

**PENGEMBANGAN ARSITEKTUR RESNET-18 UNTUK
KLASIFIKASI WAJAH**

SKRIPSI

**OLEH
ROJAUNA ZALFATTHORIQ
NIM. 220601110077**



**PROGRAM STUDI MATEMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM MALANG
2026**

**PENGEMBANGAN ARSITEKTUR RESNET-18 UNTUK
KLASIFIKASI WAJAH**

SKRIPSI

**Diajukan Kepada
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang
untuk Memenuhi Salah Satu Persyaratan dalam
Memperoleh Gelar Sarjana Matematika (S.Mat)**

**Oleh
Rojauna Zalfatthoriq
NIM. 220601110077**

**PROGRAM STUDI MATEMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM MALANG
2026**

PENGEMBANGAN ARSITEKTUR RESNET-18 UNTUK KLASIFIKASI WAJAH


SKRIPSI

Oleh
Rojauna Zalfatthoriq
NIM. 220601110077

Telah Disetujui Untuk Diuji


Malang, 19 Mei 2026

Dosen Pembimbing I



Hisyam Fahmi, M.Kom.
NIP. 19890727 201903 1 018

Dosen Pembimbing II



Abdul Aziz, M.Si.
NIP. 19760318 200604 1 002

Mengetahui,
Ketua Program Studi Matematika



Dr. Fachrud Rozi, M.Si.
NIP. 19800527 200801 1 012

PENGEMBANGAN ARSITEKTUR RESNET-18 UNTUK KLASIFIKASI WAJAH


SKRIPSI

Oleh
Rojauna Zalfatthoriq
NIM. 220601110077


Telah Dipertahankan di Depan Dewan Penguji Skripsi
dan Dinyatakan Diterima Sebagai Salah Satu Persyaratan
untuk Memperoleh Gelar Sarjana Matematika (S.Mat)

Tanggal, 15 Juni 2026


Ketua Penguji : Dr. Mohammad Jamhuri, M.Si.




Anggota Penguji 1 : Juhari, M.Si.



Anggota Penguji 2 : Hisyam Fahmi, M.Kom.



Anggota Penguji 3 : Abdul Aziz, M.Si.



Mengetahui,
Ketua Program Studi Matematika



Dr. Fachrur Rozi, M.Si.

NIP. 19800527 200801 1 012

PERNYATAAN KEASLIAN TULISAN

Saya bertanda tangan di bawah ini

Nama : Rojauna Zalfatthoriq

NIM : 220601110077

Program Studi : Matematika

Fakultas : Sains dan Teknologi

Judul Skripsi : Pengembangan Arsitektur ResNet-18 untuk Klasifikasi Wajah

Menyatakan bahwa skripsi yang saya tulis ini merupakan hasil karya sendiri, bukan mengambil alih tulisan atau pemikiran orang lain. Saya menyatakan skripsi ini sebagai pemikiran saya, kecuali dengan mencantumkan sumber kutipan pada daftar rujukan di halaman terakhir. Apabila dikemudian hari terbukti atau dapat dibuktikan skripsi ini hasil plagiasi atau tiruan orang lain, maka saya bersedia menerima sanksi atas perbuatan tersebut.

Malang, 15 Juni 2026



Rojauna Zalfatthoriq

NIM. 220601110017

MOTO

“Setialah pada gagasan, jangan menyisakan ruang untuk membenci manusia.”

HALAMAN PERSEMBAHAN

Dengan segenap hati, rasa syukur dan rasa bahagia karena telah samapi pada titik ini, tentunya bukan suatu hal yang mudah, tetapi dengan niat, dukungan dan juga doa dari orang-orang baik disekitar saya, pada akhirnya tugas akhir ini terselesaikan dengan baik. Saya persembahkan Skripsi ini untuk:

1. Teruntuk orang tua tercinta, Abah Asmungi dan Ibu Istiqomah, yang dalam diamnya menyimpan doa paling tulus, yang dalam lelahnya tetap tersenyum demi masa depanku, dan yang dalam setiap langkahku selalu menjadi alasan untuk tidak menyerah. Jika hari ini ada satu pencapaian yang bisa kubanggakan, sesungguhnya itu adalah pantulan dari cinta, pengorbanan, dan keteguhan hati kalian yang tak pernah meminta balasan.
2. Teruntuk kakak-adikku, yang menjadi penguat dalam setiap lelah dan pengingat bahwa aku harus terus melangkah lebih jauh. Semoga setiap capaian ini bukan hanya menjadi kebanggaanku, tetapi juga jejak kecil yang menginspirasi langkah kalian menuju masa depan yang lebih gemilang.

KATA PENGANTAR

Segala puji bagi Allah Swt. atas segala rahmat, taufik, dan karunia-Nya sehingga penulis mampu menyelesaikan skripsi ini hingga akhir. Skripsi ini disusun sebagai salah satu syarat untuk meraih gelar Sarjana Matematika (S.Mat) pada Program Studi Matematika, Fakultas Sains dan Teknologi, Universitas Islam Negeri Maulana Malik Ibrahim Malang. Penyusunan skripsi ini tidak lepas dari dukungan, motivasi, dan bantuan berbagai pihak. Oleh karena itu, penulis ingin mengucapkan terima kasih yang sebesar-besarnya kepada semua pihak selama proses penyusunan skripsi ini. Secara khusus, penulis juga ingin mengucapkan terima kasih kepada:

1. Prof. Dr. Hj. Ilfi Nurdiana, M.Si., CAHRM., CRMP, selaku Rektor Universitas Islam Negeri Maulana Malik Ibrahim Malang, atas jasanya memimpin kampus tercinta ini.
2. Dr. H. Agus Mulyono, S.Pd., M.Kes, selaku Dekan Fakultas Sains dan Teknologi, atas jasanya memberikan dukungan dan fasilitas selama penulis menjalani masa studi.
3. Dr. Fachrur Rozi, M.Si., selaku Ketua Program Studi Matematika, atas jasanya dalam memberikan bimbingan dan motivasi.
4. Hisyam Fahmi, M.Kom., selaku dosen Ketua Konsorsium Komputasi, yang sekaligus menjadi Dosen Pembimbing I, atas ilmu, bimbingan, serta inspirasi yang diberikan dalam bidang komputasi, sekaligus memberikan bimbingan, dukungan, dan arahan yang sangat berharga dalam penyusunan skripsi ini. Semoga ilmu dan waktu yang telah beliau berikan menjadi amal jariyah yang bernilai di sisi Allah Swt.
5. Abdul Aziz, M.Si., selaku Dosen Pembimbing II, atas kesabaran, masukan, serta saran yang sangat membantu dalam proses penelitian dan penulisan skripsi ini.
6. Muhammad Khudzaifah, M.Si., selaku Dosen Wali, yang telah memberikan arahan, nasihat, dan motivasi selama masa perkuliahan.
7. Seluruh Dosen Program Studi Matematika, Fakultas Sains dan Teknologi, Universitas Islam Negeri Maulana Malik Ibrahim Malang, yang telah

membekali penulis dengan ilmu, motivasi, dan semangat belajar selama masa studi.

8. Teman-teman Konsorsium Komputasi, atas kerja sama, semangat belajar, dan dukungan selama menempuh mata kuliah serta penelitian di bidang komputasi. Kebersamaan ini menjadi pengalaman berharga bagi penulis dalam mengembangkan kemampuan akademik maupun profesional.
9. Teman-teman kelas A angkatan 2022 dan seluruh mahasiswa Matematika angkatan 2022 (Mathdeux) atas kebersamaan, dukungan, dan semangat yang diberikan selama proses perkuliahan hingga penyusunan proposal skripsi ini.

Penulis menyadari bahwa skripsi ini masih jauh dari kesempurnaan. Oleh karena itu, kritik dan saran yang membangun sangat penulis harapkan demi kesempurnaan karya ini. Semoga skripsi ini dapat memberikan manfaat, baik bagi penulis maupun bagi pembaca.

Malang, 15 Juni 2026

Penulis

DAFTAR ISI

HALAMAN JUDUL	i
HALAMAN PENGAJUAN	ii
HALAMAN PERSETUJUAN	iii
HALAMAN PENGESAHAN	iv
PERNYATAAN KEASLIAN TULISAN	v
MOTTO	vi
HALAMAN PERSEMBAHAN	vii
KATA PENGANTAR.....	iviii
DAFTAR ISI.....	x
DAFTAR TABEL	xii
DAFTAR GAMBAR.....	xiii
DAFTAR SIMBOL	xiv
ABSTRAK	xv
ABSTRACT	xvi
مستخلص البحث	xvii
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	4
1.3 Tujuan Penelitian	4
1.4 Manfaat Penelitian	4
1.5 Batasan Masalah.....	5
1.6 Definisi Istilah.....	6
BAB II KAJIAN TEORI	7
2.1 Teori Pendukung.....	7
2.1.1 <i>Artificial Intelligence</i>	7
2.1.2 <i>Machine Learning</i>	8
2.1.3 <i>Deep Learning</i>	11
2.1.4 <i>Convolutional Neural Network (CNN)</i>	12
2.1.5 Fungsi Aktivasi	18
2.1.6 <i>Residual Network (ResNet)</i>	19
2.1.7 Arsitektur ResNet-18.....	20
2.1.8 Modifikasi ResNet-18	22
2.1.9 Evaluasi Model.....	24
2.2 Kajian Integrasi Topik dengan Al-Quran/Hadis	26
2.3 Kajian Topik dengan Teori Pendukung	27
BAB III METODE PENELITIAN	29
3.1 Jenis Penelitian.....	29
3.2 Data dan Sumber Data	29
3.3 Tahapan Penelitian	29
BAB IV HASIL DAN PEMBAHASAN	33
4.1 Pengembangan Arsitektur ResNet-18	33
4.2 Implementasi Arsitektur Modifikasi ResNet-18	40
4.3 Implementasi Modifikasi ResNet-18 dalam Pandangan Islam	45
BAB V PENUTUP	46

5.1 Kesimpulan	46
5.2 Saran.....	46
DAFTAR PUSTAKA	47
RIWAYAT HIDUP	49

DAFTAR TABEL

Tabel 2.1 Arsitektur ResNet-18 (Sumber: He dkk., 2016)	21
Tabel 2.2 <i>Confusion Matrix</i> (Sumber: Han dkk., 2011)	24
Tabel 4.1 Hasil Pengujian <i>Convolution Layer</i> Awal	34
Tabel 4.2 Hasil Pengujian <i>Max-Pooling</i> Awal	37
Tabel 4.3 Hasil Pengujian Penambahan SE Block	38
Tabel 4.4 Hasil Pengujian Penggunaan Dropout	38
Tabel 4.5 Hasil Evaluasi Model Terbaik.....	43
Tabel 4.6 Rata-rata Model Terbaik	43
Tabel 4.7 Perbandingan Akurasi dengan Penelitian Terdahulu	44

DAFTAR GAMBAR

Gambar 2.1 <i>Layer</i> CNN (Sumber: Saha, 2023)	13
Gambar 2.2 <i>Pooling</i> (Sumber: Yani, 2019)	16
Gambar 2.3 Ilustrasi <i>Flattening</i> (Sumber: Pandey, 2024)	17
Gambar 2.4 Fungsi Aktivasi (Sumber: Ayush, 2022).....	19
Gambar 2.5 ResNet <i>Block</i> 1×1 Konvolusi (Sumber: d2l.ai).....	19
Gambar 2.6 Arsitektur ResNet-18 (Sumber: d2l.ai)	20
Gambar 3.1 Alur Penelitian.....	30
Gambar 4.1 Sampel Citra 28 Individu	41
Gambar 4.2 <i>Training</i> dan <i>Validation Loss</i>	42

DAFTAR SIMBOL

X	: Dataset citra wajah sebagai input sistem.
Y	: Label atau kelas identitas wajah sebenarnya.
$x^{(i)}$	: Citra wajah ke- i dalam dataset.
$\hat{y}^{(i)}$	: Hasil prediksi identitas untuk citra ke- i .
w, b	: Bobot dan bias pada jaringan saraf.
$z^{(i)}$	: Kombinasi linier antara bobot dan fitur pada neuron ke- i .
$a^{(i)}$	: Aktivasi atau keluaran dari neuron ke- i .
η	: <i>Learning rate</i> , laju pembaruan parameter saat pelatihan.
$\mathcal{L}$	: Fungsi <i>loss</i> yang digunakan untuk mengukur kesalahan prediksi.
k	: Kernel atau filter konvolusi pada CNN.
s	: <i>Stride</i> , jarak pergeseran filter saat konvolusi.
p	: <i>Padding</i> , penambahan piksel di tepi citra input.

