DETEKSI ANEMIA DARI CITRA PALPEBRAL KONJUNGTIVA MATA MENGGUNAKAN PEDEKATAN DEEP LEARNING DENGAN SISTEM DIGITAL

SKRIPSI

DISUSUN OLEH

ZAHIRA INAYAH PATUAN HARAHAP

2209020241



PROGRAM STUDI TEKNOLOGI INFORMASI

FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI

UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA

MEDAN

2026

DETEKSI ANEMIA DARI CITRA PALPEBRAL KONJUNGTIVA MATA MENGGUNAKAN PEDEKATAN DEEP LEARNING DENGAN SISTEM DIGITAL

SKRIPSI

Diajukan sebagai salah satu syarat untuk memperoleh gelar Sarjana Komputer (S.Kom) dalam Program Studi Tenologi Infromasi. pada Fakultas Ilmu Komputer dan Teknologi Informasi, Universitas Muhammadiyah Sumatera Utara

ZAHIRA INAYAH PATUAN HARAHAP

NPM. 2209020241

PROGRAM STUDI TEKNOLOGI INFROMASI

FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI

UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA

MEDAN

2026

LEMBAR PENGESAHAN

Judul Skripsi	:	DETEKSI ANEMIA DARI CITRA PALPEBRAL KONJUNGTIVA MATA MENGGUNAKAN PENDEKATAN DEEP LEARNING DENGAN SISTEM DIGITAL
Nama Mahasiswa	:	Zahira Inayah Patuan Harahap
NPM	:	2209020241
Program Studi	:	Teknologi Informasi

Menyetujui

Komisi Pembimbing

(Farid Akbar Siregar, S.Kom., M.Kom.)

NIDN. 0104049401

Ketua Program Studi	Dekan
(Fatma Sari Hutagalung, S.Kom, M.Kom)	**(Dr. Al-Khowarizmi, S.Kom., M.Kom.)**
NIDN. 0117019301	**NIDN. 0127099201**

PERNYATAAN ORISINALITAS

DETEKSI ANEMIA DARI CITRA PALPEBRAL KONJUNGTIVA MATA MENGGUNAKAN PEDEKATAN DEEP LEARNING DENGAN SISTEM DIGITAL

SKRIPSI

Saya menyatakan bahwa karya tulis ini adalah hasil karya sendiri, kecuali beberapa kutipan dan ringkasan yang masing-masing disebutkan sumbernya.

Medan, 20 April 2026

Yang membuat pernyataan



Zahira Inayah Patuan Hrp

NPM. 2209020241

PERNYATAAN PERSETUJUAN PUBLIKASI KARYA ILMIAH UNTUK KEPENTINGAN AKADEMIS

Sebagai sivitas akademika Universitas Muhammadiyah Sumatera Utara, saya bertanda tangan dibawah ini:

Nama	: Zahira Inayah Patuan Harahap
NPM	: 2209020241
Program Studi	: Teknologi Informasi
Karya Ilmiah	: Skripsi

Demi pengembangan ilmu pengetahuan, menyetujui untuk memberikan kepada Universitas Muhammadiyah Sumatera Utara Hak Bedas Royalti Non-Eksekutif *(Non-Exclusive Royalty free Right)* atas penelitian skripsi saya yang berjudul:

Deteksi Anemia Dari Citra Palpebral Konjungtiva Mata Menggunakan Pedekatan Deep Learning Dengan Sistem Digital

Beserta perangkat yang ada (jika diperlukan). Dengan Hak Bebas Royalti Non-Eksekutif ini, Universitas Muhammadiyah Sumatera Utara berhak menyimpan, mengalih media, memformat, mengelola dalam bentuk database, merawat dan mempublikasikan Skripsi saya ini tanpa meminta izin dari saya selama tetap mencantumkan nama saya sebagai penulis dan sebagai pemegang dan atau sebagai pemilik hak cipta.

Demikian pernyataan ini dibuat dengan sebenarnya.

Medan, 20 April 2026

Yang membuat pernyataan



Zahira Inayah Patuan Hrp

NPM. 2209020241

RIWAYAT HIDUP

DATA PRIBADI

Nama Lengkap	: Zahira Inayah Patuan Harahap
Tempat dan Tanggal Lahir	: Medan, 21 Desember 2004
Alamat Rumah	: Jln. Menteng Indah Blok D
Telepon/Faks/HP	: 0812635400328
E-mail	: zahirainayah1@gmail.com
Instansi Tempat Kerja	: -
Alamat Kantor	: -

DATA PENDIDIKAN

SD	: SD Muhammadiyah 36 Medan	TAMAT: 2016
SMP	: SMP Muhammadiyah 01 Medan	TAMAT: 2019
SMA	: SMA Negeri 5 Medan	TAMAT: 2022

KATA PENGANTAR



Alhamdulillahi rabbil ‘aalamiin Puji dan syukur penulis ucapkan kepada Allah SWT atas rahmat dan izin-Nya sehingga skripsi ini dapat diselesaikan dengan baik. Skripsi ini disusun sebagai salah satu syarat untuk menyelesaikan pendidikan pada Program Studi Teknologi Informasi, Fakultas Ilmu Komputer dan Teknologi Informasi, Universitas Muhammadiyah Sumatera Utara.

Penulis menyadari bahwa perjalanan penyelesaian skripsi ini tidak terlepas dari dukungan, doa, arahan kedua orang tua, serta motivasi dari berbagai pihak yang senantiasa memberikan semangat selama proses berlangsung. Oleh karena itu, penulis menyampaikan terima kasih seluruh pihak yang telah memberikan perhatian dan dukungan hingga skripsi ini dapat diselesaikan dengan baik. Dengan penuh rasa syukur dan hormat, Penulis juga mengucapkan terima kasih kepada:

1. Bapak Prof. Dr. Agussani, M.AP., Rektor Universitas Muhammadiyah Sumatera Utara (UMSU)
2. Bapak Dr. Al-Khowarizmi, S.Kom., M.Kom. Dekan Fakultas Ilmu Komputer dan Teknologi Informasi (FIKTI) UMSU.
3. Ibu DR. firahmi Rizky, S.Kom., M.Kom., selaku Wakil Dekan I Fakultas Ilmu Komputer dan Teknologi Informasi.
4. Bapak Mhd.Basri, S.Si., M.I.Kom., selaku Wakil Dekan III Fakultas Ilmu Komputer dan Teknologi Informasi.
5. Ibu Fatma Sari Hutagalung, S.Kom., M.Kom., selaku Ketua Program Studi Teknologi Informasi.
6. Bapak Okvi Nugroho, S.Kom., M.Kom., selaku Sekretaris Program Studi Teknologi Informasi.
7. Bapak Farid Akbar Siregar, S.Kom., M.Kom., selaku dosen pembimbing yang telah mempermudah proses bimbingan serta memberikan arahan dan masukan yang konstruktif selama penyusunan skripsi ini.
8. kedua orang tua tercinta Ayak dan Ibu, yang menjadi alasan terbesar penulis mampu berada di titik ini, membuat penulis tumbuh dengan rasa

cukup, aman, dan percaya diri dalam menjalani setiap proses kehidupan. Kepada Ibu, sosok pertama yang penulis jadikan panutan dan kebanggaan sepanjang hidup. Setiap langkah penulis hari ini adalah hasil dari kasih sayang yang tidak pernah terukur nilainya, doa yang tidak pernah putus. Segala pengorbanan waktu, tenaga, pikiran, bahkan kesehatan yang ibu berikan demi anak-anaknya menjadi pelajaran hidup yang tidak akan pernah penulis lupakan. Kepada Ayak, terima kasih atas kasih sayang dan dukungan yang selalu diwujudkan melalui perhatian dan tindakan nyata. Kehadiran ayak yang selalu menjaga, membantu, serta memastikan penulis berada dalam keadaan baik menjadi kekuatan besar selama ini.

9. Kepada 5 saudara kesayangan penulis serta keluarga, yang selalu menghadirkan suasana hangat di rumah, menjadi tempat pulang terbaik bagi penulis. Kehadiran keluarga yang penuh canda dan kebersamaan menjadi penyemangat tersendiri di tengah proses yang tidak selalu mudah. kepada Bule Ana, Kak Nashuha dan Kak Hanny atas doa, dukungan, serta nasihat, memberikan arahan, saran, serta dorongan untuk terus belajar menjadi motivasi bagi penulis dalam menyelesaikan skripsi ini dengan baik.
10. Kepada sahabat dan teman-teman terdekat penulis yang senantiasa hadir dalam perjalanan hidup memberikan dukungan dan perhatian yang tulus pada penulis hingga sampai pada tahap ini. Terima kasih kepada Nazwa Shahira, yang selalu menjadi tempat berbagi cerita dalam berbagai keadaan. Kepedulian, serta kesediaannya untuk mendengarkan tanpa menghakimi dan dan selalu memberi ruang bagi penulis untuk bertumbuh menjadikan kehadirannya sangat berarti bagi penulis layaknya seorang saudara. Kehadirannya yang konsisten serta sikapnya yang hangat menjadi salah satu penyemangat bagi penulis dalam menjalani proses selama ini. kepada Aisyah Putri Syahrani, Cherisa Adelia Putri, , Shahila gusri, Karin Aqilah, Najawa Shafita, Roydatull, Afji Lianur, Raudhatun Nisa, Nayna Rasyid, Jasmine Aqilah, Aisyah Aprilia, Atira Nazmi, Dinda Fajrina yang telah menemani kehidupan penulis dengan penuh kebersamaan, canda, keceriaan, humor yang selalu mampu menghibur serta menjadi pelepas

lelah di tengah proses dan pengalaman yang tidak terlupakan. Waktu yang diberikan menjadi bagian dari perjalanan berharga yang membantu penulis tetap bertahan dalam proses panjang ini. Kepada Putri Amira Basri, teman seperjuangan selama masa perkuliahan yang banyak berbagi proses akademik bersama penulis. Diskusi, kerja sama, serta kejujuran dalam memberikan pandangan dan saran membuat penulis belajar melihat berbagai hal secara lebih realistis dan dewasa. Kehadirannya sebagai rekan bertukar pikiran membantu penulis berkembang, tidak hanya secara akademik tetapi juga secara pribadi. Serta kepada Putri Aprilia, yang turut menjadi teman seperjuangan selama masa perkuliahan dan menghadirkan suasana kebersamaan yang penuh energi dan cerita. Kehadiran teman-teman tersebut memberikan warna tersendiri dalam perjalanan penulis, sehingga proses penyelesaian skripsi ini terasa lebih ringan untuk dijalani.

11. Kepada seluruh teman seperjuangan selama masa perkuliahan dan semua pihak yang terlibat langsung ataupun tidak langsung yang tidak dapat disebutkan satu per satu, terima kasih atas pengalaman, pembelajaran, serta kenangan yang telah dilalui bersama.

Medan, 26 Januari 2026

Penulis



Zahira Inayah P.Hrp

DETEKSI ANEMIA DARI CITRA PALPEBRAL KONJUNGTIVA MATA MENGGUNAKAN PEDEKATAN DEEP LEARNING DENGAN SISTEM DIGITAL

ABSTRAK

Anemia merupakan salah satu masalah kesehatan yang masih banyak ditemukan dan umumnya didiagnosis melalui pemeriksaan laboratorium yang bersifat invasif. Perkembangan teknologi kecerdasan buatan memungkinkan deteksi awal anemia dilakukan melalui pendekatan berbasis citra medis secara non-invasif. Penelitian ini bertujuan merancang dan mengimplementasikan sistem deteksi anemia menggunakan metode deep learning berbasis transfer learning dengan memanfaatkan citra konjungtiva palpebral sebagai sumber informasi visual. Model klasifikasi dibangun menggunakan arsitektur MobileNetV2 dengan bobot pretrained ImageNet yang berperan sebagai feature extractor. Tahapan penelitian meliputi preprocessing citra berupa resizing, normalisasi nilai piksel, serta augmentasi data untuk meningkatkan variasi dataset. Strategi pelatihan dilakukan secara bertahap melalui proses feature extraction dan fine-tuning guna memperoleh performa model yang stabil dan memiliki kemampuan generalisasi yang baik terhadap data baru. Model dilatih menggunakan optimizer Adam dan fungsi loss *binary crossentropy* dengan metrik evaluasi accuracy dan *Area Under Curve* (AUC). Hasil pelatihan menunjukkan model mampu mempelajari pola citra dengan baik dengan akurasi pelatihan mencapai sekitar 82%, akurasi validasi sebesar 79,82%, serta nilai AUC 0,9003 pada epoch terbaik. Evaluasi menggunakan data uji menghasilkan akurasi sebesar 90,71%, yang menunjukkan kemampuan klasifikasi yang stabil dan memiliki generalisasi yang baik terhadap citra baru. Model yang telah dilatih kemudian diintegrasikan ke dalam aplikasi mobile berbasis React Native dengan dukungan backend Flask sehingga proses deteksi dapat dilakukan secara *real-time* melalui perangkat Android. Hasil pengujian implementasi menunjukkan aplikasi mampu melakukan klasifikasi citra baru secara konsisten dengan hasil yang sesuai terhadap kondisi sebenarnya. Dengan demikian, sistem yang dikembangkan berpotensi menjadi alat bantu skrining awal anemia yang praktis, cepat, dan non-invasif berbasis perangkat mobile.

Kata Kunci: Anemia, Deep Learning, Transfer Learning, MobileNetV2, Citra Konjungtiva Palpebral, Deteksi Non-Invasif.

ANEMIA DETECTION BASED ON PALPEBRAL CONJUNCTIVA EYE IMAGES USING A DEEP LEARNING APPROACH WITH A DIGITAL SYSTEM

ABSTRACT

Anemia remains one of the most common health problems and is generally diagnosed through invasive laboratory examinations. Advances in artificial intelligence technology have enabled early anemia detection using non-invasive medical image–based approaches. This study aims to design and implement an anemia detection system using a deep learning method based on transfer learning by utilizing palpebral conjunctiva images as the primary visual information source. The classification model was developed using the MobileNetV2 architecture with ImageNet pretrained weights serving as a feature extractor. The research stages included image preprocessing consisting of resizing, pixel value normalization, and data augmentation to increase dataset variability. The training strategy was conducted in stages through feature extraction followed by fine-tuning to obtain stable model performance and strong generalization capability on unseen data. The model was trained using the Adam optimizer with binary crossentropy loss and evaluated using accuracy and Area Under the Curve (AUC) metrics. Training results indicate that the model successfully learned visual patterns, achieving approximately 82% training accuracy, 79.82% validation accuracy, and an AUC score of 0.9003 at the best epoch. Evaluation on the test dataset produced an accuracy of 90.71%, demonstrating stable classification performance and good generalization capability toward new images. The trained model was subsequently integrated into a React Native–based mobile application supported by a Flask backend, enabling real-time detection through Android devices. Implementation testing results show that the application consistently classified new images with predictions aligned with actual conditions. Therefore, the developed system has the potential to serve as a practical, fast, and non-invasive early anemia screening tool implemented on mobile devices.

Keywords: Anemia, Deep Learning, Transfer Learning, MobileNetV2, Palpebral Conjunctiva Image, Non-invasive Detection.

DAFTAR ISI

.....iv
KATA PENGANTAR.....vii
ABSTRAK x
ABSTRACT.....xi
DAFTAR ISI.....xii
DAFTAR TABEL xiv
DAFTAR GAMBAR.....xv
BAB I PENDAHULUAN.....1
1.1. Latar Belakang Masalah 1
1.2. Rumusan masalah 4
1.3.Batasan Masalah 4
1.4.Tujuan Penelitian 5
BAB II LANDASAN TEORI 6
2.1. Anemia 6
2.2. Konjungtiva Palpebral 7
2.3. Pengolahan Citra Digital 7
2.4. Deep Learning 8
2.4. Transfer Learning 9
2.5. MobileNetV2 10
2.6. Confusion Matrix.....11
2.7. Implementasi Sistem Berbasis Digital.....13
2.8. Ringkasan Peneliti Terdahulu 14
2.9. Analisis Gap 18
BAB III METODOLOGI PENELITIAN 20
3.1. Pendekatan Penelitian 20
3.2. Teknik Pengumpulan Data 21
3.3 Tahapan Penelitian.....22
3.4 Uml Sistem Deteksi Anemia 27
3.5 Rancangan Interface 31
BAB IV PEMBAHASAN DAN HASIL 33
4.1 Akuisisi dan Analisis Dataset 33
4.2 Preprocessing Data 35

4.3 Pembangunan dan Pelatihan Model Transfer Learning Menggunakan MobileNetV2 38
4.3.1 Arsitektur Model dan Strategi Regularisasi.....39
4.4 Validasi Model dan Pengecekan Overfitting.....45
4.4.1 Interpretasi terhadap Penelitian 48
4.5 Evaluasi Model 49
4.6 Integrasi Model atau Deploy 52
4.7 Prediksi Anemia dari Hasil Model Citra Konjungtiva Palpebral Menggunakan Expo 56
BAB V KESIMPULAN DAN SARAN 63
5.1 Kesimpulan.....63
5.2 Saran 64
DAFTAR PUSTAKA.....66
2. Formulir Perbaikan Ujian Skripsi 71
3. Hasil Turnitin Skripsi.....72
LAMPIRAN.....70

DAFTAR TABEL

Tabel 2.1 Penelitian Terdahulu 15
Tabel 4.1 Tabel Arsitektur Model 40
Tabel 4.2 Validasi Implementasi Model Pada Citra Sebenarnya 59

DAFTAR GAMBAR

Gambar 2.1 Bagian Palpebral Conjunctiva 7
Gambar 2.2 Skema Confusion Matrix 11
Gambar 3.1 contoh non-anemic & anemic 22
Gambar 3.2 Tahapan Penelitian 23
Gambar 3.3 Use Case Diagram 28
Gambar 3.4 Activity Diagram 29
Gambar 3.5 Sequence Diagram 30
Gambar 3.6 Rancangan Interface 31
Gambar 4.1 Citra sebelum di Processing 34
Gambar 4.2 Tahap Preprocessing Data 36
Gambar 4.3 Tahap Class Weight 37
Gambar 4.4 Tahap Pembangunan Model 38
Gambar 4.5 Arsitektur Model 39
Gambar 4.6 Set Regulasi 41
Gambar 4.7 Set Checkpoint 41
Gambar 4.8 Set EarlyStopping 42
Gambar 4.9 Set ReduceLR 42
Gambar 4.10 Hasil Pelatihan Model Phase 1 42
Gambar 4.11 Phase 2 Fine-tunning 43
Gambar 4.12 Hasil Pelatihan Model Phase 2 44
Gambar 4.13 Grafik Accuracy dan Loss Model Phase 1 45
Gambar 4.14 Grafik Accuracy dan Loss Model Phase 2 47
Gambar 4.15 Hasil Evaluasi Model 50
Gambar 4.16 Hasil Confusion Matrix Pengujian 50
Gambar 4.17 Hasil Kurva ROC 51
Gambar 4.18 Hasil Kurva Precision–Recall 52
Gambar 4.19 Tahap Penyimpanan Model Hasil Pelatihan 53
Gambar 4.20 Tahap Backend dikembangkan dengan framework Flask 54
Gambar 4.21 Hasil Pengujian Implementasi Aplikasi 58

BAB I

PENDAHULUAN

1.1. Latar Belakang Masalah

Perkembangan teknologi digital saat ini membawa dampak besar di berbagai sektor, termasuk bidang kesehatan. Munculnya teknologi kecerdasan buatan (*Artificial Intelligence*/AI), terutama *deep learning*, menghadirkan peluang baru. Salah satu penerapan yang banyak diteliti adalah pemanfaatan pengolahan citra medis untuk mengidentifikasi kondisi kesehatan seseorang secara otomatis melalui gambar tertentu. Pendekatan ini mulai dianggap sebagai alternatif metode pemeriksaan konvensional karena dinilai lebih efisien, cepat, dan minim invasif (Suryani & Putra, 2022).

