Loss* ditunjukkan pada Gambar 6.13. Adapun penerapan metode tersebut bertujuan untuk membuat citra yang mirip menjadi lebih dekat, dan membuat citra yang berbeda menjadi lebih jauh. Ekstraksi fitur yang dihasilkan dari *FaceNet* memiliki fitur wajah (*embedding*) berkualitas tinggi dengan 12 dimensi (Cahyono, Wirawan, & Rachmadi, 2020).



Gambar 2. 12 Ekstraksi fitur *FaceNet*



Gambar 2. 13 *Triplet Loss*

2.3.10. VGG16

VGG16 merupakan salah satu arsitektur CNN yang populer karena kesederhanaan modelnya dan menggunakan kernel berukuran kecil yang diperkenalkan pada tahun 2014. Arsitektur VGG16 menggunakan 3x3 kernel dengan *Max Pooling* dan *stride* bernilai 1 untuk *feature extraction* dan 3 *fully*

connected layer pada akhir arsitektur. Dengan ukuran kernel tersebut, kedalaman neural network dapat ditambahkan sehingga dapat menghasilkan akurasi yang lebih akurat daripada arsitektur lainnya. Setiap lapisan konvolusi akan diikuti dengan fungsi aktivasi ReLU untuk mengurangi kondisi *overfit* (S. Khan, 2018).

Arsitektur VGG16 ini merupakan arsitektur yang baik digunakan untuk memecahkan masalah seperti pengenalan dan klasifikasi citra serta untuk deteksi dan lokalisasi citra. Selain itu, VGG16 memiliki kelebihan pada kesederhanaan arsitekturnya dan akurasi yang baik.

2.3.11 Algoritma K-Nearest Neighbor (KNN)

Algoritma K-Nearest Neighbor (KNN) merupakan salah satu metode klasifikasi dalam machine learning yang bekerja dengan prinsip supervised learning. Dalam konteks pengenalan wajah, KNN berfungsi untuk membandingkan fitur data uji dengan dataset wajah yang telah dilatih sebelumnya. Prinsip kerja utama algoritma ini adalah mengklasifikasikan objek baru berdasarkan atribut dan sample dari training data yang memiliki jarak terdekat atau paling mirip.

Kunci utama dalam optimalisasi KNN terletak pada penentuan nilai K ($n_neighbors$), yaitu jumlah tetangga terdekat yang digunakan untuk menentukan kelas dari data baru. Penentuan nilai K yang tepat sangat krusial karena nilai yang terlalu kecil dapat membuat model sensitif terhadap *noise*, sedangkan nilai yang terlalu besar dapat mengaburkan batas antar kelas. Oleh karena itu, dalam penelitian ini dilakukan pengujian variasi nilai K mulai dari 1 hingga 20 untuk menemukan parameter yang paling optimal dalam mengklasifikasikan wajah penyandang tunanetra.

BAB 3

METODE PENELITIAN

Pada penelitian ini, proses pengenalan wajah dilakukan dengan lima tahapan pokok yang terdiri dari pembuatan dataset wajah, prapemrosesan, ekstraksi fitur, klasifikasi, uji model, dan perbandingan kinerja.

3.1 Jenis, Sifat, dan Pendekatan Penelitian

3.1.1. Jenis Penelitian

Penelitian ini merupakan jenis penelitian eksperimental. Penelitian eksperimental dipilih karena penelitian ini bertujuan untuk menguji efektivitas model CNN dalam konteks pengenalan wajah penyandang tunanetra, dengan melakukan percobaan langsung terhadap model-model yang diujikan. Eksperimen dilakukan dengan menerapkan dua model CNN berbeda pada dataset wajah dan menganalisis hasil deteksi serta pengenalan wajah dalam berbagai kondisi.

3.1.2. Sifat Penelitian

Sifat penelitian ini adalah kuantitatif. Penelitian kuantitatif dipilih karena hasil penelitian diperoleh dari pengukuran dan analisis data numerik, khususnya berkaitan dengan performa model pengenalan wajah. Metrik kuantitatif yang digunakan meliputi persentase deteksi wajah, tingkat akurasi, precision, recall, dan F1-score dari model pengenalan wajah yang diuji.

3.1.3. Pendekatan Penelitian

Pendekatan yang digunakan dalam penelitian ini adalah pendekatan komparatif. Pendekatan komparatif dilakukan dengan membandingkan kinerja dua

model Convolutional Neural Network (CNN) yang berbeda, yaitu FaceNet dan VGG16, dalam mengenali wajah penyandang tunanetra. Selain itu, penelitian ini juga membandingkan pengaruh dua metode deteksi wajah yang berbeda, yaitu MTCNN dan HaarCascade, terhadap kinerja kedua model CNN tersebut. Melalui pendekatan komparatif ini, dapat diketahui kombinasi metode yang paling efektif untuk pengenalan wajah penyandang tunanetra.

3.2. Metode Pengumpulan Data

Pengumpulan data dalam penelitian ini dilakukan dengan cara mengunduh gambar-gambar wajah dari situs web yang menyediakan dataset terbuka. Kriteria pemilihan dataset ditentukan berdasarkan relevansinya dengan objek penelitian yaitu wajah penyandang tunanetra dan bukan penyandang tunanetra (normal). Dataset yang dipilih memiliki karakteristik sebagai berikut:

- a. Beragam kondisi pencahayaan, mulai dari pencahayaan yang baik hingga pencahayaan yang minim.
- b. Berbagai posisi kepala dan sudut pengambilan gambar, termasuk posisi yang tidak sejajar.

Total gambar wajah yang digunakan dalam penelitian ini adalah 160 citra wajah, yang digunakan untuk menguji kemampuan model dalam mendeteksi dan mengenali wajah penyandang tunanetra dalam berbagai kondisi. Dataset ini dipilih khusus untuk merepresentasikan objek penelitian dan memastikan bahwa model yang digunakan dapat bekerja dalam berbagai skenario dunia nyata.

3.3. Metode Analisis Data

Penelitian ini menggunakan Google Colab sebagai platform utama untuk implementasi dan analisis data karena menyediakan lingkungan komputasi yang memadai untuk melakukan pelatihan dan pengujian model CNN. Metode analisis data terdiri dari beberapa tahapan yang saling terkait.

Tahap pertama adalah pemilahan dan penyeimbangan data, di mana gambar wajah dari dataset diseleksi dan dikategorikan berdasarkan kualitasnya untuk memastikan kesesuaian dengan tujuan penelitian. Data wajah yang telah dipilah kemudian dianalisis menggunakan dua metode deteksi wajah yang berbeda: MTCNN dan HaarCascade. MTCNN (Multi-task Cascaded Convolutional Networks) merupakan metode deteksi wajah yang terdiri dari tiga tahap: Proposal Network (P-Net), Refinement Network (R-Net), dan Output Network (O-Net) yang bekerja secara berurutan untuk melakukan deteksi wajah (Sunarko et al., 2023). Sementara itu, HaarCascade merupakan metode deteksi wajah alternatif yang digunakan dalam penelitian ini untuk memberikan perbandingan kinerja (Sikha & Bharath, 2022).

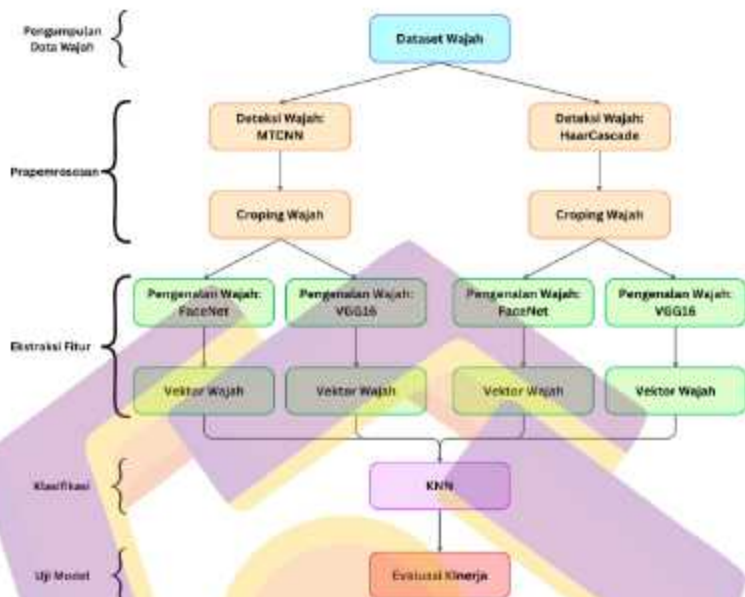
Selanjutnya, analisis pengenalan wajah dilakukan dengan mengimplementasikan dua model CNN yaitu FaceNet dan VGG16. FaceNet digunakan karena kemampuannya dalam memetakan gambar wajah ke dalam ruang Euclidean menggunakan triplet loss (Sukash et al., 2024), sedangkan VGG16 digunakan karena kemampuannya dalam mengidentifikasi fitur wajah dengan akurasi tinggi (Chethana et al., 2024). Untuk klasifikasi wajah, digunakan algoritma

K-Nearest Neighbors (KNN) yang membandingkan fitur wajah yang diekstrak dengan dataset yang telah dilatih sebelumnya.

Evaluasi kinerja model dilakukan menggunakan metrik standar yang umum digunakan dalam klasifikasi, yaitu akurasi, precision, recall, dan F1-score. Akurasi mengukur persentase prediksi yang benar dari total prediksi, precision mengukur tingkat ketepatan antara informasi yang diminta dengan jawaban yang diberikan oleh model, recall mengukur tingkat keberhasilan model dalam menemukan kembali sebuah informasi, dan F1-score merupakan rata-rata harmonik dari precision dan recall. Selain itu, confusion matrix juga digunakan sebagai alat visualisasi untuk mengevaluasi kinerja model klasifikasi.