ABSTRAK

Zalfatthoriq, Rojauna. 2026. **Pengembangan Arsitektur ResNet-18 untuk Klasifikasi Wajah**. Skripsi. Program Studi Matematika, Fakultas Sains dan Teknologi, Universitas Islam Negeri Maulana Malik Ibrahim Malang.
Pembimbing: (I) Hisyam Fahmi, M.Kom. (II) Abdul Aziz, M.Si.

Kata Kunci: Klasifikasi Wajah, ResNet-18, Pembelajaran Mesin, Dropout.

Penelitian ini bertujuan memperoleh model hasil pengembangan ResNet-18 yang optimal untuk klasifikasi wajah serta mengevaluasi performanya pada dataset Extended Yale Face Database B. Pengembangan arsitektur dilakukan secara bertahap melalui modifikasi *convolution layer* awal, pengujian penggunaan *max-pooling* awal, dan penerapan *dropout*. Dataset dibagi menjadi data *training*, *validation*, dan *testing* dengan rasio 70:10:20. Model dilatih menggunakan *learning rate* sebesar 0.001, *batch size* sebesar 32, dan jumlah *epoch* sebanyak 50. Hasil penelitian menunjukkan bahwa konfigurasi terbaik diperoleh pada arsitektur Modifikasi ResNet-18 yang menggunakan *convolution layer* awal dengan kernel berukuran 5×5 , *stride* 2, *zero padding* dan channel berjumlah 32, mempertahankan *max-pooling* awal, serta menerapkan *dropout* sebelum *fully connected layer*. Model akhir berhasil memperoleh *accuracy* sebesar 98.36% dan F1-score sebesar 98.37%.

ABSTRACT

Zalfatthoriq, Rojauna. 2026. **Development of a ResNet-18 Architecture for Face Classification**. Undergraduate Thesis. Mathematics Study Program, Faculty of Science and Technology, Universitas Islam Negeri Maulana Malik Ibrahim Malang.

Advisors: (I) Hisyam Fahmi, M.Kom. (II) Abdul Aziz, M.Si.

Keywords: Face Classification, ResNet-18, Machine Learning, Dropout.

This study aims to develop an optimal modified ResNet-18 model for face classification and evaluate its performance on the Extended Yale Face Database B dataset. The architecture was developed sequentially through modifications to the initial convolution layer, evaluation of the initial max-pooling operation, and the application of dropout. The dataset was divided into training, validation, and testing sets with a ratio of 70:10:20. The model was trained using a learning rate of 0.001, a batch size of 32, and 50 epochs. The results showed that the best configuration was achieved by the modified ResNet-18 architecture employing an initial convolution layer with a 3×3 kernel, stride of 1, zero padding, and 32 output channels, while retaining the initial max-pooling layer, and applying dropout before the fully connected layer. The final model achieved 98.36% accuracy and 98.37% F1-score.

مستخلص البحث

زلف الطريق، رجونا. ٢٠٢٦. تطوير بنية **ResNet-١٨** لتصنيف الأوجه. البحث العلمي. برنامج دراسة الرياضيات، كلية العلوم والتكنولوجيا، جامعة مولانا مالك إبراهيم الإسلامية الحكومية، مالانج.
المشرف: (١) هشام فهمي، الماجستير في علوم الحاسوب. (٢) عبد العزيز، الماجستير في العلوم.

الكلمات المفتاحية: تصنيف الأوجه، **ResNet-١٨**، التعلم الآلي، *Dropout*.

هدفت هذه الدراسة إلى تطوير نموذج **ResNet-١٨** معدل ومحسن لتصنيف الأوجه، وتقييم أدائه على مجموعة بيانات *Extended Yale Face Database B*. تم تطوير البنية تدريجيًا من خلال إجراء تعديلات على طبقة الالتفاف الأولية، وتقييم طبقة التجميع الأقصى الأولي، وتطبيق تقنية التعطيل العشوائي. تم تقسيم مجموعة البيانات إلى مجموعات للتدريب والتحقق والاختبار بنسبة ٧٠٪ : ١٠٪ : ٢٠٪. تم تدريب النموذج باستخدام معدل تعلم قدره ٠,٠٠١، وحجم دفعة قدرها ٣٢، ولمدة ٥٠ حقبة تدريبية. أظهرت النتائج أن أفضل أداء تحقق باستخدام بنية **ResNet-١٨** المعدلة التي اعتمدت على طبقة التفاف أولية بنواة ٣×٣، وخطوة ١، وحشو صفري، و٣٢ قناة إخراج، مع الاحتفاظ بطبقة التجميع الأقصى الأولي، وتطبيق طبقة التعطيل العشوائي قبل الطبقة المتصلة بالكامل. حقق النموذج النهائي دقة بلغت ٣٦.٩٨٪، وبلغت قيمة مقياس *F1* نسبة ٣٧.٩٨٪.

BAB I

PENDAHULUAN

1.1 Latar Belakang

Perkembangan teknologi kecerdasan buatan dalam dua dekade terakhir telah membawa kemajuan signifikan di berbagai bidang, salah satunya dalam pengenalan pola visual (Zhao et al., 2003). Salah satu implementasi yang paling menonjol dari kemajuan tersebut adalah *face recognition* atau pengenalan wajah, yakni proses mengidentifikasi seseorang berdasarkan citra wajah. Dalam pemodelan citra wajah, *Convolutional Neural Network* (CNN) telah menjadi pendekatan yang sangat efektif dalam mengekstraksi representasi spasial dari gambar dua dimensi, dengan menangkap pola lokal melalui operasi konvolusi dan menggabungkannya dengan fungsi aktivasi non-linear untuk membentuk representasi fitur yang semakin abstrak, sehingga secara hierarkis mengubah data citra mentah menjadi vektor fitur berdimensi tinggi yang lebih bermakna (LeCun et al., 2015). Salah satu pengembangan penting dari CNN adalah *Residual Network* (ResNet), yang diperkenalkan oleh He dkk (2016) untuk mengatasi masalah *vanishing gradient* dan penurunan akurasi pada jaringan yang semakin dalam, dengan memperkenalkan jalur penghubung langsung antar lapisan (*shortcut connection*), membuat jaringan mampu mempelajari fungsi residu (*residual function*) alih-alih fungsi langsung, sehingga mempercepat konvergensi dan meningkatkan performa model.

Di sisi lain, penelitian mengenai pengenalan wajah berbasis CNN terus mengalami perkembangan pesat dalam beberapa tahun terakhir, terutama dalam menghadapi tantangan variasi pencahayaan. George dkk. (2023) meneliti efektivitas arsitektur CNN ringan dalam mengekstraksi fitur wajah pada kondisi

pencahayaannya yang beragam dan mencapai akurasi 94,85% pada dataset IJB-C. Sementara itu, Nguyen dan Chu (2023) melakukan studi komparatif terhadap beberapa arsitektur pengenalan wajah, termasuk CNN klasik dan model berbasis *transfer learning*, untuk menguji ketahanannya terhadap pencahayaannya yang bervariasi dan menunjukkan bahwa CNN murni mampu mencapai akurasi hingga 93,7% pada pencahayaannya ideal, meskipun performanya menurun sedikit di bawah 90% pada skenario *low-light*. Penelitian lain oleh Kurniadi dkk. (2025) secara khusus menyoroti masalah pencahayaannya rendah dalam pengenalan wajah dengan menggabungkan representasi fitur *DeepFace embedding* berbasis CNN dan *Multilayer Perceptron*, berhasil mencapai akurasi hingga 95,16% pada dataset uji.

Meskipun berbagai pendekatan di atas menunjukkan hasil yang memuaskan, tantangan besar masih tersisa pada pengenalan wajah yang melibatkan variasi pose atau sudut pandang dan pencahayaannya secara bersamaan. Secara umum, penelitian terdahulu cenderung hanya memfokuskan pada satu faktor variabilitas, entah pencahayaannya, ekspresi, atau pose, tanpa menguji *robustness* model terhadap kombinasi kondisi yang kompleks sebagaimana terjadi di dunia nyata. Celah inilah yang menunjukkan perlunya penelitian lebih lanjut dalam membangun model pengenalan wajah yang mampu beradaptasi terhadap berbagai variasi pose dan pencahayaannya sekaligus.

Dari perspektif Islam, manusia merupakan makhluk yang diberikan keistimewaan khusus dibandingkan makhluk lainnya, baik dalam struktur penciptaannya maupun kemampuan akal yang dimilikinya. Allah berfirman dalam QS. At-Tin ayat 4 (Kemenag, 2022) yang artinya:

“Sungguh, Kami benar-benar telah menciptakan manusia dalam bentuk yang sebaik-baiknya.”

Ayat ini menegaskan bahwa manusia diciptakan dalam keadaan *ahsani taqwīm*, yaitu bentuk penciptaan yang paling sempurna. Dalam konteks ilmiah, kemampuan manusia untuk merancang teknologi seperti CNN dan sistem *face recognition* dapat dipandang sebagai manifestasi dari potensi intelektual yang merupakan bagian dari kesempurnaan penciptaan tersebut.

Selain itu, pada QS. Ar-Rūm ayat 22 (Kemenag, 2022) Allah berfirman yang artinya:

“Dan di antara tanda-tanda kekuasaan-Nya ialah penciptaan langit dan bumi, dan perbedaan bahasamu dan warna kulitmu. Sungguh, pada yang demikian itu benar-benar terdapat tanda-tanda bagi orang-orang yang mengetahui.”

Ayat ini menunjukkan bahwa keberagaman karakteristik manusia merupakan bagian dari desain penciptaan ilahi yang penuh hikmah. Dalam perkembangan teknologi modern, konsep keberagaman karakteristik ini menjadi dasar dalam sistem biometrik, termasuk teknologi pengenalan wajah yang bekerja dengan mengidentifikasi ciri unik yang membedakan satu individu dengan individu lainnya.

Dalam penelitian ini, akan dilakukan pengembangan arsitektur ResNet-18 untuk menganalisis performanya pada dataset citra wajah dengan kondisi pencahayaan dan pose yang bervariasi. Tujuannya adalah untuk menghasilkan model yang *robust* yang tidak hanya mampu mendeteksi wajah dengan akurat pada kondisi pencahayaan ideal, tetapi juga tetap stabil pada pencahayaan rendah, berlebih, tidak merata, serta sudut pandang yang berbeda-beda. Dengan dukungan arsitektur ResNet yang telah terbukti andal dalam ekstraksi fitur mendalam serta strategi optimasi yang disesuaikan dengan keterbatasan dataset, diharapkan penelitian ini dapat memberikan kontribusi terhadap pengembangan model

pengenalan wajah yang lebih tangguh pada skenario dunia nyata dengan kondisi data yang heterogen.

1.2 Rumusan Masalah

Penelitian ini dirancang untuk menjawab pertanyaan utama berikut:

1. Bagaimana model modifikasi ResNet-18 didapatkan untuk melakukan klasifikasi wajah pada dataset dengan pose dan kondisi pencahayaan yang bervariasi?
2. Bagaimana performa model modifikasi ResNet-18 dalam melakukan klasifikasi wajah pada dataset dengan pose dan kondisi pencahayaan yang bervariasi?

1.3 Tujuan Penelitian

Sesuai dengan rumusan masalah, penelitian ini bertujuan:

1. Merancang model modifikasi ResNet-18 melakukan klasifikasi wajah dengan pose dan kondisi pencahayaan yang bervariasi.
2. Menganalisis hasil performa model Mmodifikasi ResNet-18 dalam melakukan klasifikasi wajah dengan pose dan kondisi pencahayaan yang bervariasi.

1.4 Manfaat Penelitian

Penelitian ini diharapkan mampu memberikan manfaat, yaitu:

1. Manfaat Teoritis
 - a. Memberikan kontribusi bagi pengembangan ilmu pengetahuan di bidang penerapan asitektur ResNet dalam sistem pengenalan wajah.

- b. Memperkaya literatur mengenai penerapan ResNet pada konteks klasifikasi wajah dengan dataset terbatas, variasi tingkat pencahayaan dan pose yang beragam.

2. Manfaat Praktis

- a. Bagi pengembang sistem berbasis *computer vision*, hasil penelitian ini diharapkan dapat memberikan wawasan mengenai penerapan ResNet dalam mengatasi tantangan pengenalan wajah pada kondisi data yang terbatas dan pencahayaan serta pose yang bervariasi.
- b. Bagi institusi pendidikan maupun lembaga penelitian, penelitian ini diharapkan dapat menjadi referensi dalam mengembangkan model pengenalan wajah yang efisien dan adaptif terhadap kondisi lingkungan yang tidak ideal.