Anemia ialah kondisi ketika kadar hemoglobin (Hb) dalam darah berada di bawah batas normal, sehingga menyebabkan pasokan oksigen ke jaringan tubuh berkurang dan merupakan salah satu masalah kesehatan global yang masih sulit dikendalikan. Dalam laporan Global Burden of Disease (GBD) 2021, sekitar 1,92 miliar orang di seluruh dunia mengalami anemia (Vos et al., 2021), dengan prevalensi standar usia mencapai 23.176,2 per 100.000 populasi (BioMed Central). Data WHO (2021) juga menunjukkan bahwa wanita usia produktif dan anak-anak merupakan kelompok dengan angka kejadian anemia tertinggi. Di Indonesia, prevalensi anemia masih tergolong tinggi, terutama pada remaja dan ibu hamil (Kemenkes RI, 2022). Dampak klinisnya dapat berupa kelelahan menetap, penurunan konsentrasi, hingga komplikasi serius apabila tidak ditangani

Pemeriksaan anemia umumnya dilakukan melalui pengukuran kadar hemoglobin yang bersifat invasif dan membutuhkan fasilitas serta tenaga medis,

Kondisi ini menjadi kendala terutama di wilayah dengan keterbatasan layanan kesehatan. Oleh sebab itu, dibutuhkan alternatif pemeriksaan yang lebih praktis, tidak invasif, dan tetap akurat. Salah satu pendekatan yang mulai dikembangkan adalah analisis citra palpebral konjungtiva, yaitu bagian dalam kelopak mata yang secara visual dapat menunjukkan tingkat kecerahan atau kepucatan sebagai indikator kadar hemoglobin (Amalia et al., 2023).

Secara fisiologis, konjungtiva palpebral memiliki rona kemerahan karena terdapat banyak pembuluh darah kapiler. Apabila seseorang mengalami kekurangan hemoglobin, area tersebut akan tampak lebih pucat. Karakteristik visual tersebut menjadi dasar pengembangan sistem deteksi anemia berbasis pengolahan citra digital. Sejumlah studi menunjukkan bahwa warna konjungtiva dapat dijadikan parameter visual untuk memperkirakan kadar hemoglobin secara otomatis (Kasiviswanathan et al., 2020). Dengan memanfaatkan foto konjungtiva dari kamera ponsel atau perangkat optik sederhana, model *deep learning* dapat dilatih untuk membedakan citra penderita anemia dan non-anemia secara akurat.

Pendekatan *deep learning*, khususnya *Convolutional Neural Network* (CNN), mampu mempelajari pola visual seperti warna, tekstur, dan tingkat kecerahan secara otomatis tanpa proses ekstraksi fitur manual. Namun, pelatihan CNN dari awal umumnya membutuhkan dataset berukuran besar dan waktu komputasi yang tinggi. Oleh karena itu, *transfer learning* banyak digunakan dengan memanfaatkan model pra-latih seperti MobileNet, EfficientNet, atau ResNet yang sebelumnya dilatih pada dataset skala besar (Tan & Le, 2020). Dalam penelitian ini, *transfer learning* diterapkan untuk mendeteksi anemia melalui citra konjungtiva palpebral dengan dua kelas, yaitu anemia dan non-anemia, guna

mengevaluasi kemampuan model dalam melakukan klasifikasi pada data baru.

Penelitian Amalia et al. (2023) menunjukkan bahwa klasifikasi anemia berbasis citra konjungtiva palpebral dengan *transfer learning* mampu mencapai akurasi sekitar 85% dan menjadi dasar pengembangan sistem deteksi anemia non-invasif. Namun, masih terdapat aspek metodologis yang perlu diperbaiki, khususnya pada pengelolaan dataset dan validasi model. Augmentasi yang dilakukan sebelum pemisahan data latih dan data uji berpotensi menimbulkan *data leakage*. Secara metodologis, data uji seharusnya tetap bersifat murni tanpa augmentasi agar evaluasi model mencerminkan performa pada data baru secara objektif. Selain itu, ketidakseimbangan kelas menunjukkan perlunya pendekatan yang lebih terstruktur. Oleh karena itu, penelitian ini difokuskan pada perbaikan alur pengolahan data dan validasi untuk meningkatkan kemampuan generalisasi model, tanpa mengesampingkan kontribusi penelitian sebelumnya.

Berdasarkan kondisi tersebut, penelitian ini bertujuan mengembangkan sistem deteksi anemia non-invasif berbasis *deep learning* dengan pendekatan *transfer learning* pada citra konjungtiva palpebral yang diintegrasikan ke dalam sistem berbasis digital. Model dilatih menggunakan dua kelas data, yaitu anemia dan non-anemia, serta diuji menggunakan citra baru untuk menilai kemampuan generalisasinya. Melalui sistem ini, pengguna dapat mengambil atau mengunggah foto konjungtiva untuk memperoleh prediksi potensi anemia secara otomatis, sehingga diharapkan menjadi solusi skrining yang cepat, terjangkau, mudah diakses, dan ramah pengguna, sekaligus mendukung pencapaian tujuan pembangunan berkelanjutan pada aspek kesehatan masyarakat (United Nations, 2020).

1.2.Rumusan masalah

Penelitian ini membahas bagaimana merancang dan mengimplementasikan model *transfer learning* berbasis *deep learning* untuk mendeteksi kondisi anemia secara akurat melalui citra palpebral konjungtiva, serta bagaimana melakukan optimasi model agar mampu menghasilkan performa klasifikasi yang stabil dan memiliki kemampuan generalisasi yang baik terhadap citra baru. Selain itu, penelitian ini juga mengintegrasikan model deteksi anemia berbasis *deep learning* ke dalam sistem android, sehingga dapat digunakan secara praktis sebagai alat bantu deteksi dini anemia yang bersifat non-invasif.

1.3.Batasan Masalah

Penelitian ini memiliki batasan permasalahan yang dibahas agar dapat menyelesaikan permasalahan utama. Berikut ini batasan masalah penelitian ini

1. Penelitian berfokus pada klasifikasi 2 kelas, yaitu anemia dan non-anemia, dataset yang digunakan berasal dari sumber publik dan pengumpulan gambar secara terbatas (data anemia 1.293 dan non-anemia 1.165) .
2. Tahap *preprocessing* citra hanya mencakup *resize*, normalisasi, dan augmentasi sederhana
3. Evaluasi model difokuskan pada metrik performa klasifikasi, seperti *accuracy*, *precision*, *recall*, dan *F1-score*.
4. Implementasi sistem berbasis digital hanya difokuskan pada pengujian fungsi deteksi dan input objek penelitian dibatasi pada citra palpebral konjungtiva mata manusia
5. Sistem dikembangkan dalam bentuk aplikasi berbasis Android menggunakan react native untuk mendukung pengujian model.

1.4.Tujuan Penelitian

1. Merancang dan mengembangkan model deteksi anemia berbasis *transfer learning* dengan arsitektur MobileNetV2 atau EfficientNetB0, yang mampu mengklasifikasikan citra konjungtiva palpebral ke dalam dua kategori, yaitu anemia dan non-anemia.
2. Melatih dan menguji model dengan dataset citra konjungtiva berlabel untuk memperoleh hasil klasifikasi terbaik berdasarkan metrik performa seperti *accuracy*, *precision*, *recall*, dan *F1-score*
3. Menerapkan hasil model ke dalam sistem berbasis digital yang mampu menampilkan hasil deteksi anemia secara otomatis berdasarkan citra konjungtiva yang diunggah pengguna dan menguji kemampuan generalisasi model terhadap citra baru yang belum pernah dilatih sebelumnya, untuk memastikan sistem tetap memberikan hasil prediksi yang konsisten dan dapat diandalkan.

1.5.Manfaat Penelitian

1. Penelitian ini dapat menambah referensi ilmiah di bidang pengolahan citra medis dan *deep learning*, khususnya penerapan *transfer learning* untuk deteksi anemia non-invasif menggunakan citra palpebral konjungtiva.
2. Hasil penelitian menjadi identifikasi awal dasar pengembangan sistem skrining anemia berbasis deep learning yang sederhana, cepat, dan mudah digunakan melalui aplikasi Android.
3. Hasil penelitian ini diharapkan dapat mendukung program pencegahan anemia dan peningkatan kualitas kesehatan masyarakat, khususnya di wilayah dengan keterbatasan akses layanan kesehatan.

BAB II

LANDASAN TEORI

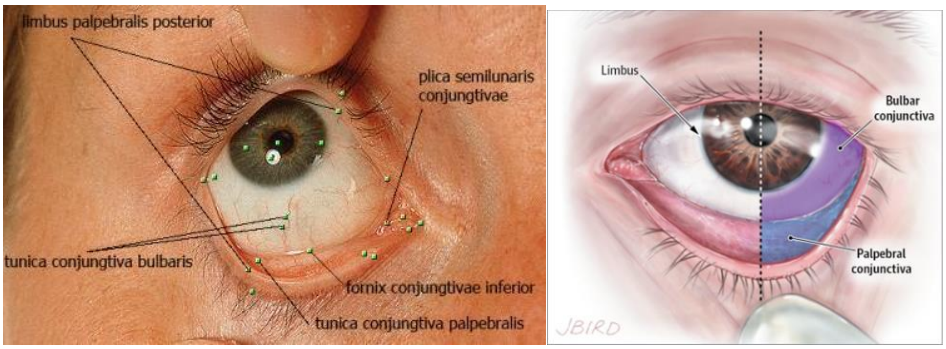
2.1. Anemia

Anemia merupakan kondisi medis yang ditandai oleh rendahnya kadar hemoglobin (Hb) dalam darah, yang berakibat pada berkurangnya kemampuan darah untuk mengangkut oksigen ke jaringan tubuh (World Health Organization, 2021). Kondisi ini dapat menyebabkan gejala seperti kelelahan, pucat, pusing, dan sesak napas. Menurut Kemenkes RI (2022), prevalensi anemia di Indonesia masih tergolong tinggi, terutama pada kelompok remaja dan wanita usia produktif.

Secara umum, anemia diklasifikasikan menjadi beberapa jenis, di antaranya anemia defisiensi besi, anemia aplastik, dan anemia hemolitik (Guyton & Hall, 2016). Metode diagnosis konvensional biasanya dilakukan dengan pemeriksaan darah laboratorium, seperti pengukuran kadar Hb dan hematokrit. Namun, cara ini bersifat invasif dan membutuhkan tenaga medis terlatih serta peralatan laboratorium yang memadai. Oleh karena itu, penelitian terkini mulai mengembangkan pendeteksian anemia *non-invasif*, salah satunya melalui analisis citra konjungtiva palpebra mata menggunakan teknologi pengolahan citra digital. Penelitian oleh Reddy et al. (2020) menunjukkan bahwa tingkat kepucatan pada konjungtiva dapat digunakan sebagai indikator visual anemia. Pendekatan ini memungkinkan pemeriksaan anemia dilakukan secara cepat, efisien, dan tanpa pengambilan darah.

2.2. Konjungtiva Palpebral

Konjungtiva palpebra merupakan selaput lendir tipis dan transparan yang melapisi bagian dalam kelopak mata dan berfungsi menjaga kelembapan serta melindungi bola mata dari infeksi (Khurana, 2018). Pada individu sehat, konjungtiva memiliki warna merah muda, sedangkan pada penderita anemia tampak lebih pucat akibat berkurangnya aliran darah dan kadar hemoglobin (Dutta



Gambar 2.1 Bagian Palpebral Conjunctiva

et al., 2019).

Citra konjungtiva palpebra menjadi salah satu objek yang banyak diteliti dalam diagnosis berbasis citra medis karena mudah diambil menggunakan kamera digital atau *smartphone* tanpa memerlukan peralatan khusus (Chowdhury et al., 2020) yang di tunjukkan pada gambar 2.1.

2.3. Pengolahan Citra Digital

Pengolahan citra digital (*digital image processing*) merupakan proses transformasi dan analisis citra untuk mengekstraksi informasi yang bermakna (Gonzalez & Woods, 2018). Tahapan umum dalam pengolahan citra meliputi *preprocessing*, segmentasi, ekstraksi fitur, dan klasifikasi.

1. Preprocessing

   Meliputi *resize*, normalisasi, peningkatan kontras, dan augmentasi

sederhana agar model lebih *robust* terhadap variasi cahaya dan posisi pengambilan gambar.

2. Segmentasi

   Proses memisahkan area relevan, seperti konjungtiva palpebral, dari bagian citra lainnya.

3. Ekstraksi Fitur

   Menangkap karakteristik visual seperti intensitas warna merah, tekstur jaringan, dan pola spasial (Gupta et al., 2021).

Dalam konteks deteksi anemia, tahap *preprocessing* digunakan untuk menyesuaikan pencahayaan,eksposur kontras, serta ukuran citra konjungtiva agar siap diproses oleh model pembelajaran mesin. Menurut Gupta et al. (2021), tahap ini sangat penting karena perbedaan pencahayaan dan posisi pengambilan gambar dapat mempengaruhi hasil prediksi model. Teknik pengolahan citra juga memungkinkan sistem mengenali pola visual seperti intensitas warna merah atau tekstur jaringan yang mengindikasikan kondisi anemia.

2.4. Deep Learning

Deep learning merupakan cabang dari *machine learning* yang menggunakan jaringan saraf tiruan (*artificial neural networks*) dengan banyak lapisan untuk meniru cara kerja otak manusia dalam mengenali pola data yang kompleks. Teknologi ini telah banyak diterapkan dalam bidang kesehatan untuk klasifikasi citra medis, termasuk deteksi kanker, pneumonia, hingga anemia (Liu et al., 2020).

Salah satu arsitektur yang paling umum digunakan *adalah Convolutional Neural Network* (CNN) karena kemampuannya dalam melakukan ekstraksi fitur

otomatis dari data citra tanpa memerlukan pemrograman manual (Goodfellow et al., 2016). CNN mempelajari fitur spasial dari gambar seperti tepi, tekstur, dan pola warna untuk menghasilkan representasi visual yang dapat digunakan dalam proses klasifikasi. Dalam penelitian ini, *deep learning* digunakan untuk membedakan citra konjungtiva normal dan konjungtiva anemik secara otomatis berdasarkan pola visual yang dipelajari oleh model.

2.4. Transfer Learning

Transfer learning merupakan pendekatan dalam *deep learning* yang memanfaatkan model pra-latih (*pre-trained model*) yang sebelumnya dilatih menggunakan dataset berskala besar, kemudian disesuaikan (*fine-tuning*) untuk menyelesaikan tugas yang lebih spesifik. Pendekatan ini terbukti efektif dalam meningkatkan performa model serta mempercepat proses pelatihan, khususnya pada kondisi ketersediaan data pelatihan yang terbatas (Dwijayana & Wibawa, 2022). Dalam bidang pengolahan citra medis, transfer learning banyak digunakan karena model pra-latih telah mampu menangkap fitur visual umum seperti warna, tekstur, dan pola bentuk, yang kemudian dapat disesuaikan untuk mendeteksi karakteristik penyakit tertentu, termasuk anemia (Tan et al., 2019). Oleh karena itu, metode ini menjadi solusi yang relevan untuk pengembangan sistem deteksi berbasis citra dengan jumlah dataset yang relatif terbatas.