3.4. Alur Penelitian

Penelitian ini dilaksanakan dengan alur yang sistematis untuk memastikan hasil yang baik. Berikut gambaran alur penelitian:



Gambar 3. 1 Alur Penelitian

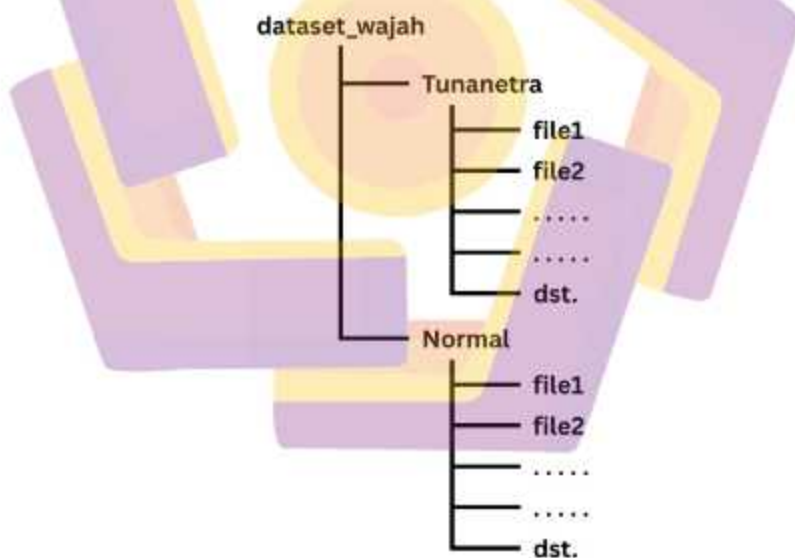
Flowchart ini menggambarkan alur proses analisis data yang dilakukan dalam penelitian. Dimulai dari tahap pemilahan dan penyeimbangan data, kemudian data diproses menggunakan dua metode deteksi wajah yang berbeda (MTCNN dan HaarCascade). Selanjutnya, untuk setiap metode deteksi wajah, pengenalan wajah dilakukan menggunakan dua model CNN (FaceNet dan VGG16). Hasil dari model-model tersebut kemudian diklasifikasikan menggunakan algoritma K-Nearest Neighbors (KNN). Terakhir, evaluasi kinerja dilakukan dengan menghitung metrik-metrik standar seperti akurasi, precision, recall, F1-score, dan membuat confusion matrix. Berikut penjabaran singkat dari setiap langkah alur penelitian:

3.4.1. Pengumpulan Data Wajah

Pengumpulan data wajah penyandang tunanetra dilakukan untuk memperoleh sampel wajah. Sampel wajah yang didapat, selanjutnya digunakan untuk analisa penelitian. Adapun proses pengumpulan data wajah sebagai berikut:

- a. Mengunduh dataset wajah penyandang tunanetra dan normal dari sumber terbuka
- b. Memilih data yang relevan dengan objek penelitian

Data wajah yang dikumpulkan berupa citra dua dimensi dengan format file gambar (*.jpg,*.jpeg). Dataset yang didapat selanjutnya disimpan dalam folder dengan ketentuan seperti gambar 3.2 berikut:



Gambar 3. 2 Struktur direktori dataset

Penyusunan struktur hierarki direktori dataset penting dilakukan. Penyusunan direktori yang sesuai hierarki mempengaruhi proses pengenalan wajah, agar sesuai

dengan tujuan penelitian. Pelabelan dan peletakan file data wajah yang sesuai dengan nama pemilik citra wajah tersebut merupakan suatu keharusan supaya tepat dalam memprediksi suatu citra.

3.4.2. Prapemrosesan

Sebelum digunakan dalam tahap pelatihan dan pengujian model pengenalan wajah, gambar-gambar dalam dataset perlu melalui tahapan prapemrosesan. Tujuannya adalah untuk menghasilkan citra wajah yang seragam dalam hal ukuran, kualitas, dan format, sehingga sesuai sebagai input model. Pada penelitian ini, digunakan dua metode dalam proses deteksi wajah, yaitu MTCNN (Multi-task Cascaded Convolutional Neural Network) dan HaarCascade.

1. Deteksi Wajah

Tahap pertama adalah mendeteksi posisi wajah dalam setiap gambar menggunakan dua metode yang berbeda:

a. MTCNN

MTCNN mendeteksi wajah sekaligus lima titik landmark penting pada wajah, yaitu mata kiri, mata kanan, hidung, mulut kiri, dan mulut kanan. Metode ini efektif mendeteksi wajah dalam berbagai kondisi pose dan pencahayaan.

b. HaarCascade Classifier

Merupakan metode klasikal berbasis fitur Haar yang mendeteksi wajah dengan memindai pola terang-gelap khas wajah manusia. Deteksi dilakukan terhadap gambar dalam format grayscale.

2. Cropping Gambar Wajah

Setelah wajah berhasil terdeteksi, dilakukan proses *cropping*, yaitu memotong gambar berdasarkan koordinat *bounding box* yang diperoleh dari tahap deteksi. Proses ini bertujuan untuk mengisolasi bagian wajah dan menghilangkan latar belakang yang tidak relevan.

3. Penyesuaian Ukuran Citra

Hasil *cropping* kemudian diubah ukurannya menjadi 160x160 piksel atau 224x224 piksel, dengan format RGB (3 kanal warna). Ukuran ini dipilih untuk menyesuaikan dengan arsitektur yang akan digunakan dalam tahap klasifikasi wajah.

3.4.3. Ekstraksi Fitur Wajah

1. Ekstraksi Fitur

Setelah melalui prapemrosesan, citra wajah dimasukkan ke dalam model deep learning untuk diekstraksi fiturnya. Penelitian ini menggunakan dua arsitektur model, yaitu FaceNet dan VGG16, yang masing-masing menghasilkan embedding dengan karakteristik berbeda:

- FaceNet

FaceNet adalah model deep learning yang dirancang khusus untuk pengenalan wajah. Model ini menghasilkan embedding berdimensi 512 (Inception-ResNet-v1) untuk setiap gambar wajah. Embedding ini memetakan wajah ke dalam ruang vektor, sehingga wajah dari individu yang sama akan berada pada jarak vektor yang dekat, dan sebaliknya.

- VGG16

VGG16 adalah arsitektur CNN yang awalnya dirancang untuk klasifikasi gambar umum. Dalam penelitian ini, VGG16 digunakan untuk mengekstraksi fitur wajah dengan menghapus lapisan klasifikasi akhir dan mengambil keluaran dari lapisan dense (fc1 atau fc2). Model ini menghasilkan embedding berdimensi 512 untuk setiap gambar wajah. Hasilnya adalah embedding yang memuat informasi spasial dan struktural dari citra wajah.

2. Penyimpanan Embedding

Hasil ekstraksi fitur berupa embedding disimpan dalam file berformat *.npz, yang berisi:

- a. Array embedding dari citra wajah, dan
- b. Label identitas yang diperoleh dari nama folder.

Setiap kombinasi metode deteksi dan model ekstraksi fitur menghasilkan file *.npz tersendiri. Dengan proses ini, seluruh dataset wajah telah diubah menjadi representasi numerik yang siap digunakan untuk tahap klasifikasi maupun verifikasi wajah.

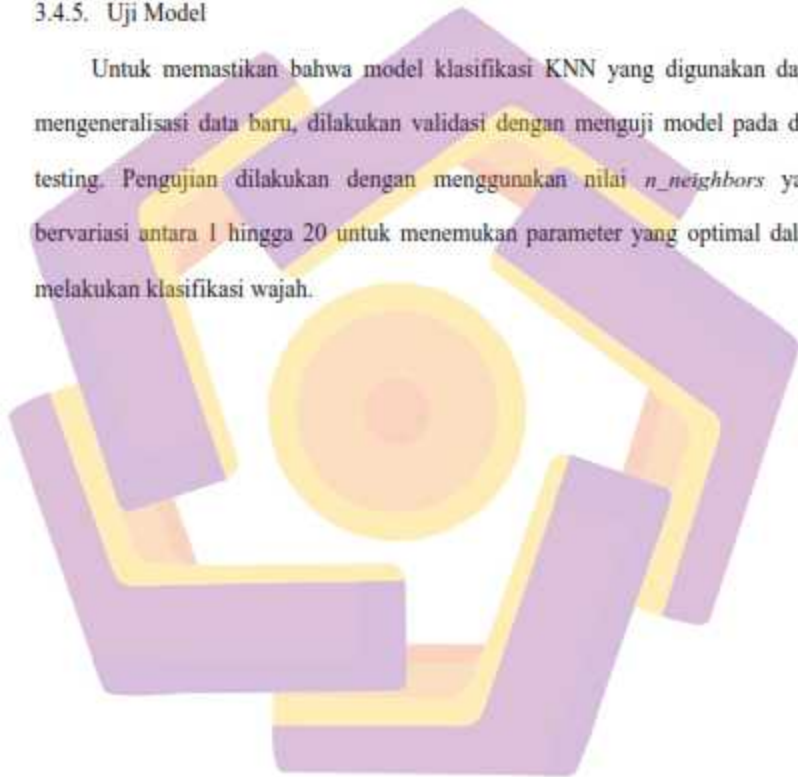
3.4.4. Klasifikasi

Dataset wajah yang didapatkan dari proses ekstraksi fitur, digunakan untuk mengenali wajah dengan cara mengklasifikasikan dataset wajah. Klasifikasi pengenalan wajah menggunakan *K-Nearest Neighbors* (KNN) karena kesederhanaannya dan kinerjanya yang baik dalam banyak aplikasi pengenalan pola, termasuk pengenalan wajah. Sehingga inputan wajah baru yang dimasukkan akan mudah untuk diklasifikasi berdasarkan ekstraksi dataset wajah yang dibuat.

Dalam melakukan klasifikasi data dibagi menjadi 80% data training dan 20% data testing. Kedua kelompok data tersebut akan dilakukan proses training dan menyimpan model klasifikasi KNN. Performansi hasil klasifikasi akan dievaluasi menggunakan *confusion matrix*.