1.5 Batasan Masalah

Agar penelitian ini terarah dan fokus pada lingkup kajian yang dapat diselesaikan secara sistematis, maka dilakukan beberapa pembatasan masalah sebagai berikut:

1. Data yang digunakan dalam penelitian ini berupa citra wajah yang diambil dari dataset publik di Kaggle.
2. Dataset hanya mencakup area wajah (*face region*) tanpa melibatkan bagian tubuh lainnya.
3. Jumlah total data yang digunakan adalah 16.380 citra wajah dengan variasi kondisi pencahayaan dan pose.

1.6 Definisi Istilah

Beberapa istilah yang digunakan dalam penelitian ini:

Konvolusi	: Proses utama dalam CNN yang mengekstraksi fitur penting dari citra melalui operasi filter atau kernel.
Kernel	: Matriks kecil pada proses konvolusi yang berfungsi sebagai filter untuk mendeteksi fitur spesifik seperti tepi, tekstur, atau pola pada citra wajah.
<i>Padding</i>	: Teknik penambahan nilai, umumnya bernilai nol (<i>zero padding</i>), pada tepi citra atau <i>feature map</i> .
<i>Stride</i>	Parameter yang menentukan jumlah pergeseran kernel pada proses konvolusi.
<i>Pooling</i>	Proses mereduksi dimensi <i>feature map</i> untuk mengurangi kompleksitas dalam komputasi, serta mempertahankan fitur-fitur yang penting, misalnya menggunakan <i>average pooling</i> untuk mengambil nilai rata-rata pada suatu area <i>feature map</i> .
Klasifikasi	: Tahap akhir pada CNN yang bertujuan menentukan kelas atau identitas citra berdasarkan fitur-fitur yang telah dipelajari oleh model.

BAB II

KAJIAN TEORI

2.1 Teori Pendukung

2.1.1 *Artificial Intelligence*

Artificial intelligence (kecerdasan buatan) merupakan salah satu cabang dari ilmu komputer dan matematika terapan yang berfokus pada pengembangan sistem yang mampu meniru kemampuan kognitif manusia, seperti belajar, bernalar, mengenali pola, mengambil keputusan, dan memecahkan masalah secara otomatis (Russell & Norvig, 2010). *Artificial intelligence* memiliki beragam pengertian yang dikemukakan oleh para ahli, seiring perkembangan teknologi dan sudut pandang keilmuan yang terus berubah. Di antaranya adalah sebagai berikut:

1. Dalam buku “Artificial Intelligence: Foundations of Computational Agents”, *artificial intelligence* didefinisikan sebagai studi mengenai perancangan agen cerdas yang mampu bertindak rasional berdasarkan persepsi terhadap lingkungannya (Poole & Mackworth, 2010).
2. Buku “Deep Learning” menjelaskan bahwa *artificial intelligence* merupakan bidang yang berupaya memungkinkan komputer menyelesaikan tugas-tugas yang biasanya membutuhkan kecerdasan manusia, seperti pengenalan pola, pengambilan keputusan, dan pembelajaran dari data (Goodfellow et al., 2016).
3. Dalam buku “Machine Learning”, *artificial intelligence* berkaitan erat dengan kemampuan sistem untuk belajar dari pengalaman, di mana sebuah

program dikatakan belajar apabila performanya meningkat seiring bertambahnya data atau pengalaman yang diterima (Mitchell, 1997).

4. Buku “Artificial Intelligence for Humans” mendefinisikan *artificial intelligence* sebagai teknologi yang memungkinkan mesin meniru proses berpikir manusia melalui logika, aturan, dan algoritma komputasi (Heaton, 2013).

Secara umum, *artificial intelligence* bertujuan untuk menciptakan mesin atau program yang dapat bekerja secara cerdas berdasarkan data dan pengalaman, sehingga mampu membantu maupun menggantikan sebagian tugas manusia. Teknologi ini berkembang pesat dan digunakan secara luas dalam berbagai bidang, seperti kesehatan, pendidikan, industri, transportasi, keamanan, serta layanan digital (Goodfellow et al., 2016).

2.1.2 Machine Learning

Machine Learning (ML) merupakan salah satu cabang dari *artificial intelligence* yang berfokus pada pengembangan sistem komputer agar mampu belajar secara otomatis dari data tanpa harus diprogram secara rinci untuk setiap tugas tertentu. Dalam pendekatan tradisional, komputer bekerja berdasarkan instruksi yang ditulis secara eksplisit oleh programmer. Namun pada *machine learning*, sistem dibekali algoritma yang dapat menganalisis data, menemukan pola, lalu menggunakan pola tersebut untuk membuat prediksi atau keputusan (Mitchell, 1997).

Proses utama dalam *machine learning* adalah membangun model berdasarkan data yang diberikan. Model ini terbentuk setelah algoritma mempelajari hubungan, kecenderungan, atau karakteristik tertentu dari

sekumpulan data pelatihan. Semakin relevan dan berkualitas data yang digunakan, maka semakin baik pula kemampuan model dalam mengenali situasi baru. Dengan kata lain, *machine learning* mengubah data menjadi pengetahuan yang dapat dimanfaatkan oleh sistem komputer (Goodfellow et al., 2016).

Machine learning disebut sebagai bagian dari *artificial intelligence* karena konsep kerjanya meniru cara manusia belajar melalui pengalaman. Manusia dapat mengenali pola setelah melihat banyak contoh, misalnya membedakan buah matang dan mentah atau mengenali wajah seseorang setelah sering bertemu. Demikian pula, sistem *machine learning* belajar dari contoh-contoh sebelumnya untuk menyelesaikan permasalahan baru yang serupa. Setelah memahami pola historis, model dapat digunakan untuk klasifikasi, prediksi, rekomendasi, maupun deteksi anomali. Contoh penerapan *machine learning* dapat ditemukan dalam kehidupan sehari-hari, seperti sistem rekomendasi film pada *platform streaming*, filter spam pada email, pengenalan wajah pada *smartphone*, serta diagnosis penyakit berbasis data medis.

Secara umum, *machine learning* dibagi ke dalam empat jenis utama berdasarkan cara sistem belajar dari data, yaitu *supervised learning*, *unsupervised learning*, *semi-supervised learning*, dan *reinforcement learning* (Goodfellow et al., 2016). Masing-masing pendekatan memiliki karakteristik, tujuan, serta metode penggunaan yang berbeda sesuai dengan jenis permasalahan yang dihadapi.

1. *Supervised learning* merupakan metode pembelajaran mesin yang menggunakan data berlabel, yaitu data yang telah memiliki pasangan *input* dan *output* yang benar. Pendekatan ini banyak digunakan untuk tugas

klasifikasi dan regresi. Contohnya adalah memprediksi apakah email termasuk spam atau bukan, mengenali jenis penyakit berdasarkan gejala pasien, serta memperkirakan harga rumah berdasarkan luas tanah dan lokasi (Alpaydm, 2010). Beberapa algoritma yang umum digunakan pada *supervised learning* antara lain Linear Regression, Logistic Regression, Decision Tree, Random Forest, Support Vector Machine, dan Neural Network (Bishop, 2006).

2. *Unsupervised learning* adalah metode pembelajaran yang menggunakan data tanpa label, sehingga sistem harus menemukan pola atau struktur tersembunyi secara mandiri. Fokus utama pendekatan ini adalah mengelompokkan data yang mirip atau mereduksi dimensi data agar lebih mudah dianalisis. Contoh penerapannya yaitu segmentasi pelanggan berdasarkan pola belanja, pengelompokan dokumen berdasarkan topik, serta deteksi pola tersembunyi dalam data besar. Algoritma yang sering digunakan pada *unsupervised learning* antara lain K-Means Clustering, Hierarchical Clustering, DBSCAN, dan Principal Component Analysis (Han et al., 2012).
3. *Semi-supervised learning* merupakan gabungan antara *supervised learning* dan *unsupervised learning*. Pada metode ini, sebagian kecil data memiliki label, sedangkan sebagian besar lainnya tidak berlabel. Pendekatan ini berguna ketika proses pelabelan data membutuhkan biaya mahal, waktu lama, atau tenaga ahli. Contohnya terdapat pada klasifikasi citra medis, di mana hanya sebagian gambar yang diberi label oleh dokter spesialis, sedangkan ribuan gambar lain belum diberi anotasi. Dengan

memanfaatkan kombinasi data tersebut, model diharapkan tetap dapat mencapai performa yang baik (Chapelle et al., 2006).

4. *Reinforcement learning* adalah metode pembelajaran mesin di mana agen belajar melalui interaksi dengan lingkungan. Sistem akan menerima *reward* jika tindakan yang diambil benar dan *penalty* jika salah, sehingga secara bertahap agen belajar memilih tindakan terbaik untuk memaksimalkan keuntungan jangka panjang. Pendekatan ini banyak digunakan pada robotika, permainan komputer, kendaraan otonom, serta optimasi keputusan dinamis. Contoh yang sudah *masyhur* adalah sistem AI yang mampu mengalahkan pemain manusia pada permainan catur, Go, dan berbagai game strategi kompleks semisalnya (Sutton & Barto, 2015).

2.1.3 *Deep Learning*

Deep Learning merupakan salah satu cabang utama dari *machine learning* yang menggunakan struktur jaringan saraf tiruan (*artificial neural network*) dengan banyak lapisan (*deep neural networks*) untuk mempelajari representasi data yang kompleks dan bersifat hierarkis (Goodfellow et al., 2016). Konsep ini berakar dari penelitian lama mengenai jaringan saraf tiruan yang mulai berkembang sejak dekade 1940-an, namun baru mengalami kemajuan pesat setelah tahun 2010 berkat peningkatan kemampuan komputasi GPU, ketersediaan data besar (*big data*), serta inovasi arsitektur jaringan saraf (LeCun et al., 2015).


Menurut LeCun, Bengio, dan Hinton (2015), *deep learning* memungkinkan komputer belajar langsung dari data mentah melalui serangkaian transformasi non-linear yang disusun secara bertingkat (*layered representation*

learning). Setiap lapisan dalam jaringan secara otomatis mengekstraksi fitur dari data pada tingkat kompleksitas yang semakin tinggi, dari pola sederhana seperti tepi dan sudut pada lapisan awal, hingga bentuk atau objek utuh pada lapisan yang lebih dalam.

2.1.4 Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) atau ConvNet merupakan salah satu jenis jaringan saraf tiruan yang dirancang khusus untuk memproses data berbentuk *grid*, terutama citra digital. CNN menjadi arsitektur yang sangat populer dalam bidang *deep learning* karena memiliki kemampuan tinggi dalam mengenali pola visual seperti tepi, tekstur, bentuk, hingga objek kompleks secara otomatis (Goodfellow et al., 2016). Berbeda dengan metode-metode klasifikasi konvensional yang memerlukan ekstraksi fitur secara manual, CNN mampu mempelajari fitur-fitur penting langsung dari data gambar mentah melalui proses pelatihan *end-to-end*, sehingga sangat efektif untuk tugas klasifikasi citra, deteksi objek, segmentasi gambar, dan pengenalan wajah (Krizhevsky et al., 2012).

Secara umum, arsitektur dasar CNN terdiri atas beberapa lapisan utama, yaitu *convolution layer*, *pooling layer*, dan *fully connected layer*. Kombinasi lapisan-lapisan ini memungkinkan sistem mengekstraksi informasi visual secara bertingkat, mulai dari fitur sederhana pada lapisan awal hingga representasi yang lebih abstrak pada lapisan dalam (LeCun et al., 2015). Untuk lebih jelasnya, arsitektur CNN dapat dilihat pada Gambar 2.1. Seiring perkembangan penelitian, arsitektur dasar tersebut kemudian dikembangkan menjadi model yang lebih kompleks seperti AlexNet, VGGNet, ResNet, GoogLeNet, dan EfficientNet untuk meningkatkan akurasi serta efisiensi komputasi (Tan & Le, 2019).