Pada penelitian ini, pendekatan *transfer learning* digunakan untuk memanfaatkan kemampuan ekstraksi fitur dari arsitektur MobileNetV2 dalam mengklasifikasikan citra palpebral konjungtiva ke dalam dua kelas, yaitu anemia dan non-anemia. Pemanfaatan *transfer learning* memungkinkan model mencapai performa yang baik tanpa harus melatih jaringan dari awal, sebagaimana

ditunjukkan dalam berbagai penelitian sebelumnya pada citra medis (Yadav et al., 2019).

2.5. MobileNetV2

MobileNetV2 merupakan salah satu arsitektur Convolutional Neural Network (CNN) yang dirancang dengan fokus pada efisiensi komputasi, sehingga cocok digunakan pada perangkat dengan keterbatasan sumber daya seperti smartphone dan sistem berbasis mobile. Berdasarkan hasil penerapan MobileNetV2 pada berbagai tugas klasifikasi citra, arsitektur ini terbukti mampu menjaga keseimbangan antara jumlah parameter yang ringan dan performa klasifikasi yang baik melalui mekanisme *depthwise separable convolution* dan *inverted residual* (Hartono & Muslikh, 2025).

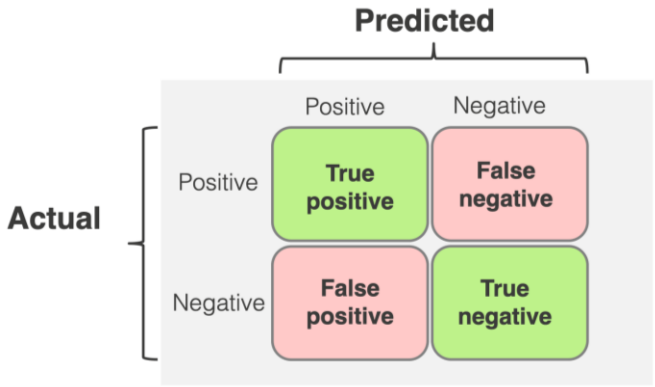
Dalam konteks penelitian ini, MobileNetV2 digunakan sebagai model utama untuk proses ekstraksi fitur dari citra palpebral konjungtiva. Model ini mampu menangkap karakteristik visual penting seperti variasi warna, tingkat kemerahan, dan pola tekstur jaringan yang berkaitan dengan kondisi anemia. Fitur-fitur tersebut selanjutnya diteruskan ke lapisan klasifikasi untuk menentukan kategori anemia atau non-anemia.

Beberapa penelitian terkini menunjukkan bahwa MobileNetV2 cukup efektif digunakan pada domain citra medis dengan ukuran model yang relatif ringan, sehingga memungkinkan penerapan pada sistem berbasis Android dan aplikasi mobile. Oleh karena itu, pemilihan MobileNetV2 dalam penelitian ini didasarkan pada pertimbangan efisiensi komputasi, kecepatan inferensi, serta keseimbangan antara kompleksitas model dan performa, sehingga sesuai dengan

tujuan pengembangan sistem deteksi anemia non-invasif berbasis perangkat mobile.

2.6. Confusion Matrix

Confusion Matrix adalah salah satu metode evaluasi yang umum digunakan untuk menilai kinerja model klasifikasi dengan membandingkan hasil prediksi model terhadap label sebenarnya dalam bentuk tabel. Metode ini sangat membantu dalam memahami kemampuan model, terutama pada permasalahan klasifikasi medis, di mana kesalahan prediksi dapat berdampak signifikan. *Confusion Matrix* terdiri dari empat komponen utama, yaitu *True Positive* (TP),



Gambar 2.2 Skema Confusion Matrix

True Negative (TN), *False Positive* (FP), dan *False Negative* (FN) (Hasnain et al., 2020).

True Positive (TP) menunjukkan jumlah data yang berhasil diklasifikasikan secara benar sebagai kelas positif, misalnya model memprediksi anemia pada citra konjungtiva yang memang berasal dari pasien anemia. *True Negative* (TN) merepresentasikan kondisi ketika model dengan tepat mengklasifikasikan data sebagai kelas negatif. Sebaliknya, *False Positive* (FP) terjadi ketika model salah mengklasifikasikan data negatif sebagai positif,

sedangkan *False Negative* (FN) menunjukkan kondisi ketika model gagal mendeteksi data positif yang seharusnya teridentifikasi. Skema confusion matrix diberikan pada gambar 2.2

Keempat komponen dalam Confusion Matrix tersebut menjadi dasar dalam perhitungan berbagai metrik evaluasi, seperti *accuracy*, *precision*, *recall*, dan *F1-score*. Metrik-metrik ini memberikan gambaran yang lebih menyeluruh mengenai performa model dibandingkan hanya mengandalkan nilai akurasi, terutama pada dataset yang memiliki ketidakseimbangan kelas. Performa model juga dievaluasi menggunakan beberapa metrik lain yang diperoleh dari *Confusion Matrix*, yaitu *accuracy*, *recall*, *precision* dan *F1-score*. Metrik-metrik ini digunakan untuk memberikan gambaran yang lebih menyeluruh terhadap kemampuan model dalam melakukan klasifikasi.

Akurasi (*accuracy*) digunakan untuk mengukur tingkat ketepatan model secara keseluruhan dengan membandingkan jumlah prediksi yang benar terhadap total data uji. Metrik ini memberikan gambaran umum performa model, namun memiliki keterbatasan pada kondisi data yang tidak seimbang.

$$Akurasi = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \quad (2)$$

Selain akurasi, evaluasi performa model juga dilakukan menggunakan metrik *precision*. *Precision* mengukur tingkat ketepatan prediksi positif yang dihasilkan oleh model, yaitu seberapa besar proporsi data yang diprediksi sebagai positif benar-benar sesuai dengan kondisi sebenarnya (Ramli et al., 2023). Metrik ini menjadi penting dalam konteks deteksi anemia, karena kesalahan prediksi positif dapat memengaruhi keandalan sistem sebagai alat bantu skrining awal. *Precision* dihitung dengan rumus sebagai berikut:

$$Presisi = \frac{TP}{(TP+FP)} \quad (3)$$

Metrik evaluasi selanjutnya adalah *recall* atau sensitivitas, yang digunakan untuk menilai kemampuan model dalam mendeteksi seluruh data positif yang sebenarnya. *Recall* berfokus pada seberapa baik model dalam meminimalkan kesalahan *False Negative*, yaitu kondisi ketika data positif tidak berhasil terdeteksi oleh model. Nilai *recall* dapat dihitung menggunakan persamaan berikut:

$$Recall = \frac{TP}{(TP+FN)} \quad (4)$$

Untuk memberikan penilaian yang lebih seimbang antara *precision* dan *recall*, digunakan metrik *F1-score. F1-score* merupakan rata-rata harmonis dari kedua metrik tersebut dan sering digunakan ketika dataset memiliki distribusi kelas yang tidak seimbang. Metrik ini memberikan gambaran performa model yang lebih representatif dibandingkan hanya mengandalkan akurasi saja. Perhitungan *F1-score* dirumuskan sebagai berikut:

$$f1 - Score = \frac{2TP}{(2TP+FP+FN)} \quad (5)$$

2.7. Implementasi Sistem Berbasis Digital

Sistem deteksi anemia pada penelitian ini diimplementasikan dalam bentuk aplikasi berbasis Android untuk mendukung penggunaan model deep learning secara praktis. Aplikasi dikembangkan menggunakan framework React Native. Pemilihan platform Android didasarkan pada tingginya penggunaan smartphone serta kemudahannya dalam mendukung proses skrining awal berbasis citra. Pengembangan aplikasi mobile dinilai efektif karena mendukung pengembangan

antarmuka serta memungkinkan integrasi dengan komponen sistem Android secara fleksibel dan efisien (Android Developers, 2023).

Model deteksi anemia yang telah dilatih menggunakan pendekatan transfer learning diintegrasikan ke dalam aplikasi sebagai komponen prediksi. Pengguna dapat mengunggah citra palpebral konjungtiva mata, kemudian sistem akan memproses citra tersebut dan menampilkan hasil prediksi berupa indikasi anemia atau non-anemia. Hasil prediksi bersifat sebagai skrining awal, sehingga tetap diperlukan pemeriksaan lanjutan oleh tenaga medis apabila terdeteksi indikasi anemia.

2.8. Ringkasan Peneliti Terdahulu

Berdasarkan pemaparan penelitian-penelitian terdahulu pada subbab sebelumnya yang memiliki keterkaitan langsung dengan topik penelitian ini, diketahui bahwa deteksi anemia non-invasif berbasis citra telah dikembangkan dengan berbagai pendekatan dan objek pengamatan. Penelitian-penelitian tersebut digunakan sebagai bahan perbandingan untuk mengidentifikasi kelebihan dan keterbatasan metode yang digunakan, baik dari sisi pengolahan data, arsitektur model, maupun hasil evaluasi. Untuk mempermudah proses analisis, ringkasan penelitian terdahulu disajikan dalam bentuk tabel yang memuat peneliti, metode, hasil, serta kelebihan dan kekurangannya. Ringkasan ini menjadi acuan dalam menentukan arah penelitian dan sebagai dasar pengembangan metode agar diperoleh sistem deteksi anemia dengan performa dan kemampuan generalisasi yang lebih baik.

Tabel 2.1 Penelitian Terdahulu

NO	Judul dan peneliti	Pembahasan	Metode	Kelebihan atau Kekurangan
1	Pengembangan Sistem Deteksi Anemia Non-Invasif melalui Analisis Citra Konjungtiva dengan Segmentasi U-Net dan Regresi Berbasis Fitur Warna (Winarsih, 2024)	Hasil pengujian regresi menunjukkan bahwa model mampu memperkirakan kadar hemoglobin dengan nilai MAE sekitar 1,1 g/dL dan tingkat akurasi estimasi mencapai ±82%. Capaian ini menandakan bahwa kombinasi segmentasi otomatis dan analisis fitur warna memiliki potensi yang cukup baik sebagai pendekatan awal dalam sistem deteksi anemia non-invasif berbasis citra.	Segmentasi U-Net (modifikasi), Support Vector Machine (SVM), dan Gradient Boosting Regression (GBR)	Kelebihan: - Segmentasi otomatis membantu memfokuskan analisis pada area konjungtiva yang relevan. - Estimasi kadar hemoglobin menunjukkan tingkat kesalahan yang relatif rendah. Kekurangan: - Performa sistem masih dipengaruhi kualitas citra dan kondisi pencahayaan. - Proses ekstraksi fitur warna menambah kompleksitas sebelum tahap prediksi.
2	Pengembangan model CNN untuk mendeteksi anemia berbasis citra konjungtiva palpebra. Model terdiri dari lima hidden layer dengan	Penelitian ini mengembangkan model deteksi anemia berbasis citra konjungtiva palpebra menggunakan arsitektur Convolutional Neural Network (CNN) yang terdiri dari lima hidden layer dengan variasi ukuran filter. Model dilatih untuk membedakan kondisi anemia dan non-anemia berdasarkan pola warna dan tekstur konjungtiva. Hasil pengujian menunjukkan akurasi klasifikasi yang tinggi, sehingga pendekatan	Convolutional Neural Network (CNN) dengan lima hidden layer dan variasi ukuran filter.	Kelebihan: - Mencapai akurasi klasifikasi yang tinggi (±94%). - Mampu menangkap karakteristik visual konjungtiva secara efektif. Kekurangan: - Tidak menggunakan transfer learning sehingga membutuhkan data dan waktu pelatihan lebih besar. - Arsitektur relatif kompleks dan kurang efisien untuk perangkat

NO	Judul dan peneliti	Pembahasan	Metode	Kelebihan atau Kekurangan
	variasi ukuran filter. (Magdalena et al., 2022)	ini dinilai memiliki potensi untuk dikembangkan sebagai sistem deteksi anemia berbasis citra digital.		dengan sumber daya terbatas.
3	Klasifikasi anemia melalui citra palpebral konjungtiva menggunakan metode transfer learning (Amalia et al., 2023)	Penelitian ini memanfaatkan citra palpebral konjungtiva sebagai indikator visual untuk deteksi anemia non-invasif dengan menerapkan metode transfer learning. Model CNN pra-latih digunakan untuk membedakan kondisi anemia dan non-anemia berdasarkan tingkat kepucatan dan rona warna konjungtiva. Hasil pelatihan dan validasi menunjukkan akurasi sekitar 85%, yang menandakan bahwa pendekatan ini cukup efektif meskipun menggunakan dataset terbatas.	Transfer learning berbasis Convolutional Neural Network (CNN) dengan model pra-latih, disertai tahap praproses berupa normalisasi dan augmentasi citra	Kelebihan: - Memberikan performa yang baik pada dataset berukuran terbatas. - Memberikan performa yang baik pada dataset berukuran terbatas. - Berpotensi dikembangkan untuk sistem skrining berbasis perangkat mobile. Kekurangan: - Augmentasi citra dilakukan sebelum pemisahan data latih dan uji, sehingga berpotensi menimbulkan *data leakage*. - Evaluasi generalisasi pada data baru masih terbatas.
4	Deteksi anemia menggunakan deep learning berbasis citra konjungtiva, kuku, telapak	Penelitian ini mengkaji penerapan metode deep learning untuk mendeteksi anemia secara non-invasif dengan memanfaatkan berbagai citra bagian tubuh, meliputi konjungtiva, kuku, telapak tangan, dan lidah. Beberapa arsitektur Convolutional Neural	Deep learning berbasis CNN dengan evaluasi beberapa arsitektur, disertai tahap	Kelebihan: - Mengkaji beberapa area tubuh sebagai sumber informasi visual anemia. - Menggunakan pendekatan deep learning yang relevan untuk citra medis. - Menunjukkan potensi

NO	Judul dan peneliti	Pembahasan	Metode	Kelebihan atau Kekurangan
	tangan, dan lidah (IRJAEH, 2023)	Network (CNN), termasuk MobileNet, dievaluasi untuk membandingkan performa klasifikasi pada masing-masing jenis citra. Hasil penelitian menunjukkan bahwa karakteristik visual seperti warna dan tingkat kecerahan pada area tubuh tertentu dapat dimanfaatkan sebagai indikator anemia, serta bahwa penggunaan arsitektur CNN yang efisien berpotensi mendukung pengembangan sistem deteksi berbasis perangkat bergerak.	preprocessing citra dan pengujian performa model.	penggunaan arsitektur ringan untuk sistem non-invasif. Kekurangan: - Fokus masih bersifat komparatif tanpa pendalaman pada satu area tubuh tertentu. - Evaluasi generalisasi pada data baru masih terbatas.

NO	Judul dan peneliti	Pembahasan	Metode	Kelebihan atau Kekurangan
5	Detection of iron deficiency anemia by medical images: a comparative study of machine learning algorithms Detection of iron deficiency anemia by medical images: a comparative study of machine learning algorithms (Appiahene et al., 2023).	Penelitian ini membandingkan beberapa algoritma pembelajaran mesin, seperti CNN, Support Vector Machine (SVM), dan Naive Bayes, dalam mendeteksi anemia menggunakan citra telapak tangan. Analisis dilakukan dengan mengevaluasi performa masing-masing metode berdasarkan metrik klasifikasi standar. Hasil penelitian menunjukkan bahwa citra telapak tangan memiliki potensi sebagai media skrining anemia non-invasif, dengan CNN memberikan performa yang lebih stabil dibandingkan metode konvensional lainnya pada dataset tertentu.	Klasifikasi citra berbasis machine learning dan deep learning (CNN), disertai preprocessing citra dan evaluasi performa.	Kelebiihan: - Menyajikan perbandingan langsung beberapa algoritma klasifikasi. - Mendukung penggunaan citra telapak tangan sebagai alternatif skrining anemia. - Memberikan gambaran performa CNN dibandingkan metode klasik. Kekurangan: - Sensitivitas terhadap variasi pencahayaan dan kualitas citra masih cukup tinggi. - Belum mengkaji integrasi model ke dalam sistem berbasis aplikasi atau perangkat mobile.

2.9. Analisis Gap

Kajian studi sebelumnya menunjukkan sejumlah ruang yang masih perlu diperbaiki. Pertama, pengembangan sistem deteksi anemia berbasis citra yang diadaptasikan secara optimal ke perangkat Android masih sangat terbatas, terutama yang memanfaatkan arsitektur model ringan untuk pemrosesan langsung

di perangkat. Sebagian penelitian berfokus pada pelatihan model saja tanpa menghasilkan prototipe aplikasi yang dapat digunakan secara praktis.

Kedua, beberapa studi menghadapi kendala teknis seperti penggunaan dataset berukuran kecil dan adanya potensi *data leakage* akibat alur pengolahan data yang kurang tepat. Penelitian ini memperbaiki aspek tersebut dengan melakukan pemisahan data sebelum augmentasi serta memanfaatkan lebih dari satu sumber dataset untuk memperoleh variasi citra yang lebih representatif.

Ketiga, kemampuan model dalam mengenali citra baru dari perangkat belum banyak dievaluasi pada penelitian sebelumnya. Oleh karena itu, penelitian ini mengutamakan pengujian generalisasi menggunakan citra dari beberapa sumber berbeda. Selain itu, integrasi arsitektur MobileNetV2 sebagai model ringan yang dirancang khusus pada perangkat mobile belum banyak diterapkan pada studi-studi terdahulu terkait deteksi anemia untuk kebutuhan skrining non-invasif melalui system berbasis digital.

BAB III
METODOLOGI PENELITIAN

3.1. Pendekatan Penelitian

Penelitian ini menggunakan pendekatan kuantitatif eksperimental yang berfokus pada pengembangan dan evaluasi model deteksi anemia berbasis *deep learning* melalui citra palpebral konjungtiva. Proses penelitian dilakukan secara sistematis dalam beberapa tahap, dimulai dari pengumpulan data citra, pengolahan awal, pelatihan model hingga implementasi ke aplikasi Android.