3.4.5. Uji Model

Untuk memastikan bahwa model klasifikasi KNN yang digunakan dapat mengeneralisasi data baru, dilakukan validasi dengan menguji model pada data testing. Pengujian dilakukan dengan menggunakan nilai $n_neighbors$ yang bervariasi antara 1 hingga 20 untuk menemukan parameter yang optimal dalam melakukan klasifikasi wajah.



BAB 4

HASIL PENELITIAN DAN PEMBAHASAN

4.1. Deskripsi Penelitian

Penelitian ini bertujuan untuk mengevaluasi efektivitas FaceNet dan VGG16 dalam mengenali wajah orang buta/tunanetra, dengan menilai bagaimana kedua model tersebut dipengaruhi oleh metode deteksi wajah yang digunakan, yaitu MTCNN dan HaarCascade. Berdasarkan hasil eksperimen, ditemukan bahwa pengenalan wajah sangat dipengaruhi oleh kualitas deteksi wajah, yang pada gilirannya dipengaruhi oleh faktor-faktor seperti pencahayaan, posisi wajah, dan ekspresi wajah dalam dataset.

4.2. Pengumpulan Data Wajah

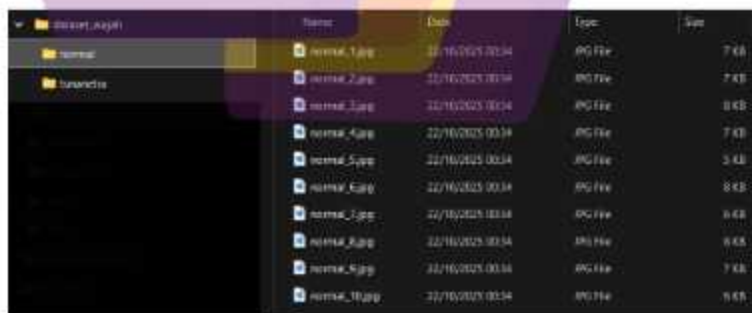
Tahap pengumpulan data dilakukan dengan mengunduh dataset wajah penyandang tunanetra dan normal (tidak menyandang tunanetra) dari sumber terbuka. Dataset ini terdiri dari 80 citra wajah tunanetra dan 80 citra wajah normal, yang diambil dalam berbagai kondisi pencahayaan dan sudut pengambilan gambar. Komposisi gender dan jumlah citra masing-masing individu berdasarkan posenya adalah sebagai berikut:

Tabel 4. 1 Sebaran Dataset Penelitian

Citra Wajah	Gender	Lurus	Serong	Total Citra
Tunanetra	Laki-laki	37	17	51
Tunanetra	Perempuan	16	13	29
Normal	Laki-laki	35	14	49
Normal	Perempuan	17	14	31

Proses pengumpulan data dilakukan dengan mempertimbangkan keberagaman karakteristik wajah, yang mencakup variasi gender, usia, dan fitur wajah khas penyandang tunanetra. Dataset ini dipilih secara khusus untuk merepresentasikan kondisi nyata yang mungkin dihadapi dalam aplikasi pengenalan wajah bagi penyandang tunanetra. Keberagaman kondisi pengambilan gambar ini penting untuk menguji ketahanan model dalam mendeteksi dan mengenali wajah pada berbagai situasi.

Dataset wajah berasal dari 2 kategori citra wajah, yaitu citra wajah penyandang tunanetra dan citra wajah normal (bukan penyandang tunanetra) yang diperoleh dari website. Dari masing-masing individu diambil 80 citra wajah berupa format gambar. Setiap citra wajah dikelompokkan berdasarkan pemilik citra wajah tersebut dalam satu folder. Penamaan folder menyesuaikan dengan nama pemilik citra wajah, untuk penamaan file tidak ada batasan ketentuan, dalam penelitian ini menggunakan ketentuan nomor urut foto. Hal ini bertujuan untuk mengetahui jumlah foto yang ada pada setiap foldernya. Adapun struktur penyimpanan dataset wajah seperti pada gambar 4.1.



Folder	Name	Date	Type	Size
normal	normal_1.jpg	22/10/2025 00:34	JPG File	7 KB
	normal_2.jpg	22/10/2025 00:34	JPG File	7 KB
	normal_3.jpg	22/10/2025 00:34	JPG File	8 KB
	normal_4.jpg	22/10/2025 00:34	JPG File	7 KB
	normal_5.jpg	22/10/2025 00:34	JPG File	5 KB
	normal_6.jpg	22/10/2025 00:34	JPG File	8 KB
	normal_7.jpg	22/10/2025 00:34	JPG File	8 KB
	normal_8.jpg	22/10/2025 00:34	JPG File	8 KB
	normal_9.jpg	22/10/2025 00:34	JPG File	7 KB
	normal_10.jpg	22/10/2025 00:34	JPG File	8 KB
tunanetra				

Gambar 4. 1 Struktur Penyimpanan Dataset

4.3.Prapemrosesan

Pada tahap prapemrosesan ini dilakukan beberapa tahapan, yaitu deteksi, cropping dan merubah ukuran citra wajah. Tahapan ini diulang sampai dengan semua dataset citra wajah melalui tahap prapemrosesan.

1. Deteksi

- MTCNN


Dengan menggunakan library dari MTCNN dilakukan deteksi wajah.



Gambar 4. 2 Deteksi Wajah dengan MTCNN

- Haarcascade


Selain menggunakan MTCNN, dilakukan juga deteksi dengan menggunakan metode haarcascade sebagai pembanding metode deteksi wajah.



Gambar 4. 3 Deteksi Wajah dengan Haarcascade

2. Cropping

Setelah mengetahui lokasi wajah pada citra, maka citra selain wajah akan diabaikan, sehingga diambil bagian yang terdeteksi sebagai wajah.



Gambar 4. 4 Cropping Citra Wajah dari Hasil Deteksi MTCNN



Gambar 4. 5 Cropping Citra Wajah dari Hasil Deteksi Haarcascade

3. Mengubah ukuran

Agar dapat dijadikan sebagai input model



Gambar 4. 6 Konversi Gambar

Pada tahap prapemrosesan ini diperoleh dataset citra yang terdeteksi sebagai citra wajah. Metode deteksi menggunakan MTCNN dengan Haarcascade menghasilkan beberapa perbedaan hasil. Pada deteksi menggunakan MTCNN terdapat 75 citra terdeteksi sebagai citra wajah, dan metode deteksi Haarcascade terdapat 68 citra terdeteksi sebagai citra wajah. Adapun hasil deteksi ditunjukkan pada gambar 4.7 untuk deteksi menggunakan metode MTCNN dan gambar 4.8 untuk hasil deteksi menggunakan metode Haarcascade.



Gambar 4. 7 Hasil Deteksi MTCNN



Gambar 4. 8 Hasil Deteksi Haarcascade

4.4. Ekstraksi Fitur Wajah

Fitur diekstraksi dengan cara memproses gambar beresolusi tertentu sebagai masukan, lalu menghasilkan representasi dalam bentuk vektor 512 dimensi. Ilustrasi hasil transformasi citra wajah menjadi vektor fitur tersebut ditampilkan pada Gambar 4.9.

```

Shape: (160, 160, 3)
Dtype: uint8
[[[ 23  24  29]
 [ 23  24  29]
 [ 20  20  27]
 ...
 [ 16  16  23]
 [ 16  15  21]
 [ 10  15  21]]]

↓

Generated embedding with shape: (512,)
Embedding values (in float32):
[1.87992978e+00 2.51771760e+00 1.88994961e+00 3.86648798e+00
1.06572306e+00 3.27137256e+00 4.72132111e+00 6.16612554e-01
7.18495414e+00 3.44972447e+00 6.62911892e-01 8.35599244e-01
5.51085949e+00 2.03823100e+00 4.81000097e-01 0.98000000e+00
1.25687418e+00 8.90709996e-01 0.00000000e+00 3.22839659e+00
6.12442374e-01 4.84351044e+00 4.63461318e-01 3.2655411e+00
1.38621064e-01 3.78745334e+00 3.40467739e+00 5.40018773e-01
1.27531195e+00 1.98911391e+00 5.23212731e-01 3.59881306e-01
4.86885737e-01 2.64888635e+00 2.28863001e+00 4.34361585e-01
1.66097581e+00 6.87631249e-01 4.18578566e+00 2.65818895e+00
2.41160884e-01 2.11193785e-01 2.04164052e+00 2.11734315e+00
1.16626296e+00 0.00000000e+00 0.78900051e-01 1.18342772e+01
5.95019042e-01 6.33313667e-01 4.18665379e-01 2.06883013e-01
1.20442234e-01 7.18985847e-01 3.63513279e+00 7.34389424e-01
1.66465139e+00 7.06414413e+00 1.77322292e+01 1.31971097e+00
1.41726804e+00 3.33253800e-01 1.97534060e+00 1.9872063e+00
3.72777820e-01 4.13955059e+00 1.13404095e+00 4.48859730e+00
0.00000000e+00 3.20440500e+00 2.41888261e+00 8.17726070e+00
1.47168070e-01 3.07115658e+00 1.14744008e+00 1.36583567e-01
1.03571718e-01 2.177209723e+00 0.00000000e+00 7.00370741e+00
8.59289110e-01 1.15483510e+00 9.78866279e-01 1.30008131e-01
7.82768822e+00 4.47380775e-01 0.00000000e+00 2.03916159e+00
7.61983824e+00 6.17612538e+00 1.48116505e+00 1.13691908e+01
1.15859032e+00 4.67373678e+00 1.29619920e+00 9.82353315e-02
5.64530850e-01 0.60431337e-01 7.72598876e+00 2.41058946e+00
2.80200679e-01 7.15848207e+00 1.11494437e+01 2.73981953e+00
3.00222546e-01 2.13041812e-01 4.28575399e-02 1.28264332e+00
3.60256024e-02 2.07512021e+00 4.14554092e+00 2.49214482e+00
1.14369858e-02 1.33692813e+00 3.35077554e-01 1.28530467e+00
3.33408598e+00 5.12581527e-01 4.20840120e+00 1.28694040e+00
7.23807792e-01 4.60087898e+00 6.45531178e-01 1.25836344e+01
2.02431059e+00 1.06322217e+00 1.08359927e+00 0.00000000e+00
2.52531838e+00 1.31065982e+01 1.84517097e+00 2.22007230e-01
1.64418774e+01 1.05650115e+00 1.64900083e+00 1.10788894e+00