Gambar 2.1 Layer CNN (Sumber: Saha, 2023)

Lapisan *convolution* merupakan komponen inti dan biasanya menjadi lapisan pertama yang menerima citra masukan. Pada lapisan ini digunakan kernel atau filter berukuran kecil yang bergerak di seluruh area gambar untuk mendeteksi pola tertentu. Setiap filter melakukan operasi konvolusi dengan menghitung hasil perkalian elemen-elemen filter terhadap nilai piksel pada area lokal gambar, kemudian menjumlahkannya dan menambahkan bias, yang kemudian hasilnya dilewatkan ke fungsi aktivasi seperti ReLU untuk menghasilkan *feature map*, yaitu representasi fitur hasil deteksi pola pada gambar (Goodfellow et al., 2016). Perpindahan filter secara horizontal maupun vertikal pada citra itu disebut *stride*. Nilai *stride* menentukan seberapa jauh filter bergeser setiap langkah. Penggunaan *stride* yang lebih besar dapat mengurangi ukuran *feature map* sehingga menurunkan kebutuhan komputasi, meskipun berpotensi mengurangi detail informasi visual. Selain *stride*, sering digunakan pula teknik *padding*, yaitu penambahan piksel di tepi gambar agar ukuran *output* tetap terjaga dan informasi di bagian pinggir citra tidak hilang. Operasi pada lapisan *convolution* dapat dinyatakan sebagaimana Persamaan 2.1.

$$w * a_{x,y} = \sum_{l=1}^L \sum_{k=1}^K w_{l,k} a_{x+l,y+k} \quad (2.1)$$

Pada Persamaan 2.1, nilai $a_{x,y}$ menyatakan piksel pada citra masukan di posisi (x, y) , sedangkan w menunjukkan kernel atau filter yang digunakan dalam proses konvolusi. Nilai L dan K menyatakan ukuran kernel pada arah baris dan kolom. Apabila ke dalam hasil konvolusi ditambahkan parameter bias, maka bentuk persamaan tersebut dapat dituliskan kembali seperti pada Persamaan 2.2.

$$z = w * a_{x,y} + b \quad (2.2)$$

Pada CNN modern, umumnya, diterapkan proses Batch Normalization untuk menstabilkan distribusi data keluaran dari lapisan *convolution*. Batch Normalization dilakukan dengan melakukan normalisasi terhadap nilai aktivasi menggunakan rata-rata dan variansi *mini-batch* sehingga proses pelatihan jaringan menjadi lebih stabil dan cepat. Proses normalisasi dapat dituliskan sebagai berikut.

$$\hat{x} = \frac{x - \mu}{\sqrt{\sigma^2 + \epsilon}} \quad (2.3)$$

Pada persamaan tersebut, x menyatakan input aktivasi, μ merupakan nilai rata-rata *mini-batch*, σ^2 merupakan variansi *mini-batch*, dan ϵ merupakan konstanta kecil untuk menghindari pembagian dengan nol. Setelah melalui proses normalisasi, Batch Normalization menerapkan transformasi linear melalui proses *scale* dan *shift* menggunakan parameter γ dan β , yang secara matematis dapat dituliskan sebagai berikut.

$$y = \gamma \hat{x} + \beta \quad (2.4)$$


Pada persamaan tersebut, parameter γ berfungsi mengatur skala distribusi data, sedangkan parameter β berfungsi menggeser distribusi data. Kedua

parameter tersebut dipelajari secara otomatis selama proses pelatihan jaringan sehingga model tetap memiliki fleksibilitas dalam mempelajari representasi fitur yang optimal. Setelah melalui proses Batch Normalization, hasil tersebut kemudian dimasukkan ke dalam fungsi aktivasi.

Selanjutnya, lapisan *pooling* merupakan komponen pada arsitektur CNN yang berfungsi untuk mengurangi ukuran atau resolusi spasial dari *feature map* yang dihasilkan oleh lapisan *convolution* setelah melewati fungsi aktivasi. Proses ini bertujuan menyederhanakan representasi data, menurunkan jumlah parameter, serta mempercepat komputasi tanpa menghilangkan informasi penting secara signifikan. Hasil keluaran dari lapisan ini disebut *pooled feature map*, yaitu *feature map* yang telah mengalami proses reduksi dimensi (Goodfellow et al., 2016).

Mekanisme *pooling* dilakukan dengan membagi *feature map* ke dalam beberapa area kecil yang disebut *pooling neighborhoods* atau jendela *pooling*. Terdapat dua metode yang umum digunakan untuk menentukan nilai representatif tersebut. Metode yang paling sering digunakan adalah *average pooling*, yaitu proses mengganti seluruh nilai dalam satu *neighborhood* dengan nilai rata-ratanya. Metode ini mempertahankan informasi umum dari area tersebut dan menghasilkan representasi yang lebih halus. Metode lain yang juga populer adalah *max-pooling*, yaitu memilih nilai terbesar dari seluruh elemen dalam satu *neighborhood* sebagai *output*. Pendekatan ini efektif dalam mempertahankan fitur dominan, seperti tepi atau pola penting pada citra, sehingga banyak digunakan dalam berbagai model CNN modern (Goodfellow et al., 2016).

Pada setiap *feature map* umumnya akan dihasilkan satu *pooled feature map* yang bersesuaian. Nilai-nilai hasil *pooling* ini kemudian diteruskan ke lapisan berikutnya sebagai representasi fitur yang lebih ringkas, dan pada tahap akhir digunakan sebagai masukan dalam proses klasifikasi (LeCun et al., 2015).




Gambar 2.2 *Pooling* (Sumber: Yani, 2019)

Proses klasifikasi pada algoritma CNN dilakukan pada lapisan *fully connected neural network* yang terletak pada bagian akhir arsitektur jaringan. Lapisan ini bertugas mengolah fitur-fitur yang telah diekstraksi oleh lapisan *convolution* dan *pooling* untuk menentukan kelas atau kategori dari data masukan (LeCun et al., 2015).

Output dari lapisan sebelumnya umumnya masih berbentuk *array* dua dimensi atau kumpulan *feature map*, sedangkan lapisan *fully connected* menerima input dalam bentuk vektor satu dimensi. Oleh karena itu, diperlukan tahap transformasi terlebih dahulu agar data dapat diproses pada lapisan klasifikasi.

Proses transformasi tersebut disebut *flattening* atau vektorisasi, yaitu mengubah matriks dua dimensi menjadi susunan data satu dimensi. Salah satu cara yang umum digunakan adalah *linear indexing*, yakni menyusun seluruh elemen *array* secara berurutan ke dalam sebuah vektor (Geron, 2022). Ilustrasi *flattening* dapat dilihat pada Gambar 2.3.



Gambar 2.3 Ilustrasi *Flattening* (Sumber: Pandey, 2024)

Selanjutnya, vektor tersebut diproses pada lapisan *fully connected* menggunakan operasi linear yang dapat dinyatakan sebagai berikut.

$$\mathbf{y} = W\mathbf{x} + \mathbf{b} \quad (2.5)$$

Pada persamaan tersebut, $\mathbf{x}$ menyatakan vektor input hasil proses *flatten*, W merupakan matriks bobot (*weight*), $\mathbf{b}$ merupakan bias, dan y merupakan *output* linear dari lapisan klasifikasi. Nilai *output* tersebut kemudian diproses menggunakan fungsi Softmax untuk menghasilkan probabilitas setiap kelas. Fungsi Softmax dapat dinyatakan sebagai berikut.

$$P(y_i) = \frac{e^{z_i}}{\sum_{j=1}^n e^{z_j}} \quad (2.6)$$

Pada persamaan tersebut, $P(y_i)$ menyatakan probabilitas data termasuk ke dalam kelas ke- i , z_i merupakan *output* linear pada kelas ke- i , dan n merupakan jumlah seluruh kelas. Fungsi Softmax menghasilkan nilai probabilitas dengan rentang 0 hingga 1, di mana jumlah seluruh probabilitas dari setiap kelas bernilai 1. Kelas prediksi akhir ditentukan berdasarkan nilai probabilitas terbesar yang dihasilkan oleh fungsi Softmax.


2.1.5 Fungsi Aktivasi

Fungsi aktivasi merupakan komponen penting dalam jaringan saraf tiruan, yang berperan sebagai transformasi matematis pada keluaran suatu neuron sebelum diteruskan ke lapisan berikutnya; memungkinkan jaringan mempelajari hubungan nonlinier pada data, sehingga model mampu menangani pola yang kompleks dan tidak dapat diselesaikan hanya dengan operasi linear (Goodfellow et al., 2016).

Salah satu fungsi aktivasi yang paling banyak digunakan adalah ReLU (*Rectified Linear Unit*). Fungsi ReLU didefinisikan seperti pada Persamaan 2.7.

$$f(x) = \max(0, x) \quad (2.7)$$


Pada Persamaan 2.7, variabel x menyatakan nilai *input* yang masuk ke neuron. Jika nilai *input* lebih kecil dari nol, maka *output* akan bernilai nol. Sebaliknya, jika nilai *input* bernilai positif, maka *output* akan sama dengan nilai *input* tersebut. Dengan mekanisme ini, ReLU hanya meneruskan sinyal positif dan menonaktifkan sinyal negatif (Nair & Hinton, 2010). Adapun bentuk grafik dari fungsi aktivasi ReLU dapat dilihat pada Gambar 2.4.



Gambar 2.4 Fungsi Aktivasi (Sumber: Ayush, 2022)

2.1.6 Residual Network (ResNet)


Residual Network (ResNet) merupakan salah satu arsitektur *deep CNN* yang dikembangkan untuk mengatasi masalah penurunan performa (*degradation problem*) pada jaringan yang sangat dalam. Pada arsitektur CNN konvensional, setiap lapisan mencoba secara langsung mempelajari fungsi pemetaan dari *input* x ke target y . Namun, He dkk. (2016) berargumen bahwa lebih mudah bagi jaringan untuk mempelajari fungsi residu, yaitu selisih antara *input* dan *output*.



Gambar 2.5 ResNet Block 1×1 Konvolusi (Sumber: d2l.ai)

2.1.7 Arsitektur ResNet-18

ResNet-18 adalah varian paling ringan dari ‘keluarga’ ResNet, terdiri atas 18 lapisan pembelajaran terlatih (*learnable layers*) yang disusun dari kombinasi konvolusi, Batch Normalization, ReLU, dan blok residual. Meskipun relatif dangkal dibandingkan varian lain, ResNet-18 memiliki keunggulan dalam efisiensi komputasi dan generalisasi, menjadikannya populer untuk klasifikasi citra skala menengah hingga kecil.



Gambar 2.6 Arsitektur ResNet-18 (Sumber: d2l.ai)

Arsitektur ResNet-18 sebagaimana ditunjukkan pada Gambar 2.6 terdiri atas serangkaian blok residual yang tersusun secara hierarkis dari lapisan konvolusi awal hingga lapisan *fully connected* pada bagian akhir. Setiap blok residual berfungsi mempertahankan informasi dari lapisan sebelumnya melalui mekanisme *skip connection*, yang memungkinkan gradien mengalir lebih stabil selama proses pelatihan jaringan. Dengan desain ini, ResNet-18 mampu mengatasi masalah *vanishing gradient* yang umum terjadi pada jaringan yang sangat dalam. Secara rinci, struktur tiap tahap dan konfigurasi lapisan pada ResNet-18 dijelaskan dalam Tabel 2.1 berikut.

Tabel 2.1 Arsitektur ResNet-18 (Sumber: He dkk., 2016)

Tahap	Jenis Lapisan	Dimensi Output	Jumlah Blok
Conv1	7×7 conv, 64 filter, stride 2 MaxPool 3×3, stride 2	112 × 112	1
Conv2_x	[3×3 conv, 64] × 2	56 × 56	2
Conv3_x	[3×3 conv, 128] × 2	28 × 28	2
Conv4_x	[3×3 conv, 256] × 2	14 × 14	2
Conv5_x	[3×3 conv, 512] × 2	7 × 7	2
Avg Pool + FC	1000-d fc → Softmax	1 × 1	1

Sehingga, ResNet-18 memiliki total 18 lapisan terlatih yang terdiri dari 1 lapisan konvolusi awal (Conv1), 16 lapisan dari 8 blok residual (masing-masing 2 konvolusi), dan 1 lapisan *fully connected* di akhir. Proses *forward pass* pada ResNet-18 dapat dirumuskan secara umum sebagai:

$$x_{l+1} = f(x_l) + x_l \quad (2.8)$$

di mana $f(x_l)$ adalah komposisi operasi konvolusi, Batch Normalization, dan aktivasi ReLU pada lapisan ke- l .