Model dikembangkan melalui tahapan pengolahan citra digital, di mana gambar konjungtiva diproses untuk mengekstraksi ciri penting yang berkaitan dengan kondisi hemoglobin, seperti tingkat kecerahan dan rona kemerahan. Proses ekstraksi fitur dilakukan menggunakan arsitektur MobileNetV2, yang berfungsi sebagai *feature extractor* berbasis *deep learning* dan telah terbukti efektif dalam mengenali pola visual pada dataset terbatas. Hasil ekstraksi kemudian diteruskan ke lapisan klasifikasi untuk membedakan citra dalam dua kategor anemia dan non-anemia.

Pendekatan transfer learning dipilih karena dapat meningkatkan akurasi sekaligus mengurangi waktu pelatihan, dengan memanfaatkan bobot pra-latih dari dataset berskala besar. Seluruh proses penelitian dirancang sebagai studi terapan, meliputi perancangan sistem, pelatihan model, evaluasi performa, dan implementasi akhir dalam perangkat Android. Dataset yang digunakan berasal dari sumber publik serta pengumpulan terbatas.

Evaluasi model dilakukan menggunakan metrik umum pada klasifikasi citra, yaitu accuracy, precision, recall, dan F1-score, untuk memastikan performa model tidak hanya tinggi pada data latih tetapi juga stabil pada citra uji baru.

Pendekatan ini selaras dengan tujuan penelitian untuk menilai efektivitas MobileNetV2 sebagai model lightweight yang dapat dioptimalkan menjadi aplikasi Android melalui TensorFlow Lite, sehingga mampu memberikan solusi praktis terhadap keterbatasan metode deteksi anemia konvensional.

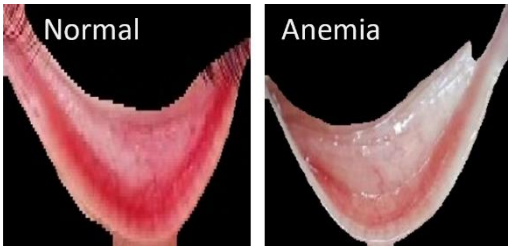
Melalui pendekatan eksperimental ini, penelitian diharapkan mampu menghasilkan model yang efisien, mudah diimplementasikan, dan memiliki nilai terapan tinggi dalam dunia medis, khususnya untuk skrining anemia secara non-invasif menggunakan perangkat mobile.

3.2. Teknik Pengumpulan Data

Teknik pengumpulan data pada penelitian ini dilakukan dengan menghimpun kumpulan citra palpebral konjungtiva yang merepresentasikan dua kategori utama, yaitu anemia dan non-anemia. Seluruh datsa yang digunakan bersifat sekunder, berasal dari sumber publik yang telah banyak dimanfaatkan dalam studi serupa, seperti dataset dari Mendeley Data, Roboflow, serta beberapa koleksi citra yang dihimpun secara terbatas dengan prosedur standar dokumentasi. Pemilihan sumber terbuka dilakukan untuk memastikan ketersediaan data yang terverifikasi sekaligus relevan dengan kebutuhan penelitian.

Setiap citra yang dikumpulkan kemudian diseleksi berdasarkan kualitas dan kesesuaian objek, Pada dataset dari Roboflow, diketahui bahwa sebagian data telah melalui proses augmentasi otomatis. Oleh karena itu, pada penelitian ini dilakukan pembersihan data secara manual dengan menghilangkan citra hasil augmentasi otomatis serta menghapus data duplikat, sehingga dataset yang digunakan merupakan citra asli tanpa modifikasi buatan. Langkah ini dilakukan untuk menjaga kemurnian data uji dan menghindari potensi bias selama proses

pelatihan dan evaluasi model sebelum akhirnya diproses ke tahap lebih lanjut. Untuk mendukung proses pelatihan model, dataset dibagi menjadi tiga bagian, yaitu data latih, data validasi, dan data uji, yang masing-masing berfungsi untuk mengoptimalkan pembelajaran model, mencegah *overfitting*, serta menilai



Gambar 3.1 contoh non-anemic & anemic

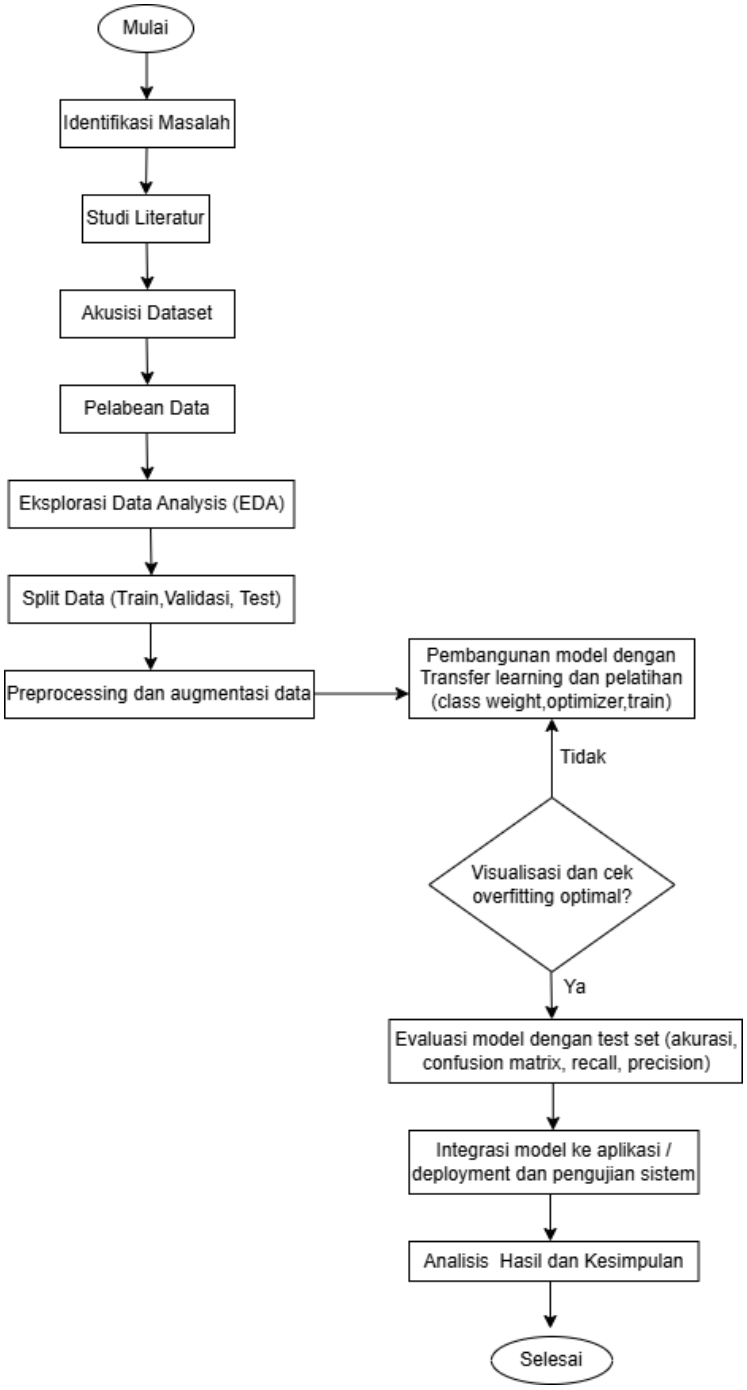
performa akhir terhadap data baru yang belum pernah dilihat model.

Seluruh citra yang digunakan selanjutnya melalui tahapan preprocessing agar sesuai dengan kebutuhan arsitektur MobileNetV2. Proses ini meliputi pengubahan ukuran gambar, normalisasi piksel, pengaturan proporsi warna agar konsisten, serta penerapan augmentasi ringan untuk memperluas variasi data tanpa mengubah makna visual utama. Tahapan tersebut bertujuan meningkatkan kualitas data dan memastikan model menerima masukan yang seragam selama pelatihan. Teknik pengumpulan data ini dirancang secara sistematis untuk mendukung pendekatan kuantitatif eksperimental yang digunakan, sehingga model dapat mempelajari pola visual pada konjungtiva secara optimal dan menghasilkan prediksi yang akurat terhadap kondisi anemia berdasarkan citra.

3.3 Tahapan Penelitian

Alur penelitian ini disusun secara sistematis untuk menggambarkan tahapan pengembangan sistem deteksi anemia non-invasif berbasis citra palpebral konjungtiva menggunakan metode deep learning dengan pendekatan transfer

learning. Setiap tahapan saling berkaitan dan dirancang agar sesuai dengan praktik penelitian deep learning pada umumnya.



Gambar 3.2 Tahapan Penelitian

1. Mulai

Penelitian diawali dengan perumusan topik dan tujuan penelitian, yaitu mengembangkan sistem deteksi anemia secara non-invasif berbasis citra

konjungtiva. Pada tahap ini juga ditentukan pendekatan penelitian, metode yang digunakan, serta ruang lingkup penelitian agar proses pengembangan sistem berjalan terarah.

2. Identifikasi Masalah

Tahap identifikasi masalah dilakukan untuk memahami permasalahan utama yang melatarbelakangi penelitian, yaitu masih dominannya metode pemeriksaan anemia yang bersifat invasif dan membutuhkan fasilitas medis tertentu. Kondisi ini mendorong perlunya solusi alternatif berbasis citra digital yang lebih praktis, mudah diakses, dan dapat digunakan sebagai alat skrining awal anemia.

3. Studi Literatur

Pada tahap ini dilakukan penelusuran dan analisis literatur yang relevan dengan topik penelitian, meliputi konsep anemia, karakteristik citra palpebral konjungtiva, pengolahan citra digital, convolutional neural network (CNN), serta metode *transfer learning* dengan arsitektur MobileNetV2. Studi literatur ini menjadi landasan teoritis dalam perancangan alur sistem dan pemilihan metode yang digunakan.

4. Akuisisi Dataset

Dataset yang digunakan dalam penelitian diperoleh dari sumber publik serta data tambahan yang relevan dengan citra palpebral konjungtiva. Data citra dikumpulkan dalam bentuk gambar digital dan disesuaikan dengan kebutuhan penelitian. Tahap ini memastikan bahwa data yang digunakan memiliki kualitas visual yang memadai untuk proses pelatihan model.

5. Pelabelan Data

Data citra yang telah dikumpulkan kemudian diberi label ke dalam dua kelas,

yaitu *anemic* dan *non-anemic*. Proses pelabelan ini bertujuan untuk memastikan bahwa setiap citra memiliki kelas yang jelas sehingga dapat digunakan dalam proses pembelajaran terawasi (*supervised learning*).

6. Eksplorasi Data (*Exploratory Data Analysis*)

Tahap eksplorasi data dilakukan untuk memahami karakteristik dataset secara lebih mendalam. Proses ini meliputi analisis jumlah data pada masing-masing kelas, distribusi data, serta kondisi ketidakseimbangan kelas *(class imbalance*). Hasil eksplorasi data digunakan sebagai dasar dalam menentukan strategi *preprocessing* dan penanganan ketidakseimbangan data.

7. Split Data

Dataset selanjutnya dibagi menjadi data latih, data validasi, dan data uji. Pembagian ini bertujuan untuk memastikan bahwa model dapat dilatih, divalidasi, dan diuji secara objektif, serta untuk menghindari bias evaluasi terhadap performa model.

8. Preprocessing dan Augmentasi Data

Tahap preprocessing dilakukan untuk mempersiapkan citra sebelum masuk ke proses pelatihan model. *Preprocessing* mencakup beberapa langkah utama, yaitu *resize* untuk menyeragamkan ukuran citra sesuai dengan input MobileNetV2, normalisasi untuk menyesuaikan rentang nilai piksel agar proses pelatihan lebih stabil, augmentasi dan balancing untuk meningkatkan variasi data latih dan mengatasi ketidakseimbangan kelas. Tahapan ini bertujuan agar citra memiliki kualitas dan format yang konsisten serta mampu meningkatkan generalisasi model.

9. Pembangunan dan Pelatihan Model dengan Transfer Learning

Pada tahap ini dilakukan pembangunan model *deep learning* dengan memanfaatkan arsitektur MobileNetV2 sebagai *feature extractor*. Model dikonfigurasi dengan penambahan lapisan klasifikasi sesuai kebutuhan penelitian. Proses ini mencakup penentuan *optimizer*, penerapan *class weight* untuk menangani ketidakseimbangan data, serta proses pelatihan model. Pelatihan dilakukan dalam beberapa fase, termasuk pelatihan awal dan *fine-tuning* untuk meningkatkan performa model.dan Fungsi *loss* yang digunakan pada penelitian ini adalah *binary cross-entropy*, yang sesuai untuk tugas klasifikasi biner antara citra anemia dan non-anemia. Fungsi ini digunakan untuk mengoptimalkan perbedaan antara prediksi probabilitas model dan label sebenarnya selama proses pelatihan.

10. Validasi Model dan Pengecekan Overfitting

Setelah pelatihan, dilakukan tahap validasi untuk memantau kinerja model selama proses *training*. Validasi dilakukan melalui visualisasi hasil pelatihan, seperti grafik akurasi dan *loss*, serta pengecekan indikasi *overfitting* atau *underfitting*. Apabila ditemukan masalah pada tahap ini, model dapat disesuaikan kembali sebelum masuk ke tahap evaluasi akhir.

11. Evaluasi Model

Model yang telah tervalidasi kemudian dievaluasi menggunakan data uji. Evaluasi dilakukan dengan menggunakan metrik performa klasifikasi, seperti akurasi, *precision, recall,* dan *F1-score*, serta visualisasi *confusion matrix*. Tahap ini bertujuan untuk menilai kemampuan model dalam membedakan citra anemia dan non-anemia secara objektif.

12. Integrasi Model dan Pengujian Sistem

Model terbaik diintegrasikan ke dalam sistem aplikasi berbasis Android. Tahap

ini mencakup pengujian fungsi utama sistem, mulai dari input citra konjungtiva hingga keluaran hasil prediksi anemia atau non-anemia.

13. Analisis Hasil dan Kesimpulan

Hasil evaluasi dianalisis untuk menilai efektivitas model yang dikembangkan serta kesesuaiannya dengan tujuan penelitian. Analisis ini menjadi dasar dalam penarikan kesimpulan mengenai kinerja sistem deteksi anemia yang diusulkan, sekaligus mengidentifikasi keterbatasan dan potensi pengembangan di masa mendatang.

14. Selesai

Tahap akhir menandai selesainya seluruh proses penelitian setelah tujuan penelitian tercapai dan seluruh hasil dianalisis serta didokumentasikan.

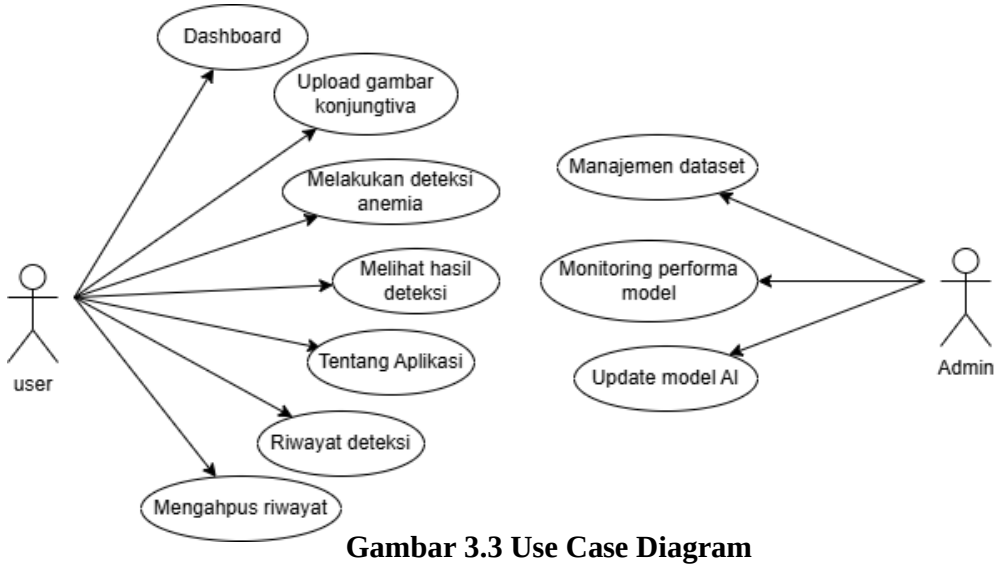
3.4 Uml Sistem Deteksi Anemia

Perancangan sistem deteksi anemia berbasis Android menggunakan Unified Modeling Language (UML). Pemodelan UML digunakan untuk menggambarkan alur proses, fungsi sistem, serta interaksi antar komponen secara terstruktur dan mudah dipahami. Diagram yang disajikan meliputi use case diagram, activity diagram, dan sequence diagram, yang disusun untuk merepresentasikan proses kerja sistem deteksi anemia mulai dari interaksi pengguna hingga proses prediksi oleh model deep learning.

1. Use Case Diagram

Menggambarkan fungsi-fungsi utama sistem serta interaksi antara aktor dengan sistem. Diagram ini terdapat dua aktor, yaitu user dan admin. User berperan sebagai pengguna aplikasi yang dapat mengakses fitur utama, seperti membuka dashboard, mengunggah citra konjungtiva, melakukan deteksi anemia, melihat

hasil deteksi, mengelola riwayat deteksi, serta mengakses informasi tentang aplikasi.