```

Gambar 4. 9 Hasil Ekstraksi Fitur

4.5. Klasifikasi

Setelah melalui tahap ekstraksi fitur wajah yang menghasilkan vektor embedding, sistem melakukan proses pengenalan wajah dengan menerapkan algoritma K-Nearest Neighbors (KNN) sebagai metode klasifikasi. Pada penelitian ini, digunakan dataset sebanyak 160 sampel citra wajah. Dari dataset yang ada,

sebanyak 160 terdeteksi sebagai citra wajah oleh metode MTCNN dan 144 terdeteksi sebagai citra wajah oleh metode Haarcascade. Pembagian dataset mengikuti rasio 80:20 untuk training dan testing, dengan komposisi sebagai berikut:

1. Data training: 128 sampel untuk MTCNN dan 115 sampel untuk Haarcascade (80% dari total citra yang terdeteksi sebagai wajah)
2. Data testing: 32 sampel untuk MTCNN dan 29 sampel untuk Haarcascade (20% dari total citra yang terdeteksi sebagai wajah)

Pembagian data ini dilakukan secara random namun terkontrol dengan menerapkan random state untuk memastikan hasil yang *reproducible*. Penggunaan rasio 80:20 dipilih untuk menyeimbangkan antara kebutuhan pelatihan model yang cukup dan validasi yang memadai.

4.6. Uji Model

Pengujian model K-Nearest Neighbors (KNN) dilakukan dengan menganalisis tingkat akurasi klasifikasi berdasarkan variasi nilai K ($n_neighbors$) dalam rentang 1 hingga 20. Tujuan dari pengujian ini adalah untuk mengidentifikasi nilai K terbaik yang mampu menghasilkan performa model paling optimal. Metode ini diterapkan pada beberapa kombinasi arsitektur model dan teknik ekstraksi fitur, sehingga dapat diperoleh perbandingan menyeluruh terhadap kinerja masing-masing pendekatan. Adapun hasil uji model sebagai berikut:

1. FaceNet – MTCNN

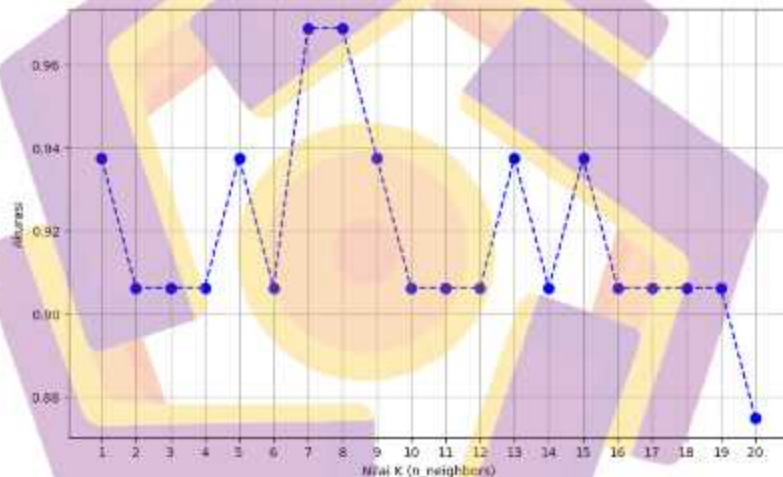
Pengujian pengenalan wajah dengan menggunakan FaceNet dan metode deteksi MTCNN tampak pada tabel 4.2.

Tabel 4. 2 Hasil Uji Model FaceNet-MTCNN

Nilai K (<i>n neighbors</i>)	Akurasi	Keterangan
1	93,75%	Akurasi Awal
2	90,62%	Penurunan Pertama
3	90,62%	Akurasi Stabil
4	90,62%	Akurasi Stabil
5	93,75%	Sama Dengan Akurasi Awal
6	90,62%	Sama Dengan Penurunan Awal
7	96,88%	Peningkatan Akurasi (Akurasi Terbaik)
8	96,88%	Akurasi Terbaik
9	93,75%	Penurunan Akurasi
10	90,62%	Penurunan Akurasi
11	90,62%	Akurasi Stabil
12	90,62%	Akurasi Stabil
13	93,75%	Sama Dengan Awal
14	90,62%	Penurunan Akurasi
15	93,75%	Peningkatan Akurasi
16	90,62%	Penurunan Akurasi
17	90,62%	Akurasi Stabil
18	90,62%	Akurasi Stabil
19	90,62%	Akurasi Stabil
20	87,50%	Akurasi Terendah

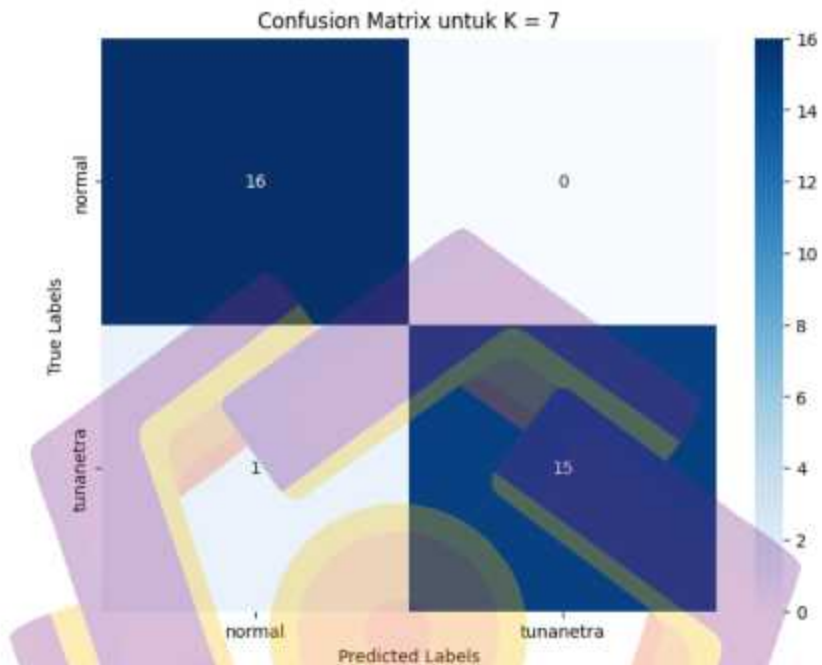
Model mencapai akurasi optimal sebesar 96,88% untuk nilai K 7 dan 8. Hal ini menunjukkan bahwa pada nilai K tersebut, model mampu melakukan klasifikasi dengan sangat baik. Keputusan yang didasarkan pada 7 dan 8 "tetangga" terdekat terbukti sangat efektif untuk dataset yang diuji. Akurasi pada iterasi pertama di peroleh 93,75% dan pada iterasi ke-2 mengalami penurunan akurasi sebesar 3,13%, di mana akurasi turun menjadi 90,62%. Akurasi terendah pada iterasi ke-20 atau nilai K=20 dengan akurasi sebesar 87,50%. Sedangkan peningkatan akurasi tertinggi pada iterasi ke-6 menuju iterasi ke-7 sebesar 6,26%. Pada iterasi ini juga

merupakan iterasi yang memiliki akurasi tertinggi, sama dengan iterasi ke-8 sebesar 96,88% dengan nilai K=8. Rata-rata akurasi dengan nilai K=1 hingga nilai K=20 yaitu 91,87%, dimana nilai K=20 merupakan akurasi terendah sebesar 87,50 dan nilai K=7 dan K=8 memperoleh akurasi tertinggi sebesar 96,88%. Hal ini mengindikasikan bahwa menentukan nilai K perlu dilakukan percobaan agar dapat mengetahui akurasi yang optimal pada nilai K tertentu. Secara visual 2 dimensi tampak pada gambar 4.14.



Gambar 4. 10 Visualisasi 2 Dimensi Uji Model FaceNet-MTCNN

Adapun hasil *confusion matrix*s tampak pada gambar 4.15.



Gambar 4. 11 *Confusion Matriks* FaceNet-MTCNN

Sample confusion matriks diambil dari salah satu akurasi terbaik, yaitu pada nilai $K=7$. Dari 32 data testing, model ini dapat mengklasifikasikan 16 citra wajah normal dan 15 citra wajah tunanetra dengan benar, serta 1 citra wajah tunanetra yang salah diklasifikasikan dengan tepat.

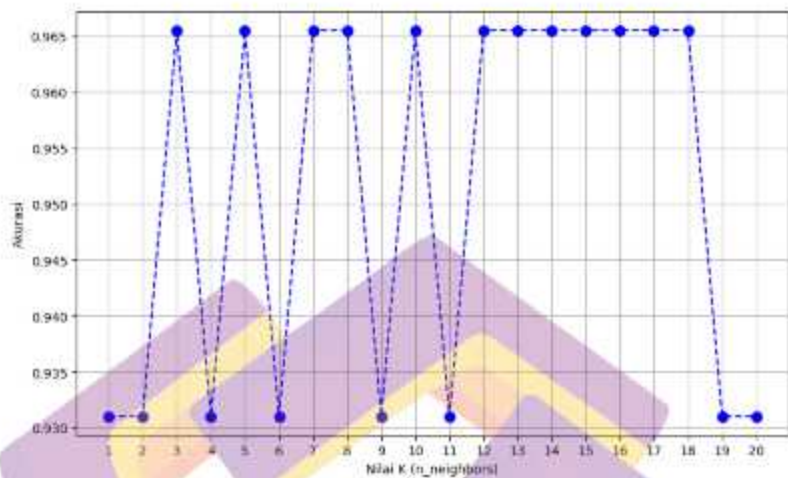
2. FaceNet – Haarcascade

Pengujian pengenalan wajah dengan menggunakan FaceNet dan metode deteksi Haarcascade tampak pada tabel 4.3.