Kemudian, Proses propagasi pada ResNet mempertahankan prinsip *end-to-end training* seperti CNN biasa, tetapi *shortcut connection* membuat propagasi gradien lebih efisien. Jika fungsi *loss* dilambangkan dengan L , maka gradien terhadap *input* x_l dinyatakan sebagai:

$$\frac{\partial L}{\partial x_l} = \frac{\partial L}{\partial x_{l+1}} \left(\frac{\partial f(x_l)}{\partial x_l} + 1 \right) \quad (2.9)$$

Suku tambahan +1 berasal dari koneksi identitas x_l , yang menjaga agar gradien tetap mengalir meskipun kedalaman jaringan meningkat. Efeknya, ResNet-18 tetap mudah dioptimasi menggunakan algoritma seperti *Stochastic*

Gradient Descent (SGD) dan *Adam Optimizer*, tanpa mengalami *vanishing gradient* yang umum terjadi pada CNN klasik (He et al., 2016).

2.1.8 Modifikasi ResNet-18

Modifikasi ResNet-18 merupakan pengembangan dari arsitektur dasar ResNet-18 yang dimodifikasi untuk menyesuaikan kebutuhan dan karakteristik data pada suatu penelitian. Modifikasi arsitektur dilakukan dengan tujuan meningkatkan kemampuan model dalam mengekstraksi fitur, mengurangi kompleksitas parameter, meningkatkan stabilitas pelatihan, serta memperoleh performa klasifikasi yang lebih optimal dibandingkan arsitektur standar. Pada Modifikasi ResNet-18, perubahan arsitektur umumnya dilakukan pada beberapa bagian utama jaringan, seperti ukuran kernel konvolusi, jumlah *channel feature map*, penggunaan *pooling*, penambahan *attention mechanism*, maupun teknik regularisasi tambahan.

Salah satu mekanisme perhatian (*attention mechanism*) yang bisa digunakan untuk Modifikasi ResNet-18 adalah *Squeeze-and-Excitation Block* (SE Block). Menurut Hu dkk. (2018), SE Block merupakan modul yang dirancang untuk meningkatkan kualitas representasi fitur dengan memodelkan hubungan antar *channel* pada *feature map*. Mekanisme ini bekerja dengan memberikan bobot perhatian (*attention weight*) pada setiap channel sehingga jaringan dapat lebih fokus terhadap fitur-fitur penting dan mengurangi pengaruh fitur yang kurang relevan.

SE Block terdiri atas dua proses utama, yaitu *squeeze* dan *excitation*. Pada tahap *squeeze*, dilakukan proses *global average pooling* untuk merangkum

informasi spasial dari setiap channel menjadi representasi vektor. Proses tersebut dapat dinyatakan sebagai berikut.

$$z_c = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W x_c(i, j) \quad (2.10)$$

Pada persamaan tersebut, $x_c(i, j)$ menyatakan nilai *feature map* pada channel ke- c di posisi (i, j) , sedangkan H dan W menyatakan tinggi dan lebar *feature map*. Hasil proses *squeeze* berupa vektor z_c yang merepresentasikan informasi global dari setiap channel. Selanjutnya, pada tahap *excitation*, vektor hasil *squeeze* diproses menggunakan dua buah *fully connected layer* dan fungsi aktivasi sigmoid untuk menghasilkan bobot perhatian pada setiap channel. Proses tersebut dapat dinyatakan sebagai berikut.

$$s = \sigma(W_2 \delta(W_1 z)) \quad (2.11)$$

Pada persamaan tersebut, z merupakan hasil proses *squeeze*, W_1 dan W_2 merupakan parameter bobot pada *fully connected layer*, δ merupakan fungsi aktivasi ReLU, sedangkan σ merupakan fungsi aktivasi sigmoid. Hasil akhir berupa vektor s digunakan sebagai bobot perhatian (*attention weight*) pada setiap channel *feature map*. Bobot perhatian tersebut kemudian dikalikan kembali dengan *feature map* awal sehingga diperoleh *feature map* hasil kalibrasi channel, yang dinyatakan sebagai berikut.

$$\tilde{x}_c = s_c \cdot x_c \quad (2.12)$$

Pada persamaan tersebut, s_c merupakan bobot perhatian pada channel ke- c , sedangkan x_c merupakan *feature map* awal pada *channel* tersebut. Dengan proses ini, *channel* yang dianggap penting akan diperkuat, sedangkan *channel* yang kurang relevan akan ditekan.

2.1.9 Evaluasi Model

Evaluasi model merupakan tahap penting dalam proses pembelajaran mesin (*machine learning*) yang bertujuan untuk mengukur seberapa baik model mampu melakukan generalisasi terhadap data baru yang tidak pernah dilihat sebelumnya. Keberhasilan suatu model tidak hanya ditentukan oleh rendahnya nilai eror pada data pelatihan, tetapi juga oleh kemampuannya mempertahankan performa tinggi pada data uji (Goodfellow et al., 2016).

Secara umum, proses evaluasi dilakukan setelah model selesai dilatih menggunakan data latih (*training set*), kemudian diuji menggunakan data validasi (*validation set*) dan data uji (*testing set*). Proses ini membantu mendeteksi apakah model mengalami *overfitting* (terlalu menyesuaikan diri terhadap data latih) atau *underfitting* (tidak cukup belajar dari data).

Salah satu cara paling umum untuk menggambarkan hasil prediksi model klasifikasi adalah dengan menggunakan *confusion matrix*. Matriks ini membandingkan antara label aktual dengan hasil prediksi model dalam bentuk tabel dua dimensi. Untuk kasus klasifikasi biner, *confusion matrix* ditunjukkan sebagai berikut:

Tabel 2.2 *Confusion Matrix* (Sumber: Han dkk., 2011)

	Prediksi Positif	Prediksi Negatif
Aktual Positif	<i>True Positive (TP)</i>	<i>False Negative (FN)</i>
Aktual Negatif	<i>False Positive (FP)</i>	<i>True Negative (TN)</i>

Dari keempat komponen tersebut, berbagai metrik evaluasi dapat diturunkan untuk mengukur performa model secara kuantitatif (Han et al., 2012). Kemudian, akurasi (*accuracy*) mengukur proporsi prediksi yang benar terhadap keseluruhan

data uji. Akurasi merupakan metrik yang paling sederhana namun efektif untuk dataset yang seimbang. Rumus akurasi diberikan oleh:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.13)$$

Namun, pada dataset yang tidak seimbang (*imbalanced data*), akurasi dapat menyesatkan karena model mungkin hanya fokus pada kelas mayoritas. Oleh karena itu, metrik tambahan seperti presisi, *recall*, dan *F1-score* diperlukan. Presisi digunakan untuk mengukur sejauh mana prediksi positif dari model benar-benar positif. Nilai presisi yang tinggi menunjukkan bahwa model jarang membuat kesalahan dalam memprediksi kelas positif (Russell & Norvig, 2020). Rumus presisi adalah:

$$Precision = \frac{TP}{TP + FP} \quad (2.14)$$

Di sisi lain, *recall* atau *sensitivity/True Positive Rate* (TPR) menunjukkan sejauh mana model mampu mendeteksi seluruh data positif yang sebenarnya. Rumusnya adalah:

$$Recall = \frac{TP}{TP + FN} \quad (2.15)$$

Terakhir adalah *F1-Score*, yang merupakan ukuran harmonik antara presisi dan *recall* yang memberikan penilaian seimbang antara keduanya, terutama saat terdapat ketidakseimbangan jumlah data antar kelas (Sokolova & Lapalme, 2009). Rumusnya adalah:

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (2.16)$$

Nilai F1 berkisar antara 0 hingga 1, di mana nilai yang lebih tinggi menunjukkan keseimbangan optimal antara presisi dan *recall*.

2.2 Kajian Integrasi Topik dengan Al-Quran/Hadis

Integrasi ilmu dan wahyu dalam konteks penelitian ini bertolak dari pandangan (*paradigm*) bahwa seluruh aktivitas ilmiah pada hakikatnya merupakan bagian dari upaya manusia untuk membaca dan memahami tanda-tanda kebesaran Allah. Al-Qur'an, melalui berbagai ayatnya, mengarahkan manusia agar menggunakan potensi akal dan indra yang dianugerahkan untuk menelusuri keteraturan ciptaan-Nya (Zarkasyi, 2020).

Pertama, dalam Surat At-Tin ayat 4, Allah menegaskan bahwa manusia merupakan makhluk yang diberikan keistimewaan khusus dibandingkan makhluk lainnya, baik dari aspek struktur penciptaan maupun potensi intelektual yang dimilikinya. Tafsir Ringkas Kementerian Agama RI menjelaskan bahwa manusia diciptakan dalam bentuk fisik yang paling sempurna dibandingkan makhluk lainnya, serta dianugerahi akal dan sifat-sifat unggul yang menjadikannya layak mengemban amanah sebagai khalifah di bumi. Kesempurnaan ini tidak hanya dipahami secara fisik, tetapi juga mencakup kapasitas kognitif manusia dalam berpikir, belajar, dan mengembangkan ilmu pengetahuan (Kemenag, 2022). Dalam konteks perkembangan ilmu pengetahuan modern, kemampuan manusia dalam merancang sistem kecerdasan buatan seperti *Convolutional Neural Network* (CNN) dan teknologi *face recognition* dapat dipandang sebagai manifestasi dari potensi intelektual tersebut. Hal ini menunjukkan bahwa kemampuan teknologi yang dimiliki manusia merupakan bagian dari keistimewaan yang telah dianugerahkan dalam penciptaan.

Kedua, Surat Ar-Rūm ayat 22, menegaskan bahwa keberagaman karakteristik manusia merupakan bagian dari tanda kekuasaan Allah yang penuh hikmah. Dalam

Fathul Karim Mukhtashar Tafsir al-Qur'an al-'Azhim karya Hikmat bin Basyir bin Yasin dijelaskan bahwa seluruh manusia sejak Nabi Adam hingga akhir zaman memiliki struktur wajah yang sama secara umum, namun tidak ada satu individu pun yang benar-benar identik dengan individu lainnya. Setiap manusia memiliki ciri khas wajah yang berbeda, baik dalam bentuk, proporsi, maupun detail-detail halus yang dapat dibedakan melalui pengamatan (Hikmat bin Basyir bin Yasin, 2016). Keunikan tersebut menunjukkan bahwa meskipun manusia memiliki struktur biologis yang serupa, setiap individu tetap memiliki identitas visual yang khas dan tidak berulang. Dalam konteks teknologi modern, konsep ini menjadi dasar penting dalam pengembangan sistem biometrik, khususnya *face recognition*, yang bekerja dengan mengekstraksi dan membandingkan karakteristik unik pada wajah manusia untuk proses identifikasi.

Integrasi antara ayat-ayat Al-Qur'an dengan sains modern menghasilkan tiga implikasi epistemologis penting (Zarkasyi, 2020). Pertama, bahwa sumber ilmu pengetahuan dalam Islam bersifat teosentris, bahwa seluruh pengetahuan berakar dari kehendak dan keteraturan ciptaan Allah. Kedua, metode ilmiah adalah bentuk implementasi dari perintah Al-Qur'an untuk *nazar* (mengamati), *tafakkur* (merenung), dan *tadabbur* (memahami makna terdalam ciptaan). Ketiga, tujuan akhir ilmu bukan hanya penguasaan teknologi, melainkan *ta'abbudiyyah* atau ibadah dan pengakuan terhadap kebesaran Allah.

2.3 Kajian Topik dengan Teori Pendukung

Tujuan dari penelitian ini adalah mengembangkan model Modifikasi ResNet-18 untuk melakukan klasifikasi wajah menggunakan citra *grayscale* pada dataset

Extended Yale Face Database B guna meningkatkan kemampuan sistem dalam mengenali identitas wajah pada kondisi pencahayaan dan pose atau sudut pandang yang bervariasi.

Pada penelitian ini, proses klasifikasi dibagi ke dalam beberapa tahapan. Tahap pertama yang dilakukan adalah praproses citra untuk menyiapkan data sebelum masuk ke proses pelatihan model. Tahap praproses bertujuan meningkatkan kualitas data dan menyesuaikan format citra agar sesuai dengan arsitektur jaringan yang digunakan.

Setelah tahap praproses selesai dilakukan, tahap berikutnya adalah tahap pemodelan (*modeling*). Pada tahap ini dilakukan perancangan arsitektur CNN berbasis Modifikasi ResNet-18. Model tersebut menggunakan *residual block* untuk mempertahankan aliran informasi antar lapisan serta mengurangi permasalahan *vanishing gradient*. Selain itu, penelitian ini juga menguji berbagai skenario jumlah channel, kernel, *padding*, dan *stride*, penggunaan *max pooling* awal, penambahan Squeeze-and-Excitation Block (SE Block) sebagai *attention mechanism*, hingga penggunaan *dropout* sebelum *fully connected layer*.