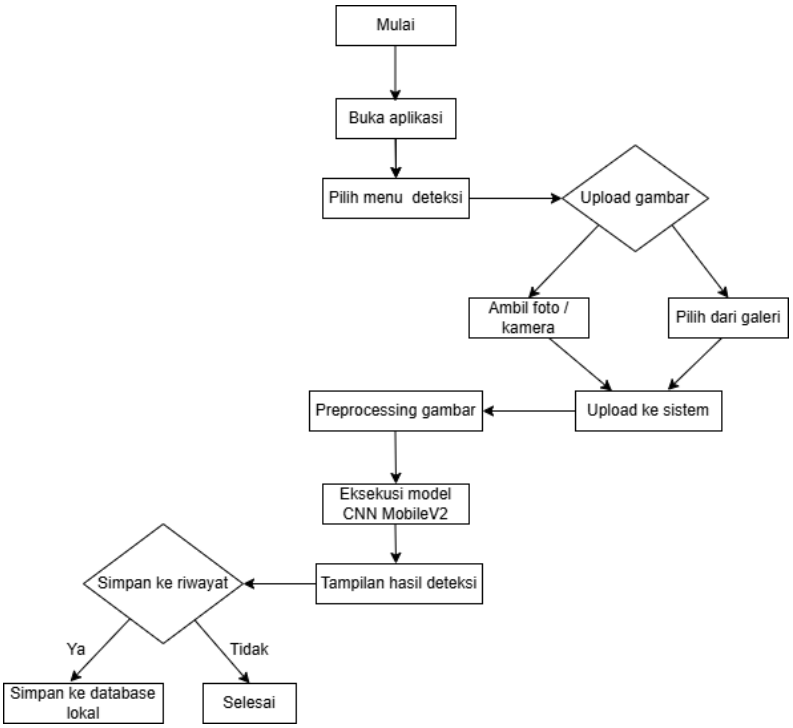
Gambar 3.3 Use Case Diagram

Pada gambar 3.3, admin memiliki peran dalam pengelolaan sistem, yang meliputi manajemen dataset, pemantauan performa model, dan pembaruan model AI apabila diperlukan. Pemisahan peran ini menunjukkan bahwa sistem tidak hanya berfokus pada penggunaan oleh masyarakat, tetapi juga menyediakan kontrol untuk pengelolaan dan pemeliharaan model secara berkelanjutan. Diagram ini mendukung kebutuhan penelitian yang tidak hanya menekankan akurasi model, tetapi juga kesiapan sistem untuk digunakan dan dikembangkan lebih lanjut.

2. Activity Diagram

Diagram menggambarkan alur kerja sistem deteksi anemia dari sudut pandang proses yang dijalankan oleh pengguna dan sistem. Proses dimulai ketika pengguna membuka aplikasi dan memilih menu deteksi anemia. Selanjutnya, pengguna diberikan pilihan untuk mengunggah citra palpebral konjungtiva, baik melalui pengambilan foto langsung menggunakan kamera maupun memilih gambar dari

galeri perangkat.

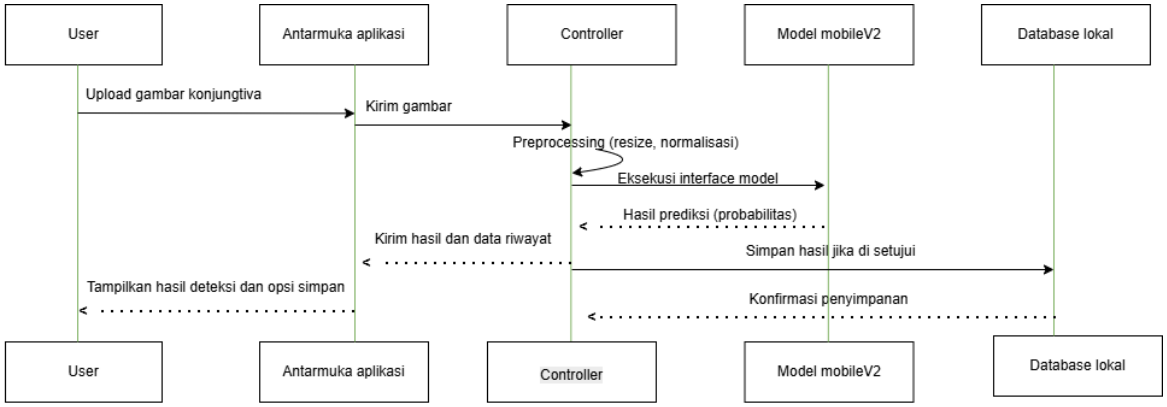


Gambar 3.4 Activity Diagram

Citra yang dipilih kemudian diunggah ke sistem dan diproses melalui tahap preprocessing, yang meliputi penyesuaian ukuran dan normalisasi citra agar sesuai dengan kebutuhan input model. Setelah itu, sistem menjalankan proses inferensi menggunakan model CNN berbasis MobileNetV2 untuk menghasilkan prediksi kondisi anemia atau non-anemia. Hasil deteksi ditampilkan kepada pengguna, disertai opsi untuk menyimpan hasil ke dalam riwayat. Apabila pengguna menyetujui, data disimpan ke dalam database lokal, sedangkan jika tidak, proses langsung diakhiri. Alur ini mencerminkan proses penggunaan sistem secara end-to-end sesuai dengan tujuan skrining awal anemia ditujukan pada gambar 3.4.

3. Sequence

Pada sequence diagram menggambarkan urutan interaksi antar komponen sistem secara kronologis. Proses dimulai ketika user mengunggah citra konjungtiva melalui antarmuka aplikasi. Antarmuka kemudian meneruskan citra tersebut ke controller untuk diproses lebih lanjut. Controller menjalankan preprocessing citra, seperti resize dan normalisasi, sebelum meneruskannya ke model MobileNetV2.

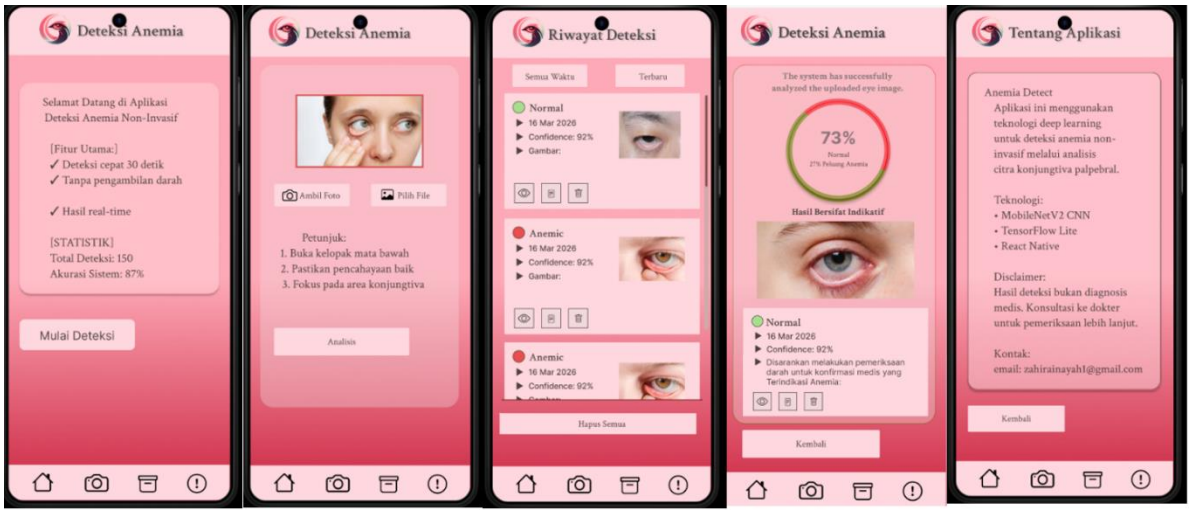


Gambar 3.5 Sequence Diagram

Pada gambar 3.5, model melakukan proses inferensi dan mengembalikan hasil prediksi berupa probabilitas klasifikasi anemia atau non-anemia. Hasil ini kemudian dikirim kembali ke controller dan diteruskan ke antarmuka aplikasi untuk ditampilkan kepada pengguna. Jika pengguna memilih untuk menyimpan hasil deteksi, controller akan menyimpan data tersebut ke dalam database lokal dan mengirimkan konfirmasi penyimpanan. Diagram ini menunjukkan alur komunikasi yang jelas antara user, antarmuka, logika sistem, model AI, dan penyimpanan data, serta mencerminkan implementasi sistem yang sesuai dengan arsitektur aplikasi berbasis Android.

3.5 Rancangan Interface

Rancangan antarmuka aplikasi deteksi anemia ini disusun dengan fokus pada kemudahan penggunaan, kejelasan alur, dan efisiensi proses deteksi. Aplikasi dirancang agar pengguna dapat melakukan pemeriksaan anemia secara mandiri melalui citra konjungtiva palpebral mata tanpa prosedur yang rumit.



Gambar 3.6 Rancangan Interface

Tampilan awal (halaman Home) berfungsi sebagai pengantar aplikasi. Pada halaman ini ditampilkan informasi singkat mengenai fungsi utama aplikasi, tingkat akurasi sistem, serta tombol Mulai Deteksi sebagai akses utama menuju proses pemeriksaan. Desain halaman dibuat sederhana dengan penekanan pada satu aksi utama agar pengguna langsung memahami langkah awal yang harus dilakukan.

Halaman Deteksi menjadi inti dari aplikasi. Pada halaman ini pengguna diberikan dua opsi, yaitu mengambil gambar secara langsung menggunakan kamera atau mengunggah gambar dari galeri. Tersedia pula petunjuk singkat terkait posisi mata dan pencahayaan untuk memastikan kualitas citra yang diunggah sesuai dengan kebutuhan sistem. Setelah gambar dipilih, pengguna

dapat menjalankan proses analisis dengan satu tombol, sehingga alur deteksi tetap singkat dan mudah diikuti.Hasil analisis ditampilkan pada halaman Hasil Deteksi. Informasi yang disajikan meliputi persentase hasil prediksi, kategori kondisi (normal, indikasi anemia ringan, atau indikasi anemia), serta cuplikan citra mata yang dianalisis. Penyajian hasil didukung dengan indikator visual berupa warna dan grafik agar pengguna dapat memahami hasil deteksi dengan cepat tanpa perlu interpretasi yang kompleks.

Aplikasi juga menyediakan halaman Riwayat Deteksi yang menampilkan daftar hasil pemeriksaan sebelumnya. Fitur ini memungkinkan pengguna untuk melihat kembali hasil deteksi terdahulu, termasuk tanggal pemeriksaan dan status kondisi, sehingga dapat digunakan sebagai bahan pemantauan secara berkala. Selain itu, halaman Tentang Aplikasi disediakan untuk menjelaskan tujuan pengembangan, teknologi yang digunakan, serta batasan penggunaan aplikasi. Informasi ini bertujuan memberikan pemahaman bahwa hasil deteksi bersifat indikatif dan bukan sebagai pengganti diagnosis medis.

Secara keseluruhan, rancangan antarmuka aplikasi ini dibuat dengan pendekatan minimalis dan konsisten, menyesuaikan dengan fungsi utama sistem deteksi anemia berbasis citra konjungtiva palpebral. Alur navigasi dirancang linear dan intuitif agar pengguna dapat melakukan deteksi dengan cepat, aman, dan nyaman.

BAB IV

PEMBAHASAN DAN HASIL

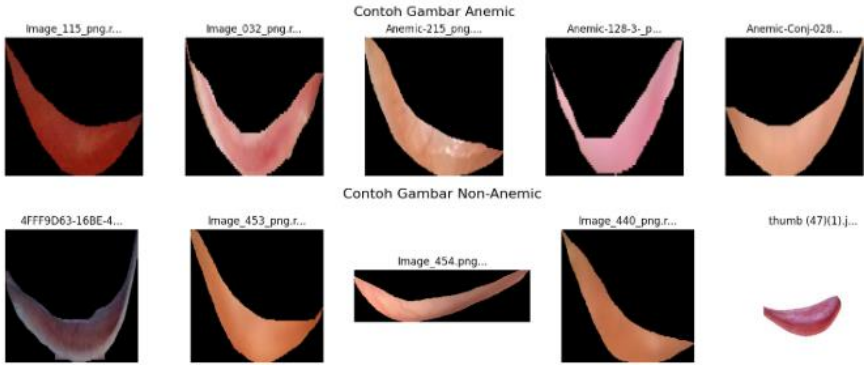
4.1 Akuisisi dan Analisis Dataset

Dataset yang digunakan dalam penelitian ini berupa citra konjungtiva palpebral untuk mendeteksi kondisi anemia dan non-anemia yang diperoleh melalui platform Roboflow. Pada sumber awal tersedia lebih dari 3.864 citra anemia dan 3.447 citra non-anemia. Namun, dataset tersebut telah teraugmentasi otomatis, sedangkan dalam praktik yang baik, proses pembagian data (train, validation, test) seharusnya dilakukan menggunakan citra asli agar tidak terjadi kebocoran data (data leakage).

Oleh karena itu, dilakukan pembersihan dan seleksi secara manual untuk memastikan bahwa data yang digunakan benar-benar merupakan sampel asli dan tidak berasal dari hasil transformasi berulang. Metode manual dipilih karena penyaringan otomatis melalui Google Colab masih menyisakan citra yang terlalu mirip dan berisiko menghapus beberapa gambar asli. Setelah proses seleksi selesai, diperoleh 1.293 citra anemia dan 1.165 citra non-anemia yang telah berlabel dengan baik dan siap digunakan untuk tahap analisis serta pembagian dataset.

Sebelum tahap pelatihan, dilakukan exploratory data analysis (EDA) untuk memahami karakteristik dataset. Berdasarkan analisis di Google Colab, distribusi kelas menunjukkan jumlah citra anemia sedikit lebih banyak dibandingkan non-anemia, namun selisihnya tidak signifikan sehingga dataset masih tergolong seimbang. Pemeriksaan ukuran gambar meliputi tinggi, lebar, dan rasio aspek juga

menunjukkan adanya variasi resolusi antar citra, sehingga diperlukan penyeragaman ukuran sebelum dimasukkan ke model.



Gambar 4.1 Citra sebelum di Processing

Hasil analisis statistik pada gambar 4.1 menunjukkan bahwa ukuran citra memiliki variasi yang cukup besar. Pada kelas anemia, lebar citra berkisar antara 91 hingga 640 piksel dengan rata-rata 475,5 piksel, sedangkan tinggi berkisar antara 34 hingga 640 piksel dengan rata-rata 432,7 piksel. Pada kelas non-anemia, lebar citra berkisar antara 79 hingga 640 piksel dengan rata-rata 497,5 piksel, dan tinggi antara 33 hingga 640 piksel dengan rata-rata 473,3 piksel. Variasi aspect ratio yang cukup tinggi (hingga >5) menunjukkan bahwa citra memiliki perbedaan sudut pengambilan dan framing, sehingga proses resizing menjadi tahap krusial sebelum pelatihan model.

Visualisasi sampel dari masing-masing kelas memperlihatkan bahwa perbedaan warna antara konjungtiva anemia dan non-anemia cenderung halus. Citra anemia umumnya tampak lebih pucat, sedangkan non-anemia lebih kemerahan, namun perbedaan ini sering dipengaruhi oleh pencahayaan, sudut pengambilan gambar, serta tekstur urat halus pada area konjungtiva. Analisis intensitas piksel juga menunjukkan variasi kontras dan tingkat kecerahan. Kondisi

ini menjadi tantangan dalam proses klasifikasi karena model harus mampu mengenali perbedaan warna dan tekstur yang tipis serta tidak selalu konsisten.

Dataset kemudian dibagi ke dalam tiga subset, yaitu

1. Data latih terdiri dari 905 citra anemia dan 815 citra non-anemia yang digunakan untuk melatih model dalam mengenali pola.
2. Data validasi berjumlah 193 citra anemia dan 175 citra non-anemia yang digunakan untuk memantau performa model selama proses pelatihan.
3. Data uji terdiri dari 195 citra anemia dan 175 citra non-anemia yang digunakan untuk mengevaluasi kinerja akhir model setelah pelatihan selesai.

Secara keseluruhan, dataset ini memiliki variasi intensitas piksel, bentuk konjungtiva palpebral, kontras warna, serta tekstur pembuluh darah yang berbeda-beda pada setiap individu. Dengan proses pembersihan yang teliti serta pembagian data yang terstruktur, dataset ini dinilai cukup representatif untuk mendukung pengembangan model deteksi anemia berbasis citra.

4.2 Preprocessing Data

Sebelum proses pelatihan dilakukan, seluruh citra terlebih dahulu melalui tahap preprocessing agar sesuai dengan kebutuhan arsitektur MobileNetV2. Tahap ini bertujuan untuk menyeragamkan ukuran input, menyesuaikan format data dengan model, serta meningkatkan stabilitas selama proses training. Proses preprocessing dilakukan menggunakan *ImageDataGenerator* dari TensorFlow yang berfungsi untuk membaca dataset langsung dari struktur direktori serta melakukan transformasi citra secara otomatis saat pelatihan berlangsung. Seluruh citra diubah ukurannya menjadi 224 × 224 piksel sesuai parameter *input size*

model. Penyeragaman ukuran ini diperlukan karena jaringan MobileNetV2 hanya dapat memproses input dengan dimensi tetap dalam satu batch pelatihan.

```
val_test_gen = ImageDataGenerator(
    preprocessing_function=preprocess_input)
train_data = train_gen.flow_from_directory(
    TRAIN_DIR,
    target_size=INPUT_SIZE,
    batch_size=BATCH_SIZE,
    class_mode='binary',
    shuffle=True)

val_data = val_test_gen.flow_from_directory(
    VAL_DIR,
    target_size=INPUT_SIZE,
    batch_size=BATCH_SIZE,
    class_mode='binary',
    shuffle=False)

test_data = val_test_gen.flow_from_directory(
    TEST_DIR,
    target_size=INPUT_SIZE,
    batch_size=1,
    class_mode='binary',
    shuffle=False)
```

Gambar 4.2 Tahap Preprocessing Data

Selanjutnya pada gambar 4.2 diterapkan fungsi *preprocess_input* bawaan MobileNetV2 pada data generator. Fungsi ini melakukan normalisasi nilai piksel dari rentang awal [0, 255] menjadi skala [-1, 1], yang merupakan standar preprocessing pada model pretrained berbasis ImageNet. Hasil verifikasi preprocessing menunjukkan nilai minimum piksel sebesar −1.000 dan maksimum sebesar 1.000, sehingga dapat disimpulkan bahwa transformasi data telah sesuai dengan kebutuhan model. Format batch yang dihasilkan memiliki dimensi (32, 224, 224, 3), menandakan setiap batch berisi 32 citra berwarna dengan tiga channel RGB.