Tabel 4. 3 Hasil Uji Model FaceNet-Haarcascade


Nilai K (<i>n neighbors</i>)	Akurasi	Keterangan
1	93,10%	Akurasi Awal
2	93,10%	Akurasi Stabil
3	96,55%	Akurasi Meningkat
4	93,10%	Akurasi Menurun
5	96,55%	Akurasi Meningkat
6	93,10%	Akurasi Menurun
7	96,55%	Akurasi Meningkat
8	96,55%	Akurasi Stabil
9	93,10%	Akurasi Menurun
10	96,55%	Akurasi Meningkat
11	93,10%	Akurasi Menurun
12	96,55%	Akurasi Meningkat
13	96,55%	Akurasi Stabil
14	96,55%	Akurasi Stabil
15	96,55%	Akurasi Stabil
16	96,55%	Akurasi Stabil
17	96,55%	Akurasi Stabil
18	96,55%	Akurasi Stabil
19	93,10%	Akurasi Menurun
20	93,10%	Akurasi Stabil

Model menunjukkan kinerja puncak dengan akurasi 96,55% pada nilai K=3, K=5, K=7, K=8, K=10, dan K=12 sampai dengan K=18. Ini adalah rentang optimal di mana model mampu mengklasifikasikan data uji dengan optimal. Akurasi terus fluktuatif pada iterasi pertama hingga iterasi ke-11. Akurasi mulai stabil pada rentang nilai K=12 hingga K=18, dimana pada iterasi tersebut akurasi tertinggi diperoleh. Percobaan dengan menggunakan metode deteksi wajah Haarcascade dan ekstraksi fitur FaceNet ini tidak terlalu banyak variasi akurasi yang didapat. Rata-rata akurasi dari model yang dilatih dengan iterasi nilai K=1 hingga K=20 yaitu sebesar 95,17%. Secara visual 2 dimensi tampak pada gambar 4.16.



Gambar 4.12 Visualisasi 2 Dimensi Uji Model FaceNet-Haarcascade

Adapun hasil *confusion matrix* tampak pada gambar 4.17



Gambar 4.13 Confusion Matriks FaceNet-Haarcascade

Sample *confusion matrix*s diambil dari salah satu akurasi terbaik, yaitu pada nilai $K=3$. Dari 29 data testing, model ini dapat mengklasifikasikan 15 citra wajah normal dan 13 citra wajah tunanetra dengan benar, serta 1 citra wajah tunanetra yang salah diklasifikasikan dengan tepat.

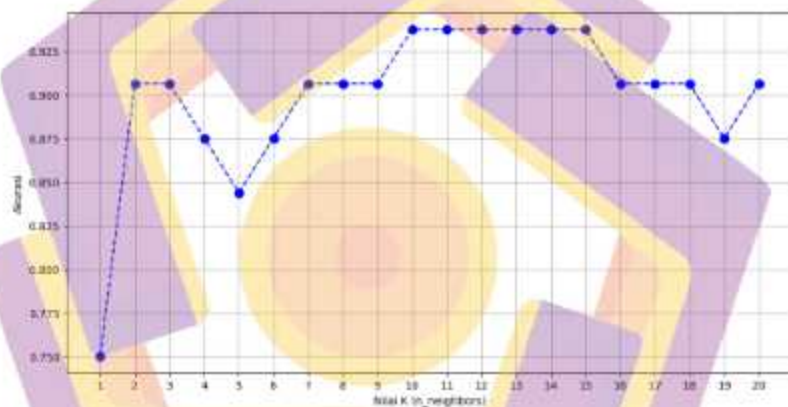
3. VGG16 – MTCNN

Pengujian pengenalan wajah dengan menggunakan FaceNet dan metode deteksi Haar cascade tampak pada tabel 4.4.

Tabel 4. 4 Hasil Uji Model VGG16-MTCNN

Nilai K (<i>n neighbors</i>)	Akurasi	Keterangan
1	75,00%	Akurasi Awal (Akurasi Terendah)
2	90,62%	Akurasi Meningkat
3	90,62%	Akurasi Stabil
4	87,50%	Akurasi Menurun
5	84,38%	Akurasi Menurun
6	87,50%	Akurasi Meningkat
7	90,62%	Akurasi Meningkat
8	90,62%	Akurasi Stabil
9	90,62%	Akurasi Stabil
10	93,75%	Peningkatan Akurasi (Akurasi Tertinggi)
11	93,75%	Akurasi Stabil
12	93,75%	Akurasi Stabil
13	93,75%	Akurasi Stabil
14	93,75%	Akurasi Stabil
15	93,75%	Akurasi Stabil
16	90,62%	Akurasi Menurun
17	90,62%	Akurasi Stabil
18	90,62%	Akurasi Stabil
19	87,50%	Akurasi Menurun
20	90,62%	Akurasi Meningkat

Kinerja model menunjukkan pola yang sangat dinamis dan fluktuatif terhadap perubahan nilai K ($n_neighbors$), yang mengindikasikan sensitivitas tinggi pada parameter ini. Kinerja terbaik atau akurasi puncak sebesar 93,75% berhasil dicapai pada rentang nilai $K=10$ hingga $K=15$. Ini merupakan rentang kerja optimal untuk model ini, di mana klasifikasi berdasarkan tetangga terdekat memberikan hasil yang baik. Berikut visual 2 dimensi hasil uji model VGG16 dengan metode deteksi MTCNN tampak pada gambar 4.18.



Gambar 4. 14 Visualisasi 2 Dimensi Uji Model VGG16-MTCNN

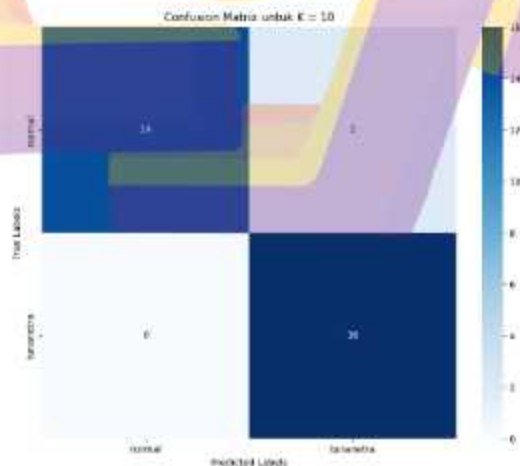
Setelah melewati rentang optimalnya, kinerja model menjadi tidak stabil dan cenderung menurun secara bertahap:

- Titik Awal dan Lonjakan Pertama: Model dimulai dengan akurasi terendah pada $K=1$ (75,00%). Terjadi lonjakan performa yang sangat drastis pada $K=2$, di mana akurasi meningkat signifikan ke 90,62% dan bertahan stabil hingga $K=3$.
- Periode Tidak Stabil ($K=4$ s.d. $K=9$): Setelah $K=3$, kinerja model mengalami fluktuasi. Akurasi turun ke 87,50% ($K=4$) dan mencapai titik terendah lokal pada

K=5 (sebesar 84,38%). Model kemudian berangsur pulih, kembali ke 87,50% (K=6) dan naik lagi ke level 90,62% (K=7), di mana ia stabil hingga K=9.

- c. Rentang Performa Puncak (Optimal): Akurasi puncak model tercapai pada K=10, dengan nilai melonjak ke 93,75%. Performa optimal ini bertahan dalam rentang yang sangat stabil dan panjang, yaitu dari K=10 hingga K=15.
- d. Tren Penurunan Pasca-Optimal: Setelah melewati rentang optimalnya di K=15, kinerja model mengalami penurunan. Akurasi turun kembali ke level 90,62% dan stabil untuk K=16, K=17, dan K=18.
- e. Fluktuasi Akhir: Pada K=19, akurasi kembali mengalami penurunan, jatuh ke level 87,5%. Namun, model sedikit pulih pada K=20, di mana akurasi kembali naik ke 90,62%.
- f. Rata-Rata Kinerja: Secara keseluruhan, performa model di 20 nilai K yang diuji cukup tinggi. Rata-rata akurasi model di seluruh pengujian ini adalah 90,62%.

Adapun hasil *confusion matrix* tampak pada gambar 4.19.



Gambar 4. 15 Confusion Matriks VGG16-MTCNN

Sample confusion matriks diambil dari salah satu akurasi terbaik, yaitu pada nilai $K=10$. Dari 32 data testing, model ini dapat mengklasifikasikan 16 citra wajah tunanetra dan 14 citra wajah normal dengan benar, serta 2 citra wajah normal yang salah diklasifikasikan dengan tepat.

4. VGG16 – Haarcascade

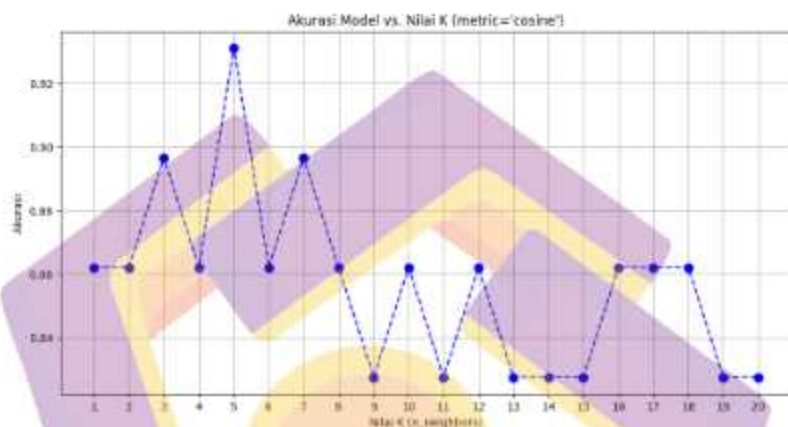
Pengujian pengenalan wajah dengan menggunakan FaceNet dan metode deteksi Haarcascade tampak pada tabel 4.5.