Tahap berikutnya adalah proses pelatihan (*training*) model menggunakan data pelatihan yang telah dipersiapkan. Pada tahap ini, model mempelajari pola-pola wajah berdasarkan fitur yang diekstraksi dari citra *grayscale*. Selanjutnya dilakukan tahap pengujian (*testing*) untuk mengevaluasi performa model dalam melakukan klasifikasi identitas wajah. Evaluasi performa dilakukan menggunakan metrik akurasi serta *confusion matrix* untuk mengetahui kemampuan model dalam mengklasifikasikan setiap kelas wajah secara benar maupun kesalahan klasifikasi yang terjadi antar kelas.

BAB III

METODE PENELITIAN

3.1 Jenis Penelitian


Jenis penelitian yang diterapkan dalam studi ini adalah penelitian kuantitatif dengan pendekatan eksperimen. Penelitian ini bertujuan untuk menguji sejauh mana variabel yang dirancang mampu bekerja secara efektif sesuai dengan tujuan penelitian. Pengujian dilakukan dengan melihat tingkat akurasi model dalam mengenali wajah. Implementasi metode yang digunakan akan dievaluasi berdasarkan performanya dalam proses pengujian (*testing*), sehingga dapat diketahui tingkat keberhasilan model yang dikembangkan.

3.2 Data dan Sumber Data

Data yang digunakan dalam penelitian ini berupa citra wajah. Sumber data diambil dari salah satu dataset publik di Kaggle sejumlah 16.380 citra dengan 28 orang berbeda. Dataset tersebut bernama “Extended Yale B (Cropped, Full)”, berisi citra berukuran 192×168 piksel (*grayscale*) dengan variasi 9 pose dan 64 kondisi pencahayaan berbeda untuk tiap orangnya (Georghiades et al., 2001).

3.3 Tahapan Penelitian

Tahapan penelitian ditunjukkan melalui diagram alir pada Gambar 3.1. Tahapan tersebut dapat dibagi menjadi dua bagian utama, yaitu implementasi dan evaluasi. Tahapan implementasi mencakup seluruh proses mulai dari pengumpulan data hingga pelatihan model, sedangkan tahap evaluasi mencakup proses pengujian performa model serta analisis hasilnya.



Gambar 3.1 Alur Penelitian

Secara rinci, tahapan penelitian dapat diuraikan sebagai berikut.

1. Pengembangan Arsitektur ResNet-18

Pengembangan dilakukan dengan menguji beberapa skenario modifikasi arsitektur. Pengujian modifikasi arsitektur dilakukan secara bertahap (*sequential architecture development*). Pendekatan ini dipilih untuk mengurangi kompleksitas eksperimen dan kebutuhan komputasi akibat banyaknya kemungkinan kombinasi arsitektur yang dapat diuji. Setiap skenario dijalankan sebanyak lima kali pelatihan untuk mengurangi pengaruh *random initialization* terhadap hasil pengujian, dan skenario dengan rata-rata akurasi, F1-score dan *loss* terbaik dipilih untuk digunakan pada tahap pengembangan berikutnya.

a. Pengujian Modifikasi Konvolusi Awal

Tahap pertama pengembangan dilakukan dengan memodifikasi *convolution layer* awal pada ResNet-18. Modifikasi dilakukan dengan

pengujian beberapa kombinasi kernel, *stride*, dan *padding*. Selain itu, juga dilakukan skenario penyesuaian jumlah *output channel*.

b. Pengujian Penggunaan Max-Pooling Awal

Setelah diperoleh konfigurasi *convolution* awal terbaik, dilakukan pengujian penggunaan *max-pooling* awal, dengan skenario memakai *max-pooling* awal dan tanpa memakai *max-pooling* awal.

c. Pengujian Penambahan SE Block pada Residual Block

Setelah diperoleh konfigurasi terbaik, dilakukan pengujian penambahan *Squeeze-and-Excitation Block* (SE Block) pada *residual block*.

d. Pengujian Penggunaan Dropout

Tahap terakhir pengembangan arsitektur dilakukan dengan menguji penggunaan *dropout* sebelum *fully connected layer*. Penggunaan *dropout* dilakukan sebagai teknik regularisasi untuk mengurangi risiko *overfitting* selama proses pelatihan model. Sementara itu, pengujian tanpa *dropout* dilakukan untuk mengetahui apakah model masih mampu mempertahankan performa klasifikasi yang baik tanpa regularisasi tambahan.

Skenario arsitektur terbaik yang telah melewati seluruh tahap pengujian ditetapkan sebagai hasil akhir pengembangan ResNet-18 pada penelitian ini.

2. Implementasi Arsitektur Modifikasi

a. Pengumpulan Dataset

Pada tahap ini dilakukan pengumpulan dataset citra wajah yang digunakan dalam penelitian, yaitu Extended Yale Face Database B. Dataset tersebut terdiri atas citra wajah *grayscale* dengan variasi

pencahayaannya yang berbeda-beda pada setiap individu. Dataset digunakan sebagai data utama dalam proses pelatihan dan pengujian model klasifikasi wajah.

b. Praproses Data

Tahap praproses dilakukan untuk mempersiapkan data sebelum digunakan pada proses pelatihan model. Proses yang dilakukan meliputi *resizing* ukuran citra dan membagi dataset menjadi data *training*, *validation*, dan *testing*.

c. Pelatihan dan Evaluasi Model

Pada tahap ini dilakukan proses pelatihan model menggunakan data *training* menggunakan arsitektur terbaik hasil pengembangan ResNet-18 pada tahapan ke-1. Proses pelatihan dilakukan dengan menentukan *batch size*, *learning rate*, dan jumlah *epoch*. Setelah proses pelatihan selesai dilakukan, model dievaluasi menggunakan data *testing* dengan metrik *loss*, akurasi dan *F1-score*, serta dilakukan analisis melalui perbandingan dengan penelitian terdahulu pada dataset yang sama, mengevaluasi sejauh mana modifikasi arsitektur yang diusulkan mampu meningkatkan kemampuan klasifikasi pada dataset Extended Yale Face Database B.

BAB IV

HASIL DAN PEMBAHASAN

4.1 Pengembangan Arsitektur ResNet-18

Proses pengembangan arsitektur ResNet-18 dilakukan guna memperoleh konfigurasi yang paling sesuai dengan karakteristik dataset penelitian ini, yaitu dataset yang berisi citra wajah *grayscale* berjumlah 16.380 dengan 28 individu, 9 variasi pose, dan 64 kondisi pencahayaan. Pengembangan dilakukan dengan menguji beberapa skenario pada konfigurasi model. Setiap skenario dijalankan lima kali *running* dengan lima *seed* berbeda, yang dipilih mulai 40 hingga 44, untuk memastikan konsistensi dan mengurangi pengaruh variasi acak selama proses pelatihan.

1. Pengembangan *Convolution Layer* Awal

Pada arsitektur *default* ResNet-18 digunakan *convolution* awal dengan konfigurasi kernel 7×7 , *stride* = 2, *padding* = 3, dan *output channel* sebanyak 64 channel, sebab dirancang untuk dataset berskala besar seperti ImageNet yang memiliki variasi objek sangat tinggi dan kompleksitas fitur yang besar. Namun, karakteristik dataset penelitian ini terdiri atas citra wajah *grayscale* dengan ukuran yang relatif kecil dan objek yang lebih spesifik, yaitu wajah manusia. Oleh karena itu, dilakukan pengujian beberapa skenario konfigurasi *convolution layer* awal, mulai dari mereduksi kernel, *padding*, hingga jumlah *output channel*, sehingga mendapat 24 skenario pengujian, termasuk *default* ResNet-18. Nilai *loss*, rata-rata *accuracy*, dan rata-rata F1-score kemudian digunakan sebagai dasar dalam menentukan konfigurasi terbaik. Hasil pengujian skenario *convolution layer* awal ditunjukkan pada Tabel 4.1.

Tabel 4.1 Hasil Pengujian *Convolution Layer* Awal

Model	Kernel	Str	Pad	OC	Acc (%)	F1-Score (%)
Default	7×7	2	3	64	97,22%	97,23%
Mod1	7×7	1	3	64	94,64%	94,72%
Mod2	7×7	2	1	64	97,74%	97,74%
Mod3	7×7	1	1	64	95,38%	95,41%
Mod4	5×5	2	3	64	97,00%	97,00%
Mod5	5×5	1	3	64	98,11%	98,12%
Mod6	5×5	2	1	64	97,83%	97,83%
Mod7	5×5	1	1	64	97,38%	97,45%
Mod8	3×3	2	3	64	97,88%	97,89%
Mod9	3×3	1	3	64	92,78%	93,38%
Mod10	3×3	2	1	64	97,55%	97,56%
Mod11	3×3	1	1	64	91,90%	92,51%
Mod12	7×7	2	3	32	97,92%	97,92%
Mod13	7×7	1	3	32	97,52%	97,53%
Mod14	7×7	2	1	32	97,25%	97,25%
Mod15	7×7	1	1	32	97,50%	97,49%
Mod16	5×5	2	3	32	97,08%	97,09%
Mod17	5×5	1	3	32	95,79%	95,86%
Mod18	5×5	2	1	32	98,33%	98,34%
Mod19	5×5	1	1	32	98,26%	98,28%
Mod20	3×3	2	3	32	97,82%	97,82%
Mod21	3×3	1	3	32	94,59%	94,58%
Mod22	3×3	2	1	32	97,48%	97,49%
Mod23	3×3	1	1	32	97,93%	97,93%

Tabel 4.1 memperlihatkan bahwa arsitektur *default* ResNet-18 menghasilkan nilai *test loss* sebesar 0,11714, *accuracy* sebesar 97,22%, dan *F1-score* sebesar 97,23%, sementara performa terbaik diperoleh pada skenario Mod18, yaitu konfigurasi dengan kernel berukuran 5×5, *stride* 2, padding 1, dan jumlah *output channel* sebesar 32, yang menghasilkan nilai *test loss* sebesar 0,08454, *accuracy* sebesar 98,33%, dan *F1-score* sebesar 98,34%, yang artinya mengalami peningkatan akurasi sebesar 1,11% dan peningkatan *F1-score* sebesar 1,11%. Penggunaan kernel 7×7 pada model *default* dirancang untuk citra beresolusi besar seperti ImageNet. Pada citra *grayscale* berukuran

lebih kecil, seperti pada Extended Yale Face Database B, kernel yang lebih besar berpotensi menyebabkan hilangnya informasi detail lokal akibat proses agregasi fitur yang terlalu cepat. Sehingga, perubahan ukuran kernel dari 7×7 menjadi 5×5 pada Mod18 memberikan keseimbangan antara kemampuan menangkap pola spasial dan mempertahankan detail citra. Selain itu, perbandingan dengan Mod19 yang menggunakan kernel dan *padding* yang sama tetapi *stride* 1, di mana performanya sedikit lebih rendah (*accuracy* 98,26%) mengindikasikan bahwa proses *downsampling* pada tahap awal masih memberikan keuntungan dalam membangun representasi fitur yang lebih efisien. Selain ukuran kernel dan *stride*, jumlah *output channel* juga memberikan pengaruh besar terhadap performa model. Pada dua belas skenario konfigurasi dengan *output channel* 64, hanya enam konfigurasi yang menunjukkan peningkatan performa dari *default* ResNet-18, sementara skenario konfigurasi dengan *output channel* 32, sembilan di antaranya menghasilkan performa yang lebih unggul, dan akhirnya, mendapatkan konfigurasi paling unggul di antara skenario yang dijalankan. Di sisi lain, kombinasi parameter memiliki pengaruh yang lebih dominan dibandingkan perubahan satu parameter secara individual. Sebagai contoh, konfigurasi dengan kernel 3×3 tidak selalu menghasilkan performa terbaik. Mod23 yang menggunakan kernel 3×3 , *stride* 1, *padding* 1, dan 32 *output channel* hanya menghasilkan akurasi 97,93%, lebih rendah dibandingkan Mod18. Meskipun kernel yang lebih kecil mampu mempertahankan detail lokal, ukuran kernel yang terlalu kecil pada layer awal dapat membatasi kemampuan model dalam menangkap hubungan spasial yang lebih luas. Hal ini menunjukkan bahwa

terdapat titik optimal antara detail lokal dan cakupan fitur, yang pada penelitian ini dicapai oleh kernel 5×5 . Sebaliknya, beberapa konfigurasi justru mengalami penurunan performa secara signifikan, terutama konfigurasi dengan kombinasi kernel 3×3 dan *output channel* 64, seperti Mod9 dan Mod11 yang menghasilkan performa terendah dengan akurasi 92,78% dan 91,90%. Penurunan ini menunjukkan bahwa peningkatan jumlah filter yang besar dengan kernel kecil dapat menghasilkan banyak fitur redundan, sementara *receptive field* yang terbatas menyebabkan informasi global pada citra kurang optimal. Berdasarkan keseluruhan eksperimen, dapat disimpulkan bahwa konfigurasi *convolution layer* awal yang optimal untuk dataset penelitian ini bukanlah konfigurasi dengan jumlah parameter terbesar ataupun terkecil, melainkan konfigurasi yang mampu memberikan keseimbangan antara kapasitas representasi dan kompleksitas model. Mod18 dengan kernel 5×5 , *stride* 2, padding 1, dan 32 *output channel* dipilih sebagai konfigurasi terbaik karena menghasilkan nilai *accuracy* dan *F1-score* tertinggi.