Augmentasi data hanya diterapkan pada data latih untuk meningkatkan variasi sampel tanpa mengubah karakteristik utama citra medis. Transformasi yang digunakan meliputi rotasi ringan hingga 12 derajat, pergeseran horizontal dan vertikal sebesar 5%, zoom kecil sebesar 8%, serta penyesuaian tingkat

kecerahan dalam rentang terbatas. Teknik *horizontal flipping* tidak digunakan karena dapat mengubah orientasi anatomi konjungtiva palpebral dan berpotensi menghasilkan representasi biologis yang tidak realistis. Sementara itu, data validasi dan data uji tidak diberikan augmentasi agar evaluasi performa model dilakukan pada citra asli tanpa modifikasi.

Dataset kemudian dimuat menggunakan mekanisme *flow_from_directory*, di mana data latih diacak (*shuffle*) untuk membantu model mempelajari pola secara lebih general dan mengurangi ketergantungan terhadap urutan data. Sebaliknya, data validasi dan pengujian tidak diacak guna menjaga konsistensi evaluasi serta memastikan kesesuaian antara prediksi dan label sebenarnya.

```python
from sklearn.utils.class_weight import compute_class_weight
import numpy as np
# Ambil label langsung dari generator
labels = train_data.classes  # array 0 dan 1
# Hitung weights
class_weights_array = compute_class_weight(
    class_weight='balanced',
    classes=np.unique(labels),
    y=labels)

# Bentuk dict untuk model.fit()
class_weights = {
    i: weight for i, weight in enumerate(class_weights_array)}

# Cek mapping kelas
print("\n Mapping Kelas:")
for class_name, idx in train_data.class_indices.items():
    print(f"   {idx} = {class_name}")

print("\n Class Weights:")
print(f"   Anemic (0): {class_weights[0]:.3f}")
print(f"   Non-Anemic (1): {class_weights[1]:.3f}")
```

Gambar 4.3 Tahap Class Weight

Setelah selesai, pada gambar 4.3 dilakukan pengecekan pemetaan kelas yang menunjukkan bahwa label *anemic* direpresentasikan sebagai kelas 0 dan *non-anemic* sebagai kelas 1. Distribusi data yang digunakan terdiri dari 2.232 citra pada data latih, 684 citra validasi, dan 678 citra pengujian. Meskipun distribusi kelas relatif seimbang, tetap dilakukan perhitungan *class weight* menggunakan

metode *balanced weighting* untuk mengurangi potensi bias model terhadap kelas dengan jumlah sampel lebih besar. Hasil perhitungan menunjukkan bobot kelas anemia sebesar 0,947 dan non-anemia sebesar 1,060. Perbedaan bobot yang tidak terlalu besar menandakan dataset memiliki keseimbangan yang cukup baik, namun penerapan *class weight* tetap membantu model memberikan perhatian yang proporsional terhadap kedua kelas selama proses optimasi. Melalui tahap preprocessing, seluruh dataset telah disesuaikan dengan format input MobileNetV2. Proses normalisasi, augmentasi pada data latih, serta penyesuaian bobot kelas dilakukan untuk meningkatkan kemampuan generalisasi model dan menjaga stabilitas pelatihan pada tahap *Feature extraction* dan *fine-tuning.*

4.3 Pembangunan dan Pelatihan Model Transfer Learning Menggunakan MobileNetV2

Pada penelitian ini, model klasifikasi citra konjungtiva palpebral dikembangkan menggunakan pendekatan transfer learning dengan arsitektur MobileNetV2. Arsitektur ini dipilih karena memiliki jumlah parameter yang efisien, performa stabil, serta sesuai untuk implementasi pada perangkat mobile. Selain itu, bobot pretrained dari dataset ImageNet memungkinkan model memiliki kemampuan awal dalam mengenali pola visual dasar seperti tepi, tekstur, kontras, dan distribusi warna.

```
import tensorflow as tf
from tensorflow.keras import layers, Model, regularizers
from tensorflow.keras.applications import MobileNetV2
from tensorflow.keras.optimizers import Adam
from tensorflow.keras.callbacks import ModelCheckpoint, EarlyStopping, ReduceLROnPlateau

# 1. Base model
base_model = MobileNetV2(
    input_shape=(224, 224, 3),
    include_top=False,
    weights='imagenet')
# Phase 1: freeze
base_model.trainable = False
```

Gambar 4.4 Tahap Pembangunan Model

Model dimuat dengan pengaturan opsi include_top=False digunakan untuk menghapus layer klasifikasi bawaan, karena penelitian ini membangun ulang layer klasifikasi sesuai kebutuhan deteksi anemia (klasifikasi biner). Sementara itu, penggunaan bobot pretrained dari ImageNet membuat proses pelatihan menjadi lebih efisien dan tidak dimulai dari nol.

4.3.1 Arsitektur Model dan Strategi Regularisasi

Pada tahap awal, seluruh layer pada *base model* dibekukan (base_model.trainable = False) sehingga bobot convolutional tidak diperbarui selama pelatihan awal. Dalam kondisi ini, MobileNetV2 berfungsi sebagai *feature extractor* yang mengekstraksi representasi visual dari citra tanpa mengubah pengetahuan dasar yang telah dipelajari dari ImageNet. Setelah proses ekstraksi fitur, ditambahkan beberapa lapisan klasifikasi. Lapisan pertama GlobalAveragePooling2D digunakan untuk mereduksi feature map menjadi representasi vektor yang lebih ringkas sekaligus menekan jumlah parameter model. Pendekatan ini membantu mengurangi risiko overfitting pada dataset medis yang relatif terbatas.

```
inputs = tf.keras.Input(shape=(224, 224, 3))
x = base_model(inputs, training=False)
x = layers.GlobalAveragePooling2D()(x)
# Dense block 1
x = layers.Dense(
    128,
    activation='relu',
    kernel_regularizer=regularizers.l2(1e-4))(x)
x = layers.BatchNormalization()(x)
x = layers.Dropout(0.4)(x)

# Dense block 2
x = layers.Dense(
    64,
    activation='relu',
    kernel_regularizer=regularizers.l2(1e-4))(x)
x = layers.BatchNormalization()(x)
x = layers.Dropout(0.3)(x)
# Output
outputs = layers.Dense(1, activation='sigmoid')(x)
```

Gambar 4.5 Arsitektur Model

Selanjutnya ditambahkan Dense layer 128 neuron dengan aktivasi ReLU dan regularisasi L2 sebesar $1e^{-4}$. Regularisasi L2 berfungsi membatasi besarnya bobot agar tidak terlalu ekstrem, sehingga model tidak terlalu menyesuaikan diri terhadap data latih. Setelah itu diterapkan BatchNormalization untuk menstabilkan distribusi aktivasi dan mempercepat proses konvergensi. Layer Dropout sebesar 0.4 ditambahkan untuk mengurangi kemungkinan overfitting dengan cara menonaktifkan sebagian neuron secara acak selama pelatihan. Struktur ini dilanjutkan dengan Dense layer 64 neuron (ReLU) yang juga menggunakan L2 regularization, diikuti BatchNormalization dan Dropout sebesar 0.3. Layer terakhir adalah Dense dengan satu neuron dan aktivasi sigmoid karena penelitian ini merupakan klasifikasi biner (anemia dan non-anemia).

Tabel 4.1 Tabel Arsitektur Model

Komponn	Konfigurasi/Simulasi
Base Model	MobileNetV2 (ImageNet pretrained) (7, 7, 1280)
InputSize	RGB Image (224, 224, 3)
Base Model Status	Frozen (Phase 1)
Pooling Layer	GlobalAveragePooling2D (1280)
Dense Layer 1	128 neuron, ReLU, L2 (1e-4) (128)
Batch Normalization	Yes
Dropout	0.4
Dense Layer 2	64 neuron, ReLU, L2 (1e-4)
Batch Normalization	Yes
Dropout	0.3
Output Layer	1 neuron, Sigmoid
Optimizer	Adam (lr = 1e-3)
Loss Fuction	Binary Crossentropy
Evaluation Metrics	Accuracy, AUC

```
model = Model(inputs, outputs)
# 3. Compile model
INITIAL_LR = 1e-3  # Gunakan 1e-3 untuk fase feature extraction
model.compile(
    optimizer=Adam(learning_rate=INITIAL_LR),
    loss='binary_crossentropy',
    metrics=['accuracy', tf.keras.metrics.AUC(name='auc')]
)
print(f"   Learning rate: {INITIAL_LR}")
print("   Base model frozen (Phase 1)")
print(f"   Model compiled: {model.optimizer is not None}")
```

Gambar 4.6 Set Regulasi

Model kemudian dikompilasi menggunakan optimizer Adam dengan learning rate awal $1e^{-3}$. Fungsi loss yang digunakan adalah binary_crossentropy, sesuai untuk klasifikasi dua kelas. Selain metrik accuracy, digunakan pula metrik AUC (Area Under Curve). Dalam konteks klasifikasi medis, AUC lebih representatif karena mengukur kemampuan model dalam membedakan dua kelas secara menyeluruh, bukan hanya berdasarkan proporsi prediksi benar.

Pelatihan tahap pertama dilakukan selama 25 epoch dengan kondisi base model tetap dibekukan. Pada fase ini, hanya layer klasifikasi tambahan yang diperbarui bobotnya. Untuk menjaga kestabilan dan kualitas pelatihan, digunakan beberapa callback yang merupakan mekanisme dalam framework deep learning yang memungkinkan sistem melakukan tindakan tertentu secara otomatis selama proses training berlangsung., yaitu:

```
checkpoint_cb = ModelCheckpoint(
    MODELS_DIR / "mobilenetv2_phase1.h5",
    monitor="val_auc",
    mode="max",
    save_best_only=True,
    verbose=1)
```

Gambar 4.7 Set Checkpoint

1. ModelCheckpoint, untuk menyimpan model dengan nilai validation AUC terbaik sehingga model optimal tidak hilang.

```
earlystop_cb = EarlyStopping(
    monitor="val_auc",
    mode="max",
    patience=8,
    restore_best_weights=True,
    verbose=1)
```

Gambar 4.8 Set EarlyStopping

2. EarlyStopping dengan patience 8, untuk menghentikan pelatihan apabila tidak terjadi peningkatan performa dalam beberapa epoch berturut-turut.

```
lrreduce_cb = ReduceLROnPlateau(
    monitor="val_loss",
    factor=0.5,
    patience=4,
    min_lr=1e-7,
    verbose=1)
```

Gambar 4.9 Set ReduceLR

3. ReduceLROnPlateau, untuk menurunkan learning rate secara otomatis ketika validation loss tidak membaik.

```
Epoch 12/15
70/70 ━━━━━━━━━━━━━━━━━━━━ 0s 2s/step - accuracy: 0.8956 - auc: 0.9645 - loss: 0.2995
Epoch 12: val_auc improved from 0.96776 to 0.97114, saving model to /content/drive/MyDrive/detection-konjungtiva/models/mobilenet

Epoch 12: finished saving model to /content/drive/MyDrive/detection-konjungtiva/models/mobilenetv2_finetuned.keras
70/70 ━━━━━━━━━━━━━━━━━━━━ 214s 3s/step - accuracy: 0.8992 - auc: 0.9637 - loss: 0.2966 - val_accuracy: 0.9094 - val_auc: 0.9711
Epoch 13/15
70/70 ━━━━━━━━━━━━━━━━━━━━ 0s 2s/step - accuracy: 0.9045 - auc: 0.9642 - loss: 0.2951
Epoch 13: val_auc did not improve from 0.97114
70/70 ━━━━━━━━━━━━━━━━━━━━ 214s 3s/step - accuracy: 0.9064 - auc: 0.9688 - loss: 0.2822 - val_accuracy: 0.8933 - val_auc: 0.9701
Epoch 14/15
70/70 ━━━━━━━━━━━━━━━━━━━━ 0s 2s/step - accuracy: 0.9133 - auc: 0.9683 - loss: 0.2843
Epoch 14: val_auc did not improve from 0.97114
70/70 ━━━━━━━━━━━━━━━━━━━━ 200s 3s/step - accuracy: 0.9064 - auc: 0.9665 - loss: 0.2881 - val_accuracy: 0.8860 - val_auc: 0.9626
Epoch 15/15
70/70 ━━━━━━━━━━━━━━━━━━━━ 0s 2s/step - accuracy: 0.9137 - auc: 0.9724 - loss: 0.2699
Epoch 15: val_auc improved from 0.97114 to 0.97550, saving model to /content/drive/MyDrive/detection-konjungtiva/models/mobilenet

Epoch 15: finished saving model to /content/drive/MyDrive/detection-konjungtiva/models/mobilenetv2_finetuned.keras
70/70 ━━━━━━━━━━━━━━━━━━━━ 201s 3s/step - accuracy: 0.9144 - auc: 0.9740 - loss: 0.2645 - val_accuracy: 0.9094 - val_auc: 0.9755
Restoring model weights from the end of the best epoch: 15.
```

Gambar 4.10 Hasil Pelatihan Model Phase 1

Berdasarkan hasil pelatihan, performa model menunjukkan peningkatan yang konsisten sejak awal epoch. Nilai accuracy dan AUC meningkat secara bertahap seiring proses penyesuaian layer klasifikasi terhadap fitur yang diekstraksi oleh MobileNetV2. Model terbaik pada fase ini diperoleh pada epoch ke-21 dan tersimpan otomatis melalui mekanisme *ModelCheckpoint*. Pada epoch tersebut diperoleh training accuracy sebesar 80,51%, validation accuracy 79,82%, validation AUC 0,9003, serta validation loss 0,4345. Selisih performa antara data

training dan validasi relatif kecil, menandakan proses pembelajaran berlangsung stabil tanpa indikasi overfitting yang signifikan. Peningkatan AUC yang konsisten menunjukkan bahwa fitur hasil ekstraksi MobileNetV2 telah mampu membedakan karakteristik warna konjungtiva pada kondisi anemia dan non-anemia, meskipun layer convolutional belum dilakukan pelatihan ulang. Setelah mencapai epoch terbaik, mekanisme *EarlyStopping* mengembalikan bobot model ke kondisi optimal tersebut (*restoring best weights from epoch 21*), sehingga model yang digunakan pada tahap selanjutnya merepresentasikan performa terbaik fase pertama.

```
print("\n Training Phase 2: Fine-Tuning...")
# 1 Unfreeze HANYA 80 layer terakhir
base_model.trainable = True
for layer in base_model.layers[:-80]:
    layer.trainable = False
for layer in base_model.layers[-80:]:
    # BatchNorm JANGAN di-train
    if not isinstance(layer, tf.keras.layers.BatchNormalization):
        layer.trainable = True
    else:
        layer.trainable = False

# 4 Epoch lanjutan (15 epoch tambahan)
history_phase2 = model.fit(
    train_data,
    validation_data=val_data,
    epochs=15,
    class_weight=class_weights,
    callbacks=[checkpoint_cb2, earlystop_cb, lrreduce_cb],
    verbose=1)
```