Tabel 4. 5 Hasil Uji Model VGG16-Haarcascade

Nilai K (<i>n neighbors</i>)	Akurasi	Keterangan
1	86,21%	Akurasi Awal
2	86,21%	Akurasi Stabil
3	89,66%	Akurasi Meningkat
4	86,21%	Akurasi Menurun
5	93,10%	Akurasi Naik (Akurasi Tertinggi)
6	86,21%	Akurasi Menurun
7	89,66%	Akurasi Meningkat
8	86,21%	Akurasi Menurun
9	82,76%	Akurasi Menurun (Akurasi Terendah)
10	86,21%	Akurasi Meningkat
11	82,76%	Akurasi Menurun
12	86,21%	Akurasi Meningkat
13	82,76%	Akurasi Menurun
14	82,76%	Akurasi Stabil
15	82,76%	Akurasi Stabil
16	86,21%	Akurasi Meningkat
17	86,21%	Akurasi Stabil
18	86,21%	Akurasi Stabil
19	82,76%	Akurasi Turun
20	82,76%	Akurasi Stabil

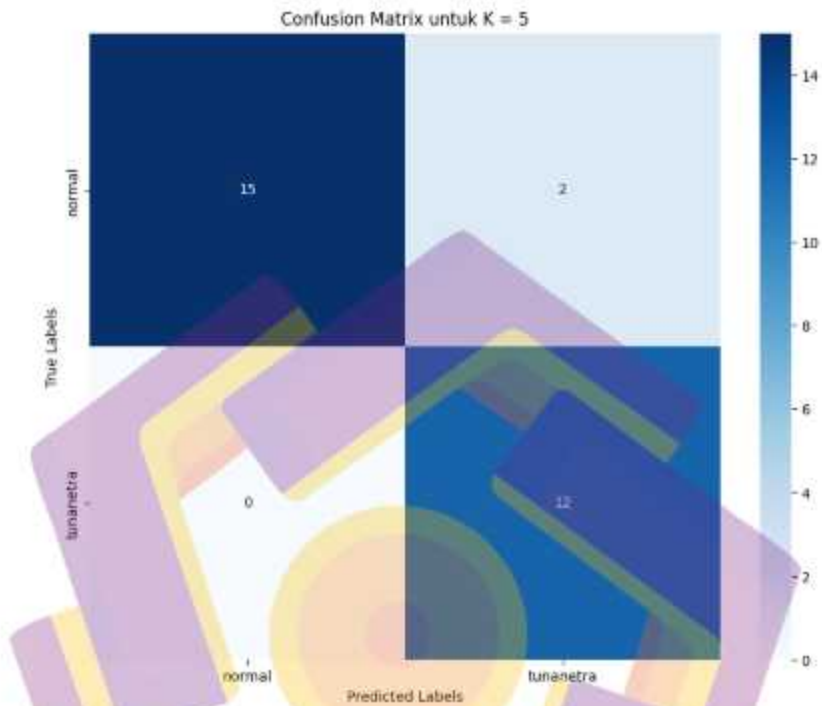
Performa terbaik model tercapai pada $K=5$ dengan akurasi 93,10%. Performa terendah model adalah 82,76%, yang pertama kali muncul pada $K=9$ dan berulang

kali muncul setelahnya. Model menunjukkan perilaku yang sangat fluktuatif (tidak stabil), di mana akurasi sering melonjak naik dan turun tajam di antara nilai K yang berdekatan. Secara visual 2 dimensi tampak pada gambar 4.20.



Gambar 4. 16 Visualisasi 2 Dimensi Hasil Uji Model VGG16-Haarcascade

Pada gambar 4.20, menampilkan performa model yang sangat fluktuatif dan tidak stabil terhadap perubahan nilai K (dari 1 hingga 20). Pola yang terlihat menyerupai "gergaji", di mana akurasi naik dan turun secara drastis pada nilai K yang berdekatan.



Gambar 4. 17 Confusion Matriks VGG16-Harcascade














Pada gambar 4.21 merupakan *sample confusion matriks* diambil dari salah satu akurasi terbaik, yaitu pada nilai $K=5$ dengan akurasi 93,10%. Dari 29 data testing dan 115 data total yang terdeteksi sebagai citra wajah, model ini dapat mengklasifikasikan 15 citra wajah normal dan 12 citra wajah tunanetra dengan benar, serta 2 citra wajah normal yang salah diklasifikasikan dengan tepat.

5. Uji Model dengan Data Baru

Hasil uji model yang didapat sebelumnya, selanjutnya dijadikan acuan dalam penentuan pengambilan keputusan nilai K terbaik, dengan harapan dapat

memperoleh performa yang tinggi. Adapun sampel contoh hasil uji model dengan data baru yang ditampilkan pada tabel 4.6 berikut:

Tabel 4. 6 Hasil Uji Model dengan Data Baru

No.	Hasil Uji Model			
	FaceNet-MTCNN	FaceNet-Haarcascade	VGG16-MTCNN	VGG16-Haarcascade
1				
2				
3				
4				
5				

Hasil Uji Model				
No.	FaceNet-MTCNN	FaceNet-Haarcascade	VGG16-MTCNN	VGG16-Haarcascade
6	 Face: 100.000000 Probability: 1.000000 Threshold: 0.500000	 Face: 100.000000 Probability: 1.000000 Threshold: 0.500000	 Face: 100.000000 Probability: 1.000000 Threshold: 0.500000	 Face: 100.000000 Probability: 1.000000 Threshold: 0.500000
7	 Face: 100.000000 Probability: 1.000000 Threshold: 0.500000	 Face: 100.000000 Probability: 1.000000 Threshold: 0.500000	 Face: 100.000000 Probability: 1.000000 Threshold: 0.500000	 Face: 100.000000 Probability: 1.000000 Threshold: 0.500000
8	 Face: 100.000000 Probability: 1.000000 Threshold: 0.500000	 Face: 100.000000 Probability: 1.000000 Threshold: 0.500000	 Face: 100.000000 Probability: 1.000000 Threshold: 0.500000	 Face: 100.000000 Probability: 1.000000 Threshold: 0.500000
9	 Face: 100.000000 Probability: 1.000000 Threshold: 0.500000	 Face: 100.000000 Probability: 1.000000 Threshold: 0.500000	 Face: 100.000000 Probability: 1.000000 Threshold: 0.500000	 Face: 100.000000 Probability: 1.000000 Threshold: 0.500000
10	 Face: 100.000000 Probability: 1.000000 Threshold: 0.500000	 Face: 100.000000 Probability: 1.000000 Threshold: 0.500000	 Face: 100.000000 Probability: 1.000000 Threshold: 0.500000	 Face: 100.000000 Probability: 1.000000 Threshold: 0.500000

Hasil Uji Model				
No.	FaceNet-MTCNN	FaceNet-Haarcascade	VGG16-MTCNN	VGG16-Haarcascade
11	 <small>Time: 100.00 (100.00%) Model: FaceNet-MTCNN Target: 100.00 (100.00%)</small>	 <small>Time: 100.00 (100.00%) Model: FaceNet-Haarcascade Target: 100.00 (100.00%)</small>	 <small>Time: 100.00 (100.00%) Model: VGG16-MTCNN Target: 100.00 (100.00%)</small>	 <small>Time: 100.00 (100.00%) Model: VGG16-Haarcascade Target: 100.00 (100.00%)</small>
12	 <small>Time: 100.00 (100.00%) Model: FaceNet-MTCNN Target: 100.00 (100.00%)</small>	 <small>Time: 100.00 (100.00%) Model: FaceNet-Haarcascade Target: 100.00 (100.00%)</small>	 <small>Time: 100.00 (100.00%) Model: VGG16-MTCNN Target: 100.00 (100.00%)</small>	 <small>Time: 100.00 (100.00%) Model: VGG16-Haarcascade Target: 100.00 (100.00%)</small>
13	 <small>Time: 100.00 (100.00%) Model: FaceNet-MTCNN Target: 100.00 (100.00%)</small>	 <small>Time: 100.00 (100.00%) Model: FaceNet-Haarcascade Target: 100.00 (100.00%)</small>	 <small>Time: 100.00 (100.00%) Model: VGG16-MTCNN Target: 100.00 (100.00%)</small>	 <small>Time: 100.00 (100.00%) Model: VGG16-Haarcascade Target: 100.00 (100.00%)</small>
14	 <small>Time: 100.00 (100.00%) Model: FaceNet-MTCNN Target: 100.00 (100.00%)</small>	 <small>Time: 100.00 (100.00%) Model: FaceNet-Haarcascade Target: 100.00 (100.00%)</small>	 <small>Time: 100.00 (100.00%) Model: VGG16-MTCNN Target: 100.00 (100.00%)</small>	 <small>Time: 100.00 (100.00%) Model: VGG16-Haarcascade Target: 100.00 (100.00%)</small>
15	 <small>Time: 100.00 (100.00%) Model: FaceNet-MTCNN Target: 100.00 (100.00%)</small>	 <small>Time: 100.00 (100.00%) Model: FaceNet-Haarcascade Target: 100.00 (100.00%)</small>	 <small>Time: 100.00 (100.00%) Model: VGG16-MTCNN Target: 100.00 (100.00%)</small>	 <small>Time: 100.00 (100.00%) Model: VGG16-Haarcascade Target: 100.00 (100.00%)</small>

Hasil Uji Model				
No.	FaceNet-MTCNN	FaceNet-Haarcascade	VGG16-MTCNN	VGG16-Haarcascade
16				
17				
18				
19				
20				

Berdasarkan tabel 4.6 di atas, kombinasi ekstraksi fitur FaceNet dan deteksi MTCNN berhasil memprediksi data baru dengan benar sebanyak 14 citra wajah, kombinasi ekstraksi fitur FaceNet dan deteksi Haarcascade berhasil memprediksi data baru dengan benar sebanyak 11 citra wajah dan 2 citra tidak terdeteksi sebagai wajah, kombinasi ekstraksi fitur VGG16 dan deteksi MTCNN berhasil

memprediksi data baru sebanyak 17 citra wajah dengan benar, dan kombinasi ekstraksi fitur VGG16 dan deteksi Haarcascade berhasil memprediksi data baru sebanyak 16 citra wajah dengan benar. Proses prediksi menggunakan algoritma KNN sebagai metode klasifikasinya. Berdasarkan percobaan di atas, didapatkan hasil perhitungan *confusion matriks* sebagai berikut:

a. Skenario 1: FaceNet – MTCNN

Analisis data:

- Normal: Terdapat 10 dideteksi dengan benar dan 5 citra wajah yang salah dideteksi (TN = 10, FP = 5)
- Tunanetra: Terdapat 4 dideteksi dengan benar dan 1 citra salah dideteksi (TP = 4, FN = 1)

Hasil Perhitungan:

$$\text{Akurasi: } \frac{TP+TN}{\text{Total}} = \frac{4+10}{20} = \frac{14}{20} = 70\%$$

$$\text{Presisi: } \frac{TP}{TP+FP} = \frac{4}{4+5} = \frac{4}{9} = 44,4\%$$

$$\text{Recall: } \frac{TP}{TP+FN} = \frac{4}{4+1} = \frac{4}{5} = 80\%$$

b. Skenario 2: FaceNet – Haarcascade

Analisis data:

- Normal: Terdapat 9 citra dideteksi dengan benar dan 6 citra wajah salah dideteksi (TN = 9, FP = 6)
- Tunanetra: Terdapat 2 dideteksi dengan benar dan 3 citra salah dideteksi (TP = 2, FN = 3)

Hasil Perhitungan:

$$\text{Akurasi: } \frac{TP+TN}{Total} = \frac{2+9}{20} = \frac{11}{20} = 55\%$$

$$\text{Presisi: } \frac{TP}{TP+FP} = \frac{2}{2+6} = \frac{2}{8} = 25\%$$

$$\text{Recall: } \frac{TP}{TP+FN} = \frac{2}{2+3} = \frac{2}{5} = 40\%$$

c. Skenario 3: VGG16 – MTCNN

Analisis data:

- Normal: Terdapat 12 dideteksi dengan benar dan 3 citra wajah yang salah dideteksi (TN = 12, FP = 3)
- Tunanetra: Terdapat 4 dideteksi dengan benar dan 1 citra salah dideteksi (TP = 5, FN = 0)

Hasil Perhitungan:

$$\text{Akurasi: } \frac{TP+TN}{Total} = \frac{5+12}{20} = \frac{17}{20} = 85\%$$

$$\text{Presisi: } \frac{TP}{TP+FP} = \frac{5}{5+3} = \frac{5}{8} = 62,5\%$$

$$\text{Recall: } \frac{TP}{TP+FN} = \frac{5}{5+0} = \frac{5}{5} = 100\%$$

d. Skenario 4: VGG16 – Haarcascade

Analisis data:

- Normal: Terdapat 12 dideteksi dengan benar dan 3 citra wajah yang salah dideteksi (TN = 12, FP = 3)
- Tunanetra: Terdapat 4 dideteksi dengan benar dan 1 citra salah dideteksi (TP = 4, FN = 1)

Hasil Perhitungan:

$$\text{Akurasi: } \frac{TP+TN}{Total} = \frac{4+12}{20} = \frac{16}{20} = 80\%$$

$$\text{Presisi: } \frac{TP}{TP+FP} = \frac{4}{4+3} = \frac{4}{7} = 57,1\%$$

$$\text{Recall: } \frac{TP}{TP+FN} = \frac{4}{4+1} = \frac{4}{5} = 80\%$$

Berikut ringkasan dari hasil perhitungan *confusion matrix*:

Tabel 4. 7 Ringkasan Hasil *Confusion Matriks*

Skenario	Akurasi	Presi	Recall
FaceNet – MTCNN	70%	44,4%	80%
FaceNet – Haarcascade	55%	25%	40%
VGG16 – MTCNN	85%	62,5%	100%
VGG16 - Haarcascade	80%	57,1%	80%

Berdasarkan hasil pengujian pada data baru, skenario VGG16 dengan deteksi MTCNN terbukti menjadi kombinasi model terbaik karena menghasilkan akurasi tertinggi (85%) dan nilai Recall sempurna (100%), yang menjadikannya sangat andal dalam mendeteksi seluruh penyandang tunanetra tanpa kesalahan (False Negative). Secara keseluruhan, arsitektur VGG16 jauh mengungguli FaceNet yang performanya rendah (di bawah 70%), sementara penggunaan MTCNN terbukti lebih stabil dan presisi dibandingkan Haarcascade yang cenderung menghasilkan banyak False Positive sehingga menurunkan nilai presisi sistem.

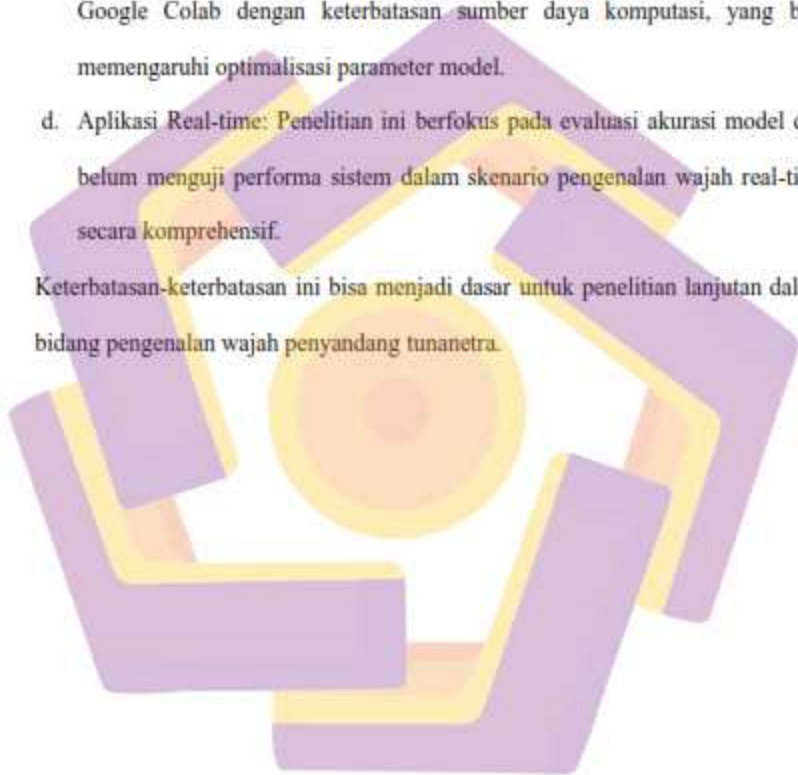
4.7. Keterbatasan Penelitian

Meskipun penelitian ini telah berhasil mengidentifikasi kombinasi model yang efektif untuk pengenalan wajah penyandang tunanetra, terdapat beberapa keterbatasan yang perlu diakui:

- Ukuran Dataset: Dataset yang digunakan dalam penelitian ini terbatas pada 80 citra wajah normal dan 80 citra wajah tunanetra. Dataset yang lebih besar dan beragam bisa memberikan hasil yang lebih representatif.

- b. Variasi Kondisi: Meskipun dataset mencakup berbagai kondisi pencahayaan, masih terdapat variasi kondisi lain seperti jarak pengambilan gambar dan oklusi parsial yang belum diuji secara komprehensif.
- c. Keterbatasan Komputasi: Implementasi model dilakukan dalam lingkungan Google Colab dengan keterbatasan sumber daya komputasi, yang bisa memengaruhi optimalisasi parameter model.
- d. Aplikasi Real-time: Penelitian ini berfokus pada evaluasi akurasi model dan belum menguji performa sistem dalam skenario pengenalan wajah real-time secara komprehensif.

Keterbatasan-keterbatasan ini bisa menjadi dasar untuk penelitian lanjutan dalam bidang pengenalan wajah penyandang tunanetra.



BAB 5

PENUTUP

5.1. Kesimpulan

Berdasarkan hasil penelitian dan pembahasan yang telah dilakukan, diperoleh beberapa kesimpulan sebagai berikut:

- a. Metode Deteksi Wajah MTCNN Terbukti Jauh Lebih Unggul. Tahap deteksi wajah (pra-pemrosesan) memiliki dampak krusial pada keseluruhan sistem. Dari total 160 sampel citra wajah yang digunakan, metode MTCNN berhasil mendeteksi 100% citra wajah (160 dari 160). Sebaliknya, metode HaarCascade hanya mampu mendeteksi 90% citra wajah (144 dari 160), yang berarti 10% data hilang sebelum sempat diproses lebih lanjut.
- b. Kombinasi FaceNet-MTCNN Mencapai Akurasi Puncak Tertinggi. Ketika membandingkan kinerja puncak (akurasi tertinggi yang dicapai pada nilai K optimal), arsitektur FaceNet yang dikombinasikan dengan deteksi MTCNN terbukti paling akurat. Kombinasi ini mencapai akurasi puncak 96,88%. Sebagai perbandingan, akurasi puncak VGG16-MTCNN adalah 93,75%, FaceNet-Haarcascade 96,55%, dan VGG16-Haarcascade 93,10%.
- c. FaceNet Menunjukkan Performa Rata-Rata yang Lebih Baik, Namun Hasilnya Bervariasi Tergantung Detektor. Berdasarkan perhitungan rata-rata akurasi dari 20 iterasi nilai K:
 - 1) FaceNet-Haarcascade secara tak terduga memiliki akurasi rata-rata tertinggi, yaitu 95,17% (dihitung dari Tabel 4.3).