2. Pengembangan Max-Pooling Awal

Pada arsitektur *default* ResNet-18, setelah *convolution layer* awal terdapat lapisan *max-pooling* berukuran kernel 3×3 dengan *stride* 2 yang berfungsi untuk mengurangi dimensi *feature map* pada tahap awal jaringan. Namun, dataset penelitian ini berisi citra wajah *grayscale* dengan ukuran 128×128 piksel yang mengandung detail-detail penting seperti kontur wajah, tekstur kulit, bentuk mata, hidung, dan variasi pencahayaan. Oleh karena itu, dilakukan pengujian untuk mengetahui apakah penggunaan *max-pooling*

awal masih diperlukan atau justru menyebabkan penurunan performa klasifikasi. Pengujian dilakukan menggunakan dua skenario, yaitu arsitektur yang menggunakan *max-pooling* awal (Mod18) dan arsitektur tanpa *max-pooling* awal (NoMP). Hasil pengujian kedua skenario ditunjukkan pada Tabel 4.2.

Tabel 4.2 Hasil Pengujian *Max-Pooling* Awal

Skenario	Loss	Accuracy	F1-Score
Mod18	0,08454	0,98332	0,98336
NoMP	0,12258	0,97856	0,97858

Berdasarkan hasil pengujian pada Tabel 4.2, skenario NoMP memperoleh *accuracy* sebesar 97,86% dan *F1-score* sebesar 97,86%, dengan penurunan akurasi sebesar 0,98% dan penurunan *F1-score* sebesar 0,98% dibandingkan dengan Mod18, sehingga menunjukkan bahwa penggunaan *max-pooling* awal masih memberikan manfaat dalam proses ekstraksi fitur wajah. Selain itu, NoMP justru menghasilkan nilai *loss* yang lebih tinggi di 0,12258 dengan peningkatan nilai *loss* sebesar 0,03804 dibandingkan Mod18. Sehingga, skenario Mod18 dipilih sebagai konfigurasi terbaik pada tahap ini.

3. Pengembangan Squeeze-and-Excitation Block (SE Block)

Pada penelitian ini, SE Block ditempatkan setelah *convolution layer* kedua dan Batch Normalization pada setiap *residual block* sebelum proses *residual addition* dilakukan, yang memungkinkan SE Block melakukan evaluasi terhadap *feature map* hasil ekstraksi fitur sebelum informasi digabungkan dengan *shortcut connection*. Pengujian dilakukan dengan membandingkan dua skenario, yaitu arsitektur terbaik hasil tahap sebelumnya tanpa SE Block (Mod18) dan dengan penambahan SE Block (Mod18+SE).

Tabel 4.3 Hasil Pengujian Penambahan SE Block

Skenario	Loss	Accuracy	F1-Score
Mod18	0,08454	0,98332	0,98336
Mod18+SE	0,10344	0,98188	0,9819

Berdasarkan Tabel 4.3, arsitektur dengan SE Block menghasilkan *test loss* sebesar 0,10344, *accuracy* sebesar 98,19%, dan *F1-score* sebesar 98,19%, yang artinya terjadi penurunan akurasi sebesar 0,14%, penurunan *F1-score* sebesar 0,14%, dan meningkatkan nilai *loss* dari 0,08454 menjadi 0,10344, dengan selisih sebesar 0,01890. Ini menunjukkan bahwa mekanisme *channel attention* belum memberikan peningkatan representasi fitur yang signifikan pada dataset yang digunakan, dan pada kasus ini, penambahan mekanisme tersebut justru menambah kompleksitas model sehingga proses optimasi menjadi kurang efisien. Oleh karena itu, konfigurasi Mod18 tanpa SE Block tetap dipilih sebagai arsitektur terbaik.

4. Pengembangan Dropout

Tahap terakhir dalam pengembangan arsitektur ResNet-18 adalah menguji penggunaan *dropout* sebelum *fully connected layer*, untuk mengurangi kemungkinan terjadinya *co-adaptation* antar neuron pada tahap pengambilan keputusan klasifikasi. Pengujian dilakukan dengan membandingkan arsitektur terbaik hasil tahap sebelumnya (Mod18) dengan arsitektur yang sama namun ditambahkan *dropout* sebelum *fully connected layer* (Mod18+Dropout). Hasil dapat dilihat pada Tabel 4.4.

Tabel 4.4 Hasil Pengujian Penggunaan Dropout

Skenario	Loss	Accuracy	F1-Score
Mod18	0,08454	0,98332	0,98336
Mod18+Dropout	0,08814	0,98364	0,98368

Berdasarkan Tabel 4.8, penambahan *dropout* berhasil meningkatkan performa model pada seluruh metrik evaluasi. Arsitektur Mod18+Dropout memperoleh *accuracy* sebesar 98,36% dan *F1-score* sebesar 98,37%, yang artinya terjadi peningkatan sebesar 0,03% dari model Mod18. Di sisi lain, nilai *loss* pada model dengan dropout mengalami peningkatan 0,00360 sehingga menjadi 0,08814. Namun, perubahan tersebut relatif kecil dan tidak diikuti oleh penurunan performa klasifikasi. Sebaliknya, model dengan *dropout* tetap mampu meningkatkan nilai *accuracy* dan *F1-score*. Hal ini menunjukkan bahwa *dropout* tidak secara langsung meningkatkan kemampuan model dalam meminimalkan nilai kesalahan prediksi pada data uji, tetapi membantu proses regularisasi sehingga model memiliki kemampuan generalisasi yang lebih baik.

Berdasarkan hasil pengujian tersebut, arsitektur Mod18+Dropout dipilih sebagai arsitektur akhir hasil pengembangan karena menghasilkan *accuracy* dan *F1-score* tertinggi dibandingkan seluruh konfigurasi yang telah diuji. Secara matematis, sebelum dilakukan penambahan *dropout*, proses transformasi fitur hingga tahap klasifikasi pada model dapat direpresentasikan sebagai:

$$X \rightarrow F(X; \theta) \rightarrow z \rightarrow \text{Softmax}(Wz + b)$$

Artinya, citra masukan X terlebih dahulu diproses oleh *feature extractor* ResNet melalui fungsi $F(X; \theta)$ yang melakukan transformasi bertahap melalui lapisan konvolusi dan *residual block* untuk menghasilkan representasi fitur akhir z . Selanjutnya, vektor fitur tersebut langsung diteruskan ke lapisan klasifikasi *fully connected* dengan transformasi linear $Wz + b$, kemudian dikonversi menjadi

probabilitas kelas menggunakan fungsi *softmax*. Sementara itu, setelah dilakukan penambahan *dropout*, aliran proses berubah menjadi:

$$X \rightarrow F(X; \theta) \rightarrow z \rightarrow (m \odot z) \rightarrow \text{Softmax}(W(m \odot z) + b)$$

Pada arsitektur yang telah dikembangkan, sebelum fitur masuk ke lapisan klasifikasi, representasi fitur z terlebih dahulu melewati mekanisme *dropout*. Proses ini memberikan *mask* acak m pada setiap neuron fitur sehingga sebagian fitur akan dinonaktifkan sementara selama proses pelatihan. Hasil transformasi tersebut menghasilkan representasi baru $m \odot z$ yang kemudian digunakan oleh lapisan *fully connected* untuk menghasilkan prediksi kelas.

4.2 Implementasi Arsitektur Modifikasi ResNet-18

1. Pengumpulan Data

Dataset yang digunakan berupa citra wajah yang diperoleh dari dataset publik yang tersedia pada *website* Kaggle. Dataset tersebut bernama Extended Yale B. Pada dataset tersebut, terdapat 16.380 citra wajah yang berasal dari 28 individu berbeda. Seluruh citra berada dalam format *grayscale*. Selain itu, dataset ini memiliki variasi kondisi pengambilan gambar yang cukup beragam, yaitu terdiri atas 9 variasi pose dan 64 kondisi pencahayaan yang berbeda untuk setiap individu. Adapun contoh sampel citra wajah dari dataset dapat dilihat pada Gambar 4.1.




Gambar 4.1 Sampel Citra 28 Individu

2. Praproses Citra

Tahap praproses data pada penelitian ini dilakukan dengan mengubah ukuran setiap citra wajah menjadi 128×128 piksel. Pemilihan ukuran piksel tersebut didasarkan pada pertimbangan antara kualitas informasi visual dan efisiensi komputasi, dan merupakan salah satu standar masukan yang umum digunakan pada arsitektur ResNet, sehingga tetap mampu mempertahankan fitur penting pada citra wajah, seperti kontur wajah, mata, hidung, dan mulut, tanpa menghasilkan beban komputasi yang terlalu besar selama proses pelatihan. Selain itu, dataset dibagi menjadi data *training*, *validation*, dan *testing* dengan rasio 70:10:20 dari total 16.380 data. Sehingga, diperoleh sebanyak 11.289 data *training*, 1.638 data *validation*, dan 3.276 data *testing*.

3. Pelatihan dan Evaluasi Model

Model dilatih menggunakan *learning rate* sebesar 0,001, *batch size* sebesar 32, dan jumlah *epoch* sebanyak 50. Hasil *training* dan *validation loss* ditunjukkan pada Gambar 4.2.



Gambar 4.2 *Training dan Validation Loss*

Berdasarkan Gambar 4.2, pada fase awal pelatihan terjadi penurunan nilai *loss* yang sangat signifikan. Nilai *training loss* turun secara drastis dari sekitar 1,21 pada *epoch* pertama menjadi di bawah 0,1 hanya dalam lima *epoch* awal. Setelah melewati fase awal pelatihan, kurva *training loss* terus mengalami penurunan secara bertahap hingga mencapai nilai yang sangat kecil mendekati nol pada *epoch-epoch* akhir, menunjukkan bahwa model semakin mampu menyesuaikan parameter internalnya untuk meminimalkan kesalahan prediksi pada data training. Di sisi lain, *validation loss* juga mengalami penurunan yang cukup tajam dari sekitar 0,45 menjadi mendekati 0,15 pada fase-fase awal. Hanya saja, ia menunjukkan pola yang relatif lebih fluktuatif dibandingkan *training loss*. Meskipun secara umum nilainya berada pada rentang yang stabil, terdapat beberapa kenaikan pada *epoch* tertentu, seperti sekitar *epoch* ke-12, *epoch* ke-15, serta beberapa fluktuasi kecil pada *epoch-epoch* selanjutnya. Meskipun terdapat jarak antara kurva *training loss* dan *validation loss*, gap tersebut masih berada dalam rentang yang relatif wajar dan tidak menunjukkan gejala *overfitting* yang ekstrem. Hal ini dapat dilihat dari *validation loss* yang tidak

mengalami peningkatan progresif secara terus-menerus pada *epoch* akhir, melainkan tetap berada pada kisaran stabil sekitar 0,09 hingga 0,13. Kondisi ini mengindikasikan bahwa model memiliki kemampuan generalisasi yang baik terhadap data yang tidak terlibat dalam proses pelatihan. Kemampuan generalisasi tersebut kemudian divalidasi lebih lanjut melalui pengujian menggunakan data *testing*, sebagaimana ditunjukkan pada Tabel 4.5.

Tabel 4.5 Hasil Evaluasi Model Terbaik

Arsitektur	Random Seed	Accuracy	Precision	Recall	F1-Score
Mod18 + Dropout	40	0,9768	0,9779	0,9768	0,977
	41	0,9866	0,9868	0,9866	0,9866
	42	0,9881	0,9883	0,9881	0,9881
	43	0,9847	0,9849	0,9847	0,9847
	44	0,982	0,9824	0,982	0,982

Untuk memberikan gambaran performa yang lebih representatif, dilakukan perhitungan rata-rata dan standar deviasi dari seluruh hasil pengujian sebagaimana disajikan pada Tabel 4.6.