Gambar 4.11 Phase 2 Fine-tunning

Setelah fase feature extraction selesai, dilakukan *fine-tuning* untuk meningkatkan performa model. Pada tahap ini, sekitar 80 layer terakhir dari MobileNetV2 dibuka kembali (unfreeze), sementara layer BatchNormalization tetap dibekukan untuk menjaga kestabilan distribusi statistik internal jaringan. Learning rate diturunkan menjadi $1e^{-5}$. Penurunan ini sangat penting karena pada tahap fine-tuning, bobot pretrained sudah cukup baik sehingga pembaruan parameter harus dilakukan secara lebih halus agar tidak merusak fitur yang telah

dipelajari sebelumnya. Fine-tuning dilakukan selama 15 epoch tambahan dengan konfigurasi callback yang sama.

```
Epoch 21/25
70/70 ━━━━━━━━━━━━━━━━━━━━ 0s 2s/step - accuracy: 0.8013 - auc: 0.8905 - loss: 0.4493
Epoch 21: val_auc improved from 0.89569 to 0.90035, saving model to /content/drive/MyDrive/detection-konjungtiva/models/mobilenet
WARNING:absl:You are saving your model as an HDF5 file via `model.save()` or `keras.saving.save_model(model)`. This file format i

Epoch 21: finished saving model to /content/drive/MyDrive/detection-konjungtiva/models/mobilenetv2_phase1.h5
70/70 ━━━━━━━━━━━━━━━━━━━━ 195s 2s/step - accuracy: 0.8051 - auc: 0.8867 - loss: 0.4596 - val_accuracy: 0.7982 - val_auc: 0.9003
Epoch 22/25
70/70 ━━━━━━━━━━━━━━━━━━━━ 0s 2s/step - accuracy: 0.7895 - auc: 0.8817 - loss: 0.4625
Epoch 22: val_auc did not improve from 0.90035
70/70 ━━━━━━━━━━━━━━━━━━━━ 155s 2s/step - accuracy: 0.8020 - auc: 0.8862 - loss: 0.4571 - val_accuracy: 0.7997 - val_auc: 0.8929
Epoch 23/25
70/70 ━━━━━━━━━━━━━━━━━━━━ 0s 2s/step - accuracy: 0.7943 - auc: 0.8870 - loss: 0.4568
Epoch 23: val_auc did not improve from 0.90035
70/70 ━━━━━━━━━━━━━━━━━━━━ 175s 2s/step - accuracy: 0.8047 - auc: 0.8857 - loss: 0.4594 - val_accuracy: 0.7617 - val_auc: 0.8813
Epoch 24/25
70/70 ━━━━━━━━━━━━━━━━━━━━ 0s 2s/step - accuracy: 0.8037 - auc: 0.8874 - loss: 0.4524
Epoch 24: val_auc did not improve from 0.90035
70/70 ━━━━━━━━━━━━━━━━━━━━ 179s 2s/step - accuracy: 0.8163 - auc: 0.8939 - loss: 0.4442 - val_accuracy: 0.8070 - val_auc: 0.8979
Epoch 25/25
70/70 ━━━━━━━━━━━━━━━━━━━━ 0s 2s/step - accuracy: 0.8086 - auc: 0.8919 - loss: 0.4486
Epoch 25: val_auc did not improve from 0.90035
70/70 ━━━━━━━━━━━━━━━━━━━━ 156s 2s/step - accuracy: 0.8127 - auc: 0.8929 - loss: 0.4473 - val_accuracy: 0.8056 - val_auc: 0.8989
Restoring model weights from the end of the best epoch: 21.
```

Gambar 4.12 Hasil Pelatihan Model Phase 2

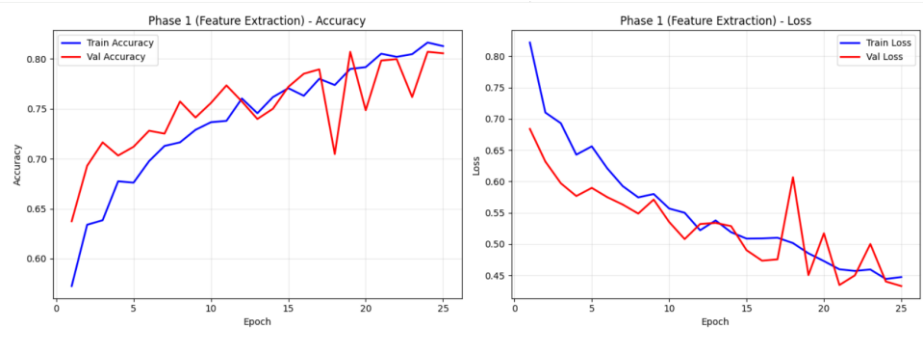
Selama proses ini, peningkatan performa terlihat lebih jelas dibandingkan fase pertama. Pada awal pelatihan, model masih menyesuaikan diri terhadap layer yang baru dibuka, namun memasuki epoch ke-5 performa mulai meningkat signifikan dengan validation AUC mencapai 0,9418 dan validation accuracy sebesar 86,40%. Hal ini menunjukkan bahwa penyesuaian ulang parameter membantu model mengenali fitur tingkat tinggi yang lebih relevan dengan karakteristik warna konjungtiva terkait anemia.

Performa model terus membaik secara konsisten hingga mencapai hasil optimal pada epoch ke-15 yang otomatis tersimpan berdasarkan nilai validation AUC tertinggi. Pada tahap ini diperoleh training accuracy sebesar 91,44% dengan peningkatan training AUC yang stabil. Selisih performa antara data pelatihan dan validasi tetap kecil, sehingga tidak menunjukkan indikasi overfitting dan menandakan kemampuan generalisasi model masih terjaga dengan baik terhadap data baru. Hasil tersebut menunjukkan bahwa pembukaan sebagian layer convolutional pada MobileNetV2 memungkinkan model melakukan penyesuaian

representasi fitur secara lebih mendalam dibandingkan fase sebelumnya, sehingga kemampuan klasifikasi citra konjungtiva meningkat secara lebih optimal.

4.4 Validasi Model dan Pengecekan Overfitting

Pada penelitian ini, evaluasi dilakukan untuk memastikan bahwa model tidak hanya menunjukkan performa tinggi pada data pelatihan, tetapi juga memiliki kemampuan generalisasi yang baik terhadap data baru. Proses validasi dilakukan melalui visualisasi metrik pelatihan guna mengamati dinamika pembelajaran model selama proses training berlangsung. Melalui tahap ini, potensi terjadinya overfitting maupun underfitting dapat diidentifikasi lebih awal sebelum model digunakan pada tahap evaluasi akhir. Validasi dilakukan menggunakan fungsi plot_training_history() berbasis library Matplotlib pada Python. Fungsi ini memvisualisasikan grafik *accuracy* dan *loss* pada data pelatihan serta data validasi berdasarkan objek *history* dari dua tahap pelatihan, yaitu *feature extraction* (Phase 1) dan *fine-tuning* (Phase 2). Selain visualisasi grafik, sistem juga secara otomatis menghitung selisih performa (*gap*) antara data pelatihan dan validasi sebagai indikator tingkat overfitting model.



Gambar 4.13 Grafik Accuracy dan Loss Model Phase 1

Berdasarkan grafik akurasi dan loss pada tahap feature extraction, terlihat bahwa model mengalami proses pembelajaran yang stabil sejak epoch awal hingga akhir pelatihan. Kurva training accuracy meningkat secara bertahap dari

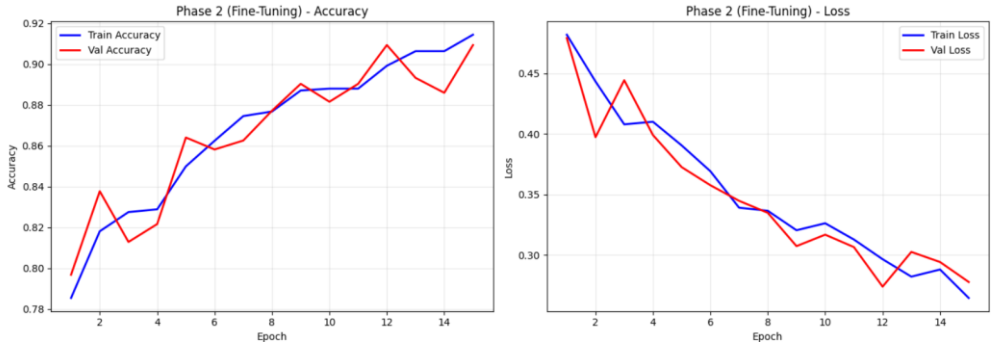
sekitar 0,57 pada epoch awal hingga mencapai sekitar 0,82–0,83 pada epoch terakhir. *Validation accuracy* juga menunjukkan pola peningkatan yang searah, dimulai dari kisaran 0,63 dan berakhir pada nilai sekitar 0,81–0,82. Kedekatan antara kurva akurasi pelatihan dan validasi menunjukkan bahwa model mampu mempelajari pola citra tanpa menghafal data latih secara berlebihan. Berdasarkan hasil analisis otomatis, diperoleh gap accuracy sebesar 0,0072, yang menunjukkan perbedaan performa yang sangat kecil antara data pelatihan dan validasi.

Pada grafik loss, nilai *training loss* mengalami penurunan konsisten dari sekitar 0,82 pada awal pelatihan hingga mendekati 0,44 pada epoch terakhir. *Validation loss* juga menurun secara stabil dari kisaran 0,68 menjadi sekitar 0,43–0,45. Pola penurunan kedua kurva berlangsung paralel tanpa divergensi yang signifikan. Hasil perhitungan menunjukkan *gap loss* sebesar −0,0144, yang menandakan bahwa performa validasi bahkan sedikit lebih baik dibandingkan data pelatihan pada akhir proses *training.*

Secara keseluruhan pada Phase 1 (Feature Extraction), kurva akurasi memperlihatkan peningkatan bertahap dengan training accuracy mencapai sekitar 0,83 dan *validation accuracy* sekitar 0,82 pada akhir pelatihan. Grafik loss juga menunjukkan penurunan yang stabil, baik pada data pelatihan maupun validasi. Nilai *gap accuracy* sebesar 0,0072 dan gap loss sebesar −0,0144 menunjukkan bahwa tingkat overfitting berada dalam kategori terkontrol.

Berdasarkan indikator tersebut, kondisi model pada fase *feature extraction* dapat dikategorikan memiliki overfitting yang terkendali pada metrik *accuracy* maupun loss. Stabilitas pola kurva menunjukkan bahwa model berhasil memanfaatkan fitur umum dari arsitektur pretrained untuk mengenali karakteristik

warna konjungtiva secara efektif, sekaligus mempertahankan kemampuan generalisasi yang baik terhadap data validasi.



Gambar 4.14 Grafik Accuracy dan Loss Model Phase 2

Pada tahap fine-tuning, grafik menunjukkan peningkatan performa model yang lebih optimal dibandingkan fase sebelumnya. Kurva akurasi pelatihan dan validasi bergerak searah dengan pola peningkatan yang stabil sepanjang epoch pelatihan. Nilai training accuracy meningkat secara bertahap hingga mencapai sekitar 0,91–0,92, sedangkan validation accuracy berada pada kisaran 0,90–0,91 pada akhir epoch. Kedekatan kedua kurva tersebut menunjukkan bahwa model mampu mempertahankan performa yang konsisten antara data pelatihan dan data validasi.

Pada grafik loss, training loss menurun secara bertahap dari sekitar 0,47 pada awal fine-tuning hingga mendekati 0,28 pada epoch terakhir. Validation loss juga mengalami penurunan serupa, dari sekitar 0,48 menjadi 0,29. Pola penurunan yang paralel tanpa fluktuasi signifikan menunjukkan proses pembelajaran berlangsung stabil tanpa indikasi divergensi. Hasil perhitungan otomatis menghasilkan gap accuracy sebesar 0,0051 dan gap loss sebesar 0,0132. Kedua nilai tersebut berada di bawah ambang batas overfitting, sehingga kondisi model dikategorikan sebagai overfitting terkontrol pada metrik accuracy maupun loss.

Pada Phase 2 (Fine-Tuning), performa model meningkat lebih lanjut dengan training accuracy mendekati 0,92 dan validation accuracy sekitar 0,91, disertai penurunan loss yang konsisten hingga kisaran 0,28–0,29. Nilai gap accuracy 0,0051 dan gap loss 0,0132 kembali menunjukkan bahwa perbedaan performa antara data pelatihan dan validasi sangat kecil.

Secara keseluruhan pada Phase 2 (Fine-Tuning), peningkatan performa terlihat dari training accuracy yang mendekati 0,92 dan validation accuracy sekitar 0,91, disertai penurunan loss yang konsisten pada kisaran 0,28–0,29. Selisih performa yang sangat kecil menunjukkan bahwa pembukaan sebagian layer convolutional berhasil meningkatkan representasi fitur tingkat tinggi tanpa membuat model terlalu spesifik terhadap data pelatihan, sehingga kemampuan generalisasi tetap terjaga dengan baik.

4.4.1 Interpretasi terhadap Penelitian

Hasil visualisasi pada kedua fase menunjukkan bahwa strategi pelatihan bertahap (*feature extraction* dilanjutkan *fine-tuning*) efektif dalam meningkatkan performa model deteksi anemia berbasis citra konjungtiva palpebral. Selisih performa antara data pelatihan dan validasi pada kedua fase berada jauh di bawah 10%, bahkan kurang dari 1%, yang menunjukkan bahwa model tidak mengalami overfitting dan mampu melakukan generalisasi dengan baik terhadap data yang belum pernah dilihat sebelumnya. Pola peningkatan akurasi yang konsisten disertai penurunan loss yang stabil juga mengindikasikan tidak adanya underfitting, karena model berhasil mempelajari pola data secara bertahap selama proses pelatihan.

Selain itu, tidak ditemukan indikasi data leakage, yang ditunjukkan oleh peningkatan performa yang berlangsung secara wajar tanpa lonjakan nilai yang tidak realistis. Konsistensi kurva pelatihan dan validasi menandakan bahwa model belajar dari karakteristik citra secara aktual tanpa dipengaruhi bias distribusi data. Secara keseluruhan, model menunjukkan keseimbangan yang baik antara kemampuan pembelajaran dan generalisasi, sehingga dinilai stabil dan layak digunakan pada tahap evaluasi lanjutan serta implementasi sistem deteksi anemia berbasis citra konjungtiva palpebral. Dengan demikian, model dinilai cukup stabil dan layak digunakan pada tahap evaluasi dan implementasi sistem.

4.5 Evaluasi Model

Tahap selanjutnya dilakukan evaluasi performa model menggunakan data uji (*test set*) yang tidak terlibat pada proses pelatihan maupun validasi. Pengujian ini bertujuan untuk melihat kemampuan model dalam melakukan generalisasi terhadap data baru pada klasifikasi citra konjungtiva palpebral ke dalam kategori *Anemic* dan Non-Anemic. Sebelum evaluasi akhir dilakukan, terlebih dahulu dicari nilai *threshold* optimal menggunakan data validasi. Penentuan nilai ini dilakukan dengan menguji beberapa kandidat threshold pada rentang 0,30 hingga 0,69 dan memilih nilai dengan F1-Score tertinggi. Berdasarkan proses tersebut diperoleh threshold optimal sebesar 0,640 dengan F1-Score 0,9247. Nilai ini kemudian digunakan sebagai batas keputusan klasifikasi pada tahap pengujian.

```
Classification Report (Threshold Optimal = 0.64)
              precision    recall  f1-score   support

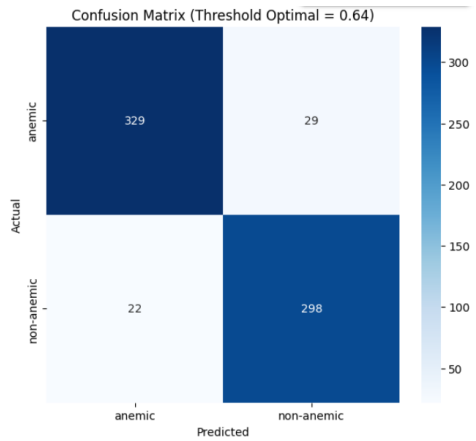
      Anemic     0.9373    0.9190    0.9281       358
  Non-Anemic     0.9113    0.9313    0.9212       320

    accuracy                         0.9248       678
   macro avg     0.9243    0.9251    0.9246       678
weighted avg     0.9250    0.9248    0.9248       678


 Hasil Evaluasi (test set):
Test Accuracy: 90.71%
Test AUC: 0.9768
Test Loss: 0.2802
```

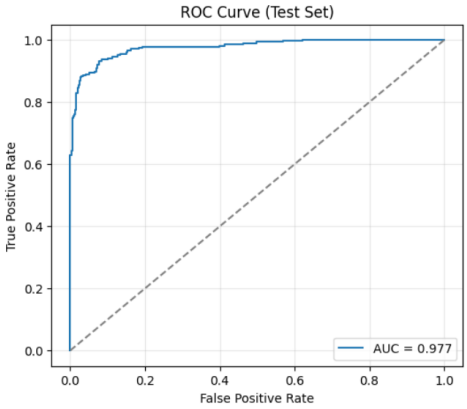
Gambar 4.15 Hasil Evaluasi Model

Berdasarkan hasil evaluasi pada data uji, model memperoleh akurasi sebesar 90,71%, nilai AUC sebesar 0,9768, serta loss sebesar 0,2802. Hasil ini menunjukkan bahwa model mampu mempertahankan performa yang tinggi ketika dihadapkan pada data yang belum pernah dilihat sebelumnya. Hasil *classification report* menggunakan *threshold* optimal menunjukkan performa yang seimbang pada kedua kelas. Pada kelas *Anemic*, model memperoleh *precision* sebesar 0,9373, *recall* 0,9190, dan F1-score 0,9281 dari total 358 data. Sementara itu, pada kelas *Non-Anemic*, diperoleh *precision* 0,9113, *recall* 0,9313, dan F1-score 0,9212 dari 320 data uji. Nilai macro average F1-score sebesar 0,9246 mengindikasikan bahwa kemampuan klasifikasi model relatif merata dan tidak condong pada salah satu kelas tertentu.



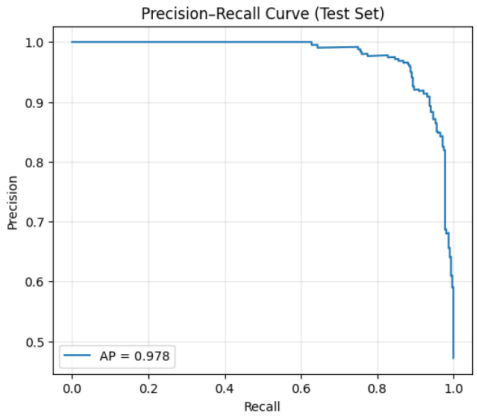
Gambar 4.16 Hasil Confusion Matrix Pengujian

Visualisasi *confusion matrix* pada Gambar menunjukkan distribusi prediksi model setelah menggunakan *threshold* optimal 0,64. Sebanyak 329 data *Anemic* berhasil diklasifikasikan dengan benar, sementara 29 data masih salah dikenali sebagai *Non-Anemic*. Pada kelas *Non-Anemic*, model mampu mengklasifikasikan 298 data secara tepat, dengan 22 data keliru diprediksi sebagai Anemic. Pola kesalahan yang relatif seimbang ini menunjukkan bahwa model memiliki sensitivitas dan spesifisitas yang baik dalam mengenali kedua kategori citra.



Gambar 4.17 Hasil Kurva ROC

Kurva ROC pada data uji memperlihatkan nilai AUC sebesar 0,977, sebagaimana terlihat pada grafik ROC Curve. Kurva berada jauh di atas garis diagonal acak, yang menandakan bahwa model memiliki kemampuan diskriminatif yang sangat baik dalam membedakan citra penderita anemia dan non-anemia. Nilai AUC yang mendekati 1 menunjukkan bahwa model mampu mempertahankan *true positive rate* yang tinggi dengan tingkat kesalahan prediksi positif yang rendah pada berbagai nilai threshold.



Gambar 4.18 Hasil Kurva Precision–Recall

Selain itu, kurva *Precision–Recall* menghasilkan nilai *Average Precision* (AP) sebesar 0,978. Kurva ini memperlihatkan bahwa precision tetap berada pada tingkat tinggi meskipun *recall* meningkat. Kondisi tersebut penting dalam konteks deteksi medis karena menunjukkan bahwa model mampu mendeteksi sebagian besar kasus anemia tanpa menghasilkan terlalu banyak prediksi positif yang salah. Secara keseluruhan, hasil evaluasi pada data uji menunjukkan bahwa model memiliki performa yang stabil dan konsisten. Nilai akurasi yang tinggi, keseimbangan *precision* dan *recall* pada kedua kelas, serta skor AUC dan AP yang sangat baik menandakan bahwa model mampu melakukan generalisasi dengan baik terhadap data baru. Dengan demikian, model klasifikasi citra konjungtiva palpebral yang dikembangkan dapat dinilai cukup andal dan layak untuk digunakan pada tahap implementasi sistem deteksi anemia berbasis aplikasi.

4.6 Integrasi Model atau Deploy

Setelah tahap pelatihan, *fine-tuning*, dan evaluasi model selesai dilakukan di Google Colab, langkah selanjutnya adalah mengimplementasikan model ke dalam aplikasi mobile agar dapat digunakan secara praktis oleh pengguna. Pada penelitian ini, model klasifikasi citra konjungtiva palpebral untuk deteksi anemia

tidak hanya berhenti pada tahap eksperimen, tetapi diintegrasikan ke dalam aplikasi berbasis React Native menggunakan Expo yang didukung oleh backend berbasis Flask.

```
# Simpan model Keras
model_path = MODELS_DIR / "mobilenetv2_anemia_final.keras"
model.save(model_path)
print(f"Model tersimpan di: {model_path}")

# Konversi ke TFLite
converter = tf.lite.TFLiteConverter.from_keras_model(model)
converter.optimizations = [tf.lite.Optimize.DEFAULT]
tflite_model = converter.convert()
tflite_path = MODELS_DIR / "mobilenetv2_anemia.tflite"
with open(tflite_path, "wb") as f:
    f.write(tflite_model)
print(f"TFLite tersimpan: {tflite_path}")
```

Gambar 4.19 Tahap Penyimpanan Model Hasil Pelatihan

Model hasil pelatihan terlebih dahulu disimpan dalam dua format, yaitu format asli Keras (.keras) dan format TensorFlow Lite (.tflite). Penyimpanan dalam format Keras bertujuan untuk mempertahankan model lengkap beserta parameter pelatihannya, sedangkan konversi ke TensorFlow Lite dilakukan untuk menghasilkan model yang lebih ringan dan telah dioptimasi sehingga memungkinkan implementasi pada perangkat dengan sumber daya terbatas. Format .tflite juga membuka kemungkinan proses inferensi dilakukan secara lokal pada perangkat (*on-device*), meskipun pada implementasi penelitian ini pendekatan utama yang digunakan adalah *backend* API.

Pada tahap *deployment*, model tidak langsung dijalankan di aplikasi mobile, melainkan terlebih dahulu dikemas sebagai layanan backend melalui mekanisme *Application Programming Interface* (API). Pendekatan ini dipilih untuk memisahkan proses komputasi model dari aplikasi pengguna sehingga

aplikasi tetap ringan serta memudahkan proses pemeliharaan dan pembaruan model tanpa perlu melakukan pembaruan aplikasi di sisi pengguna.

Backend dikembangkan menggunakan *framework Flask* berbasis Python yang berfungsi sebagai server inferensi. Beberapa dependensi pendukung diinstal, meliputi TensorFlow untuk menjalankan model deep learning, Pillow untuk pengolahan citra, serta pyngrok yang digunakan untuk menyediakan akses publik terhadap server lokal yang berjalan pada Google Colab. Model yang telah disimpan kemudian dimuat kembali menggunakan fungsi load_model, bersamaan dengan pemanggilan nilai threshold optimal yang diperoleh pada tahap evaluasi sebelumnya.

```
@app.route('/health', methods=['GET'])
def health():
    return jsonify({'status': 'ok'})
@app.route('/predict', methods=['POST'])
def predict():
    if 'image' not in request.files:
        return jsonify({'error': 'No image'}), 400
    file = request.files['image']
    img = Image.open(io.BytesIO(file.read())).convert('RGB')
    img = img.resize((224, 224))

    img_array = image.img_to_array(img)
    img_array = preprocess_input(img_array)  # sama persis dengan training!
    img_array = np.expand_dims(img_array, axis=0)

    score = float(model.predict(img_array, verbose=0)[0][0])
    is_anemic = score < threshold

    return jsonify({
        'label': 'Anemia' if is_anemic else 'Normal',
        'confidence': round((1 - score) * 100 if is_anemic else score * 100, 1),
        'score': score})
```

Gambar 4.20 Tahap Backend dikembangkan dengan framework Flask

Server *backend* menyediakan dua *endpoint* utama. *Endpoint /health* digunakan untuk memastikan layanan berjalan dengan baik dan berfungsi sebagai indikator koneksi antara aplikasi dan server. Sementara itu, *endpoint /predict* berperan sebagai layanan utama untuk melakukan prediksi. *Endpoint* ini menerima citra yang dikirim dari aplikasi mobile melalui metode POST,

kemudian melakukan serangkaian praproses yang identik dengan tahap pelatihan model, meliputi konversi warna ke format RGB, penyesuaian ukuran citra menjadi 224×224 piksel, serta normalisasi menggunakan fungsi preprocess_input dari arsitektur MobileNetV2. Setelah proses praproses selesai, citra dimasukkan ke dalam model untuk menghasilkan nilai probabilitas prediksi. Nilai probabilitas tersebut dibandingkan dengan *threshold* optimal untuk menentukan kategori hasil, yaitu Anemia atau Normal. Hasil inferensi kemudian dikirim kembali ke aplikasi dalam format JSON yang berisi label klasifikasi, skor probabilitas, serta tingkat kepercayaan (confidence score).

Untuk memastikan mekanisme prediksi berjalan konsisten, dikembangkan pula fungsi prediksi deployment yang mereplikasi seluruh tahapan inferensi, mulai dari pemuatan citra, *preprocessing* sesuai standar MobileNetV2, hingga proses klasifikasi berbasis *threshold.* Pengujian fungsi ini menggunakan sampel data uji menunjukkan bahwa citra anemia menghasilkan probabilitas sangat rendah dengan tingkat keyakinan sekitar 99%, sedangkan citra *non-anemia* menghasilkan probabilitas tinggi dengan *confidence* di atas 86%. Hasil tersebut menunjukkan bahwa mekanisme inferensi pada tahap *deployment* telah berjalan sesuai dengan performa model pada tahap evaluasi.

Karena server dijalankan pada Google Colab yang bersifat lokal, layanan ngrok digunakan untuk membuat tunnel jaringan sehingga *backend* dapat diakses melalui URL publik. Alamat URL ini kemudian digunakan oleh aplikasi Expo sebagai endpoint API untuk mengirim citra dan menerima hasil prediksi secara *real-time.* Melalui mekanisme *backend* ini, model deep learning dapat diakses oleh aplikasi mobile tanpa menjalankan komputasi berat secara langsung pada

perangkat pengguna. Pendekatan tersebut meningkatkan efisiensi sistem sekaligus menjaga konsistensi proses inferensi dengan tahap pelatihan model, sehingga integrasi antara model dan aplikasi dapat berjalan secara stabil dan praktis.

4.7 Prediksi Anemia dari Hasil Model Citra Konjungtiva Palpebral Menggunakan Expo

Selanjutnya, setelah proses *deployment* dan integrasi model pada *backend* selesai dilakukan, layanan API yang telah dibangun dihubungkan ke antarmuka pengguna (*User Interface*/UI) pada aplikasi mobile berbasis React Native menggunakan framework Expo. Tahap ini bertujuan untuk memungkinkan pengguna berinteraksi langsung dengan sistem deteksi anemia melalui perangkat *smartphone* secara praktis dan intuitif. Aplikasi mobile dirancang dengan tampilan sederhana agar dapat digunakan oleh pengguna non-teknis. Implementasi aplikasi memanfaatkan komponen expo-camera untuk mengakses kamera perangkat sehingga pengguna dapat mengambil citra konjungtiva palpebral secara langsung. Selain pengambilan gambar melalui kamera, aplikasi juga menyediakan opsi pemilihan gambar dari galeri perangkat menggunakan modul expo-image-picker. Fitur tambahan seperti *flip camera* disediakan untuk membantu pengguna memperoleh posisi pengambilan citra yang sesuai.

Ketika aplikasi dijalankan, sistem terlebih dahulu melakukan proses inisialisasi koneksi ke *backend* dengan memanggil endpoint kesehatan server *(/health*). Tahap ini bertujuan memastikan layanan model siap digunakan sebelum proses prediksi dilakukan. Setelah koneksi berhasil, aplikasi berada pada kondisi siap melakukan deteksi. Alur kerja prediksi dimulai ketika pengguna membuka halaman deteksi dan mengambil gambar konjungtiva palpebral. Citra yang

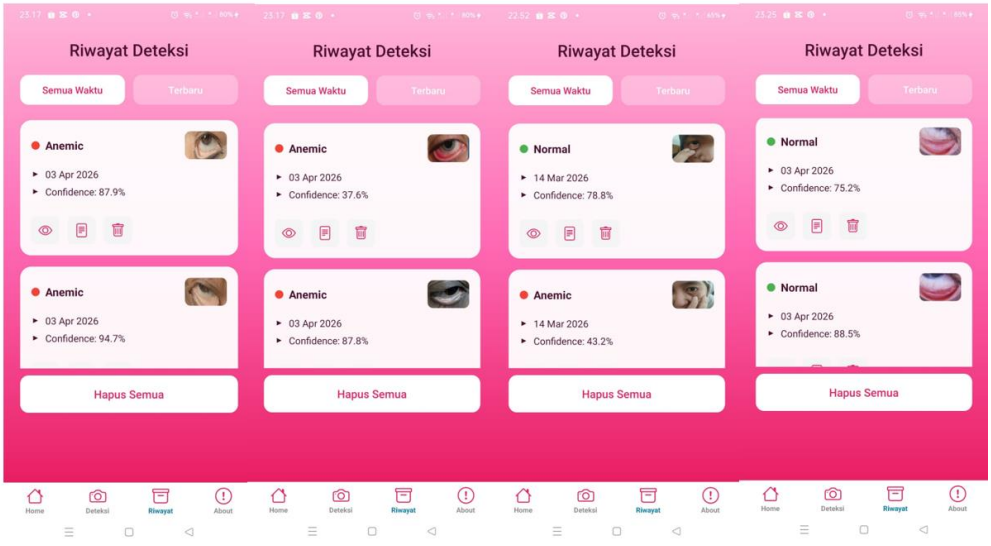
diperoleh kemudian menjalani tahap praproses awal di sisi aplikasi berupa penyesuaian ukuran gambar menjadi 224×224 piksel menggunakan modul expo-image-manipulator. Proses ini dilakukan untuk memastikan kesesuaian format input dengan spesifikasi model MobileNetV2 yang digunakan pada tahap pelatihan.

Selanjutnya, citra dikirimkan ke backend melalui permintaan HTTP POST dalam bentuk *multipart form data*. Aplikasi memanfaatkan fungsi khusus pada modul model (tfModel.ts) untuk mengelola proses komunikasi API, mulai dari pengiriman citra hingga penerimaan hasil prediksi. Backend kemudian mengembalikan respons berupa label klasifikasi dan nilai confidence yang merepresentasikan tingkat keyakinan model terhadap hasil prediksi. Hasil yang diterima dari server ditampilkan secara langsung pada antarmuka aplikasi dalam bentuk informasi kondisi pengguna, yaitu *Anemic* atau *Non-Anemic*, disertai nilai confidence dalam persentase. Untuk meningkatkan kemudahan interpretasi, aplikasi menggunakan indikator visual berupa perbedaan warna tampilan antara kedua kategori hasil. Selama proses inferensi berlangsung, sistem menampilkan indikator *loading* sehingga pengguna memperoleh umpan balik visual bahwa proses analisis sedang berjalan.

Selain menampilkan hasil secara real-time, aplikasi juga dilengkapi dengan mekanisme penyimpanan riwayat pemeriksaan menggunakan database lokal SQLite melalui modul expo-sqlite. Basis data lokal dibuat secara otomatis saat aplikasi pertama kali dijalankan dengan tabel *history* yang menyimpan informasi hasil deteksi, meliputi status klasifikasi, nilai confidence, tanggal pemeriksaan, rekomendasi, serta lokasi penyimpanan citra. Setiap hasil prediksi

yang diperoleh akan disimpan ke dalam database lokal sehingga pengguna dapat melihat kembali riwayat pemeriksaan sebelumnya tanpa memerlukan koneksi internet. Sistem juga menyediakan fungsi pengambilan data riwayat terbaru, penghapusan data tertentu, serta pembersihan seluruh riwayat apabila diperlukan. Pendekatan penyimpanan lokal ini meningkatkan aspek kemandirian aplikasi karena data tetap dapat diakses secara personal di perangkat pengguna.

Melalui implementasi ini, proses prediksi anemia berbasis citra konjungtiva palpebral dapat berjalan secara end-to-end pada aplikasi mobile, mulai dari pengambilan citra, pengiriman data ke model, hingga penyajian hasil kepada pengguna. Integrasi antara aplikasi Expo, layanan backend berbasis Flask, dan model deep learning memungkinkan sistem berfungsi sebagai alat bantu skrining awal anemia yang praktis, cepat, dan mudah diakses melalui perangkat smartphone.



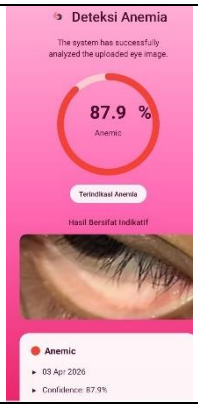
Gambar 4.21 Hasil Pengujian Implementasi Aplikasi

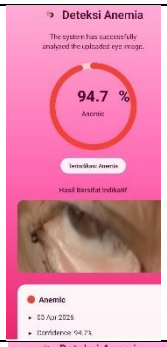
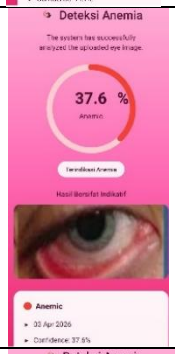
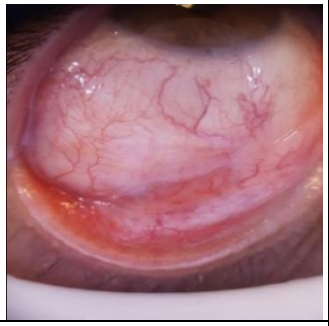
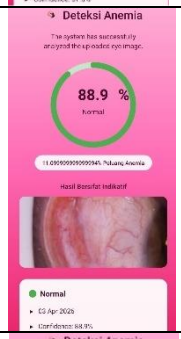
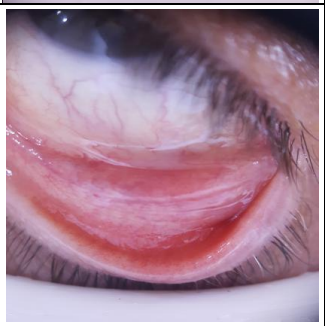
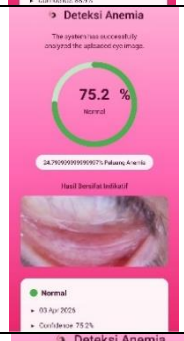
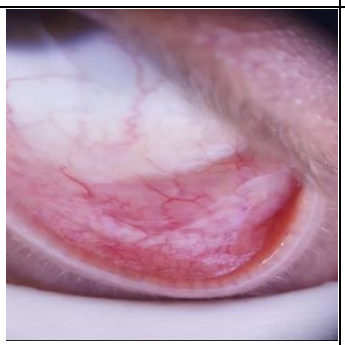
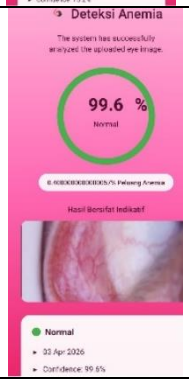
Berdasarkan hasil pengujian implementasi, aplikasi deteksi anemia berbasis citra palpebral conjunctiva berhasil dijalankan dengan baik pada perangkat mobile dan

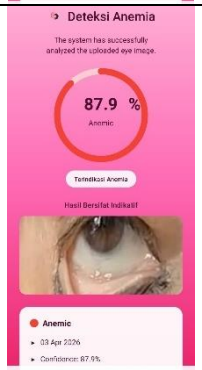