- 2) FaceNet-MTCNN memiliki akurasi rata-rata 91,87%.
 - 3) VGG16-MTCNN memiliki akurasi rata-rata 90,00%.
 - 4) VGG16-Haarcascade memiliki akurasi rata-rata terendah, yaitu 85,69%, dan menunjukkan kinerja yang sangat tidak stabil.
- d. Kombinasi FaceNet-MTCNN Adalah Model Keseluruhan Terbaik. Meskipun FaceNet-Haarcascade memiliki akurasi rata-rata tertinggi (95,17%) , kombinasinya tidak ideal karena gagal mendeteksi 10% data awal. Oleh karena itu, kombinasi FaceNet-MTCNN direkomendasikan sebagai model terbaik secara keseluruhan. Kombinasi ini berhasil mendeteksi 100% data dan juga menghasilkan akurasi puncak tertinggi (96,88%).
- e. Stabilitas Model VGG16-Haarcascade Sangat Rendah. Pengujian model menunjukkan bahwa kombinasi VGG16-Haarcascade sangat sensitif terhadap perubahan nilai K. Grafiknya menunjukkan pola fluktuatif yang tajam ("pola gergaji"), menjadikannya pilihan yang paling tidak stabil dan tidak dapat diandalkan dalam penelitian ini.
- f. Kemampuan Generalisasi pada Data Baru (Data Eksternal). Hasil pengujian menggunakan data gambar baru menunjukkan temuan yang berbeda. VGG16-MTCNN terbukti memiliki kemampuan generalisasi yang lebih adaptif dengan tingkat keberhasilan prediksi sebesar 85% dan VGG16-HaarCascade sebesar 80%. Angka ini lebih tinggi dibandingkan FaceNet-MTCNN yang hanya mencapai 70% dan FaceNet-HaarCascade sebesar 55% pada data baru. Hal ini mengindikasikan bahwa arsitektur VGG16

cenderung lebih luwes dalam mengenali variasi wajah di luar dataset pelatihan, sementara FaceNet lebih optimal dan stabil untuk lingkungan data yang terkontrol.

5.2. Saran

Berdasarkan hasil penelitian yang telah dilakukan, beberapa saran yang dapat diberikan untuk pengembangan dan penelitian selanjutnya adalah:

- a. Perluasan ukuran dan keberagaman dataset. Penelitian di masa depan sebaiknya menggunakan dataset yang lebih besar dan mencakup variasi kondisi lebih luas seperti ekspresi wajah, jarak kamera, serta berbagai bentuk oklusi, agar hasil evaluasi sistem lebih representatif terhadap kondisi nyata.
- b. Pengembangan sistem pengenalan wajah khusus penyandang tunanetra berbasis mobile atau embedded system. Penelitian ini masih terbatas pada lingkungan eksperimen menggunakan Google Colab. Untuk implementasi nyata, dibutuhkan pengujian dan penyesuaian pada perangkat keras yang lebih terbatas seperti smartphone atau sistem IoT.
- c. Eksplorasi teknik preprocessing lanjutan. Mengingat deteksi wajah sangat dipengaruhi oleh kualitas pencahayaan dan sudut pandang, penggunaan teknik preprocessing seperti histogram equalization, face alignment, dan peningkatan kontras gambar dapat meningkatkan keberhasilan deteksi.
- d. Integrasi sistem pengenalan wajah dengan alat bantu tunanetra. Penelitian lanjutan dapat diarahkan untuk mengintegrasikan sistem ini dengan alat bantu mobilitas atau navigasi berbasis suara guna meningkatkan kemandirian dan keselamatan penyandang tunanetra.

DAFTAR PUSTAKA

- [1] A, S. (2022). An introduction to convolutional neural networks. *Int. J. Res. Appl. Sci. Eng. Technol.*, 943–947.
- [2] Abdulhussien, D. M., & Saud, L. J. (2022). An evaluation study of face detection by Viola-Jones algorithm. *International Journal of Health Sciences*, 4174–4182.
- [3] Alexander, L. W., Sentinuwo, S. R., & Sambul, A. M. (2017). Implementasi Algoritma Pengenalan Wajah Untuk Mendeteksi Visual Hacking. *E-Journal Teknik Informatika*.
- [4] Budi, A., Inna, S., & Maulana, H. (2016). Pengenalan Citra Wajah Sebagai Identifier Menggunakan Metode. *Jurnal Teknik Informatika*, 166-175.
- [5] Cahyono, F., Wirawan, & Rachmadi, R. F. (2020). Face recognition system using facenet algorithm for employee presence. *ICOVET*, 57-62.
- [6] Christyanto, N. E., Jonemaron, E. M., & Yudistira, N. (2022). Pengembangan Aplikasi Android Presensi Kehadiran Realtimemenggunakan Pengenalan Wajah dengan Model Facenet. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 4839-4847.
- [7] Dharmawan, T., Mukminin, M. A., & Hidayat, M. A. (2024). Gender Classification Using Viola Jones, Orthogonal Difference Local Binary Pattern and Principal Component Analysis. *Matrik: Jurnal Manajemen, Teknik Informatika, dan Rekayasa Kompute*, 529-540.
- [8] Evelyn, Adipranata, R., & Gunadi, K. (2022). Sistem Presensi Mahasiswa Menggunakan Face Recognition Dengan Metode Facenet Pada Android. *Petra Cristian*.
- [9] Fahreza, M. A., Rabi, A., & Dirgantara, W. (2024). Pengembangan Sistem Pintu Portal Miniatur dengan Pengenalan Wajah Menggunakan FaceNet dan MediaPipe. *Jurnal Elkolind*, 446-455.
- [10] Gonzalez, R. C., & Woods, R. E. (2018). *Digital Image Processing*. New York: Pearson.
- [11] Hidayat, M., Yalmak, M. A., & Mardiyantoro, N. (2023). FACE RECOGNITION MENGGUNAKAN METODE VIOLA-JONES DAN LBPH PADA SISTEM PRESENSI DI PESANTREN AL-ASY'ARIYYAH III. *Jurnal Device*, 231-242.
- [12] Kamencay, P., Benco, M., Mizdos, T., & and Radil, R. (2017). A new method for face recognition using convolutional neural network. *Advances in Electrical and Electronic Engineering*.

- [13] Kristanto, V. N., Riyadi, I., & Yudi, P. (2023). Analisa Deteksi dan Pengenalan Wajah pada Citra dengan Permasalahan Visual. *JISKA (Jurnal Informatika Sunan Kalijaga)*, 78-89.
- [14] Margolang, K. F., Riyadi, S., Rosnelly, R., & Wanayumini. (2023). Pengenalan Masker Wajah Menggunakan VGG-16 dan Multilayer Perceptron. *Jurnal Telematika*, 80-87.
- [15] Mogan, J. N., Lee, C. P., Lim, K. M., & Muthu, K. S. (2022). VGG16-MLP: Gait Recognition with Fine-Tuned VGG-16 and Multilayer Perceptron. *Applied Science*, 1-12.
- [16] Ni'am, M., Mulyono, S., & Riansyah, A. (2022). Face Recognition Metode Viola-Jones dan Local Binary Patterns Histograms Sistem Pemantauan Pengunjung di Laboratorium. *Jurnal Transistor Elektro dan Informatika (TRANSISTOR EI)*, 162-170.
- [17] Pang, Y., Sun, M., Jiang, X., & Li, X. (2018). Convolution in convolution for network in network. *IEEE Transactions on Neural Networks and Learning Systems*, 1587-1597.
- [18] Permadi, Y., & Murinto. (2015). APLIKASI PENGOLAHAN CITRA UNTUK IDENTIFIKASI KEMATANGAN MENTIMUN BERDASARKAN TEKSTUR KULIT BUAH MENGGUNAKAN METODE EKSTRAKSI CIRI STATISTIK. *JURNAL INFORMATIKA*, 1028-1038.
- [19] Prasetya, D. A., & Nurviyanto, I. (2012). DETEKSI WAJAH METODE VIOLA JONES PADA OPENCV MENGGUNAKAN PEMROGRAMAN PYTHON. *Simposium Nasional RAPI*, 18-23.
- [20] Prastiwi, I. R. (2024). IMPLEMENTASI FACE RECOGNITION MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK UNTUK REKOMENDASI MODEL KACAMATA SECARA ONLINE. *Kohesi: Jurnal Multidisiplin Sainstek*.
- [21] Rahmawati, D., Pratama, M. A., & Wibisono, K. A. (2021). Alat Pendeteksi Wajah Mahasiswa Universitas Trunojoyo Madura (Utm) Menggunakan Metode Viola-Jones. *Alinier Jurnal*, 68-82.
- [22] S. Khan, H. R. (2018). *A Guide to Convolutional Neural Networks for Computer Vision*. Morgan & Claypool Publishers.
- [23] Satwikayana, S., Wibowo, S. A., & Vendyansyah, N. (2021). SISTEM PRESENSI MAHASISWA OTOMATIS PADA ZOOM MEETING MENGGUNAKAN FACE RECOGNITION DENGAN METODE

CONVOLUTIONAL NEURAL NETWORK BERBASIS WEB. *Jurnal Mahasiswa Teknik Informatika*, 785-793.

- [24] Sugeng, W., & Barus, D. (2023). Checking Passport Photos Using DNN And Facenet Methods as Facial Recognition. *Jurnal_Pekommas*, 169-180.
- [25] Tanuwijaya, E., & Roseanne, A. (2021). Classification of Indonesian Spices Digital Image using Modified VGG16 Architecture. *Jurnal Manajemen, Teknik Informatika, dan Rekayasa Komputer*, 189-196.
- [26] Wardani, K. R., Suryalim, H., Engel, V. J., & Christian, H. (2023). Analisis Pemilihan Optimizer dalam Arsitektur Convolution Neural Network VGG16 dan Inception untuk Sistem Pengenalan Wajah. *JEPIN*, 186-194.
- [27] Wiryadinata, R., Sagita, R., Wardoyo, S., & Priswanto. (2016). PENGENALAN WAJAH PADA SISTEM PRESENSI MENGGUNAKAN METODE DYNAMIC TIMES WRAPPING, PRINCIPAL COMPONENT ANALYSIS DAN GABOR WAVELET. *Dinamika Rekayasa*, 1-8.
- [28] Yusuf, A. A., Mohamad, F. S., & Sufyanu, Z. (2017). Human Face Detection Using Skin Color Segmentation and Watershed Algorithm. *American Journal of Artificial Intelligence*, 29-35.