Tabel 4.6 Rata-rata Model Terbaik

Metrik	Hasil
Accuracy	98,36% $\pm$ 0,45%
Precision	98,41% $\pm$ 0,41%
Recall	98,36% $\pm$ 0,45%
F1-Score	98,37% $\pm$ 0,44%

Berdasarkan hasil evaluasi, model Mod18 + Dropout memperoleh *accuracy* sebesar 98,36% dengan nilai *loss* sebesar 0,08814. Nilai *precision* sebesar 98,41%, *recall* sebesar 98,36%, dan F1-score sebesar 98,37% menunjukkan bahwa model memiliki performa yang sangat baik dalam melakukan klasifikasi wajah pada seluruh kelas yang terdapat dalam dataset Extended

Yale Face Database B. Tingginya nilai *precision* menunjukkan bahwa model mampu menghasilkan prediksi yang akurat dengan tingkat kesalahan klasifikasi yang rendah, sementara keseimbangan antara *recall* dan *F1-score* mengindikasikan bahwa performa model relatif konsisten pada seluruh kelas yang diuji. Untuk mengetahui posisi performa model yang dikembangkan terhadap penelitian lain, dilakukan perbandingan dengan beberapa penelitian terdahulu yang menggunakan dataset yang sama. Hasil perbandingan ditunjukkan pada Tabel 4.7.

Tabel 4.7 Perbandingan Akurasi dengan Penelitian Terdahulu

Paper	Method	Acc (%)
Bendjillali dkk. (2020)	ResNet50 + M-CLAHE	98.35
Bendjillali dkk. (2020)	VGG16	97.28
Raghavan & Ahmadi (2021)	SQI + CNN	99.8
Zangeneh dkk. (2020)	Deep CNN	97.2
Koley dkk. (2022)	FCLPPC	99.74
	Mod18 + Dropout (Proposed)	98.36

Berdasarkan Tabel 4.7, model yang dikembangkan pada penelitian ini berhasil mengungguli sebagian besar metode yang digunakan pada penelitian terdahulu, sebab menghasilkan performa yang lebih tinggi dibandingkan VGG16 (97,28%), Deep CNN (97,20%), dan ResNet50 + M-CLAHE (98,35%). Hasil tersebut menunjukkan bahwa modifikasi yang dilakukan pada arsitektur ResNet-18 mampu meningkatkan kemampuan klasifikasi tanpa memerlukan arsitektur yang jauh lebih kompleks. Meskipun demikian, masih terdapat beberapa penelitian yang memperoleh performa lebih tinggi, seperti SQI + CNN dengan *accuracy* sebesar 99,80% dan FCLPPC yang mencapai *accuracy* 99,74%. Perbedaan tersebut dapat

disebabkan oleh penggunaan teknik *preprocessing* dan *feature extraction* khusus yang secara spesifik dirancang untuk menangani variasi pencahayaan pada citra wajah.

4.3 Implementasi Modifikasi ResNet-18 dalam Pandangan Islam

Hasil penelitian menunjukkan bahwa arsitektur Modifikasi ResNet-18 memberikan performa klasifikasi yang lebih baik dibandingkan Default ResNet-18. Peningkatan performa tersebut diperoleh melalui beberapa modifikasi arsitektur, seperti penggunaan kernel konvolusi yang lebih kecil dan penambahan teknik regularisasi, sehingga proses klasifikasi menjadi lebih optimal. Dalam perspektif Islam, proses modifikasi dan penyempurnaan arsitektur jaringan menunjukkan bahwa ilmu pengetahuan berkembang melalui proses pengamatan, evaluasi, dan perbaikan secara terus-menerus. Hal tersebut sejalan dengan hadis Rasulullah saw melalui riwayat Al-Baihaqi.

“Sesungguhnya Allah mencintai apabila salah seorang di antara kalian melakukan suatu pekerjaan, maka ia menyempurnakannya.”

Dalam konteks penelitian ini, modifikasi arsitektur ResNet-18 merupakan bentuk ikhtiar ilmiah untuk menyempurnakan model klasifikasi wajah agar memperoleh performa yang lebih baik. Dengan demikian, pengembangan Modifikasi ResNet-18 pada penelitian ini selain menunjukkan kemajuan teknis dalam bidang *computer vision* dan kecerdasan buatan, juga mencerminkan nilai keilmuan dalam Islam yang mendorong manusia untuk terus belajar, berpikir, dan melakukan perbaikan terhadap suatu sistem demi menghasilkan kemanfaatan yang lebih baik.

BAB V

PENUTUP

5.1 Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, pengembangan ResNet-18 untuk klasifikasi wajah pada dataset dengan variasi pose dan kondisi pencahayaan diperoleh melalui pengembangan arsitektur secara bertahap (*sequential architecture development*). Hasil pengujian menunjukkan bahwa konfigurasi terbaik diperoleh pada arsitektur yang menggunakan *convolution layer* awal hasil Mod18 dengan kernel 5x5, stride 2 dan padding 1, mempertahankan *max-pooling* awal, serta menerapkan *dropout* sebelum *fully connected layer*.

Berdasarkan hasil evaluasi, model Modifikasi ResNet-18 yang diusulkan mampu melakukan klasifikasi wajah pada dataset Extended Yale Face Database B dengan *accuracy* sebesar 98,36%, *F1-score* sebesar 98,37%, dan *loss* sebesar 0,08814 yang menunjukkan bahwa model mampu mengenali identitas wajah secara cukup akurat meskipun terdapat variasi pose dan kondisi pencahayaan pada dataset.

5.2 Saran

Berdasarkan hasil penelitian yang telah dilakukan, terdapat beberapa saran untuk pengembangan penelitian selanjutnya. Penelitian berikutnya dapat menggunakan dataset wajah dengan jumlah data yang lebih besar dan variasi kondisi yang lebih kompleks, ekspresi maupun *occlusion* agar model memiliki kemampuan generalisasi yang lebih baik. Selain itu, penelitian selanjutnya juga dapat mengembangkan arsitektur lain yang lebih modern maupun kombinasi CNN dengan metode *attention* lainnya untuk membandingkan performa klasifikasi wajah.

DAFTAR PUSTAKA

- Alpaydın, E. (2010). *Introduction to Machine Learning*. The MIT Press.
- Basyir bin Yasin, Hikmat. (2016). *Fathul Karim Mukhtashar Tafsir al-Qur'an al-Azhim*. Madinah: Dar Ibn al-Jauzi.
- Bendjillali, R. I., Beladgham, M., Merit, K., & Taleb-Ahmed, A. (2020). Illumination-robust face recognition based on deep convolutional neural networks architectures. *Indonesian Journal of Electrical Engineering and Computer Science*, 18(2), 1015–1027.
- Bishop, C. M. (2006). Pattern Recognition and Machine Learning. In *Journal of Machine and Computing* (Vol. 4, Issue 1).
- Chapelle, O., Scholkopf, B., & Zien, A. (2006). Semi-Supervised Learning. In *Machine Learning and Big Data: Concepts, Algorithms, Tools and Applications*. The MIT Press. <https://doi.org/10.1002/9781119654834.ch10>
- Georghiades, A. S., Belhumeur, P. N., & Kriegman, D. J. (2001). From few to many: Illumination cone models for face recognition under variable lighting and pose. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 23(6), 643–660.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep Learning. In *Prmu*.
- Han, J., Kamber, M., & Pei, J. (2012). Data Mining: Concepts and Techniques. In *Data Mining: Concepts and Techniques* (Third Edit). Morgan Kaufmann Publishers. <https://doi.org/10.1016/C2009-0-61819-5>
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2016-Decem*, 770–778.
- Heaton, J. (2013). *Artificial Intelligence for Humans, Volume 1: Fundamental Algorithms* (Vol. 1).
- Kementerian Agama Republik Indonesia. (2022). *Tafsir Ringkas Al-Qur'an Kementerian Agama RI*. Jakarta: Kementerian Agama RI.
- Koley, S., Roy, H., Dhar, S., & Bhattacharjee, D. (2022). Illumination invariant face recognition using Fused Cross Lattice Pattern of Phase Congruency (FCLPPC). *Information Sciences*, 584, 633–648.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). *ImageNet Classification with Deep Convolutional Neural Networks*. 60-1-60–15.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>

- Mitchell, T. M. (1997). Machine learning. In *Machine Learning* (Vol. 45, Issue 13). McGraw-Hill.
- Poole, D. L., & Mackworth, A. K. (2010). *Artificial Intelligence: Foundations of Computational Agents*. United States of America by Cambridge University Press.
- Raghavan, J., & Ahmadi, M. (2021). A Modified CNN-Based Face Recognition System. *International Journal of Artificial Intelligence & Applications*, 12(2), 1–20. <https://doi.org/10.5121/ijaia.2021.12201>
- Russell, S. J., & Norvig, P. (2010). *Artificial Intelligence: A Modern Approach* (3rd ed.). Pearson Education, Inc.
- Sutton, R. S., & Barto, A. G. (2015). An introduction to reinforcement learning. In *Decision Theory Models for Applications in Artificial Intelligence: Concepts and Solutions* (Second). The MIT Press. <https://doi.org/10.4018/978-1-60960-165-2.ch004>
- Tan, M., & Le, Q. V. (2019). EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. *36th International Conference on Machine Learning, ICML 2019, 2019-June*, 10691–10700.
- Zangeneh, E., Rahmati, M., & Mohsenzadeh, Y. (2020). Low resolution face recognition using a two-branch deep convolutional neural network architecture. *Expert Systems with Applications*, 139, 1–11.
- Zhao, W., Chellappa, R., & Phillips, P. J. (2003). Face Recognition: A Literature Survey. *ACM Computing Surveys*, 35(4), 339–458.

RIWAYAT HIDUP



Rojauna Zalfatthoriq, akrab disapa Thoriq, lahir di Tulungagung pada tanggal 30 Mei 2003. Penulis tumbuh di Kelurahan Kedungsoko, Kecamatan Tulungagung, Kabupaten Tulungagung, dan merupakan anak kedua dari tiga bersaudara. Perjalanan pendidikan formal penulis bermula di SDN 1 Kedungsoko dan lulus pada tahun 2016. Kemudian, penulis melangkah naik pada tingkat menengah pertama di MTsN 1 Tulungagung hingga lulus pada tahun 2019. Selanjutnya, penulis menempuh pendidikan formal tingkat menengah atas di MAN 2 Tulungagung pada jurusan MIPA. Pada tahun 2022, penulis melanjutkan pendidikan Strata 1 pada Program Studi Matematika di UIN Maulana Malik Ibrahim Malang.



**KEMENTERIAN AGAMA RI
UNIVERSITAS ISLAM NEGERI
MAULANA MALIK IBRAHIM MALANG
FAKULTAS SAINS DAN TEKNOLOGI**

Jl. Gajayana No.50 Dinoyo Malang Telp. / Fax. (0341)558933

BUKTI KONSULTASI SKRIPSI

Nama : ROJAUNA ZALFATTHORIQ
NIM : 220601110077
Fakultas / Jurusan : Sains dan Teknologi / Matematika
Judul Skripsi : Pengembangan Arsitektur ResNet-18 untuk Klasifikasi Wajah
Pembimbing I : Hisyam Fahmi, M.Kom.
Pembimbing II : Abdul Aziz, M.Si.

No	Tanggal	Hal	Tanda Tangan
1.	30 September 2025	Konsultasi Bab I, II, dan III	1.
2.	25 Oktober 2025	Konsultasi Bab I, II, dan III	2.
3.	26 Oktober 2025	ACC Bab I, II, dan III	3.
4.	28 Oktober 2025	ACC Kajian Agama Bab I dan II	4.
5.	15 November 2025	ACC Seminar Proposal	5.
6.	16 Mei 2026	Konsultasi Bab IV dan V	6.
7.	18 Mei 2026	ACC Bab IV dan V	7.
8.	18 Mei 2026	ACC Kajian Agama Bab IV	8.
9.	18 Mei 2026	ACC Seminar Hasil	9.
10.	9 Juni 2026	Konsultasi Revisi Seminar Hasil	10.
11.	9 Juni 2026	ACC Sidang Skripsi	11.
12.	15 Juni 2026	ACC Keseluruhan	12.

Malang, 15 Juni 2026

Mengetahui,

Ketua Program Studi Matematika



Dr. Fachrur Rozi, M.Si.

NIP. 19800527 200801 1 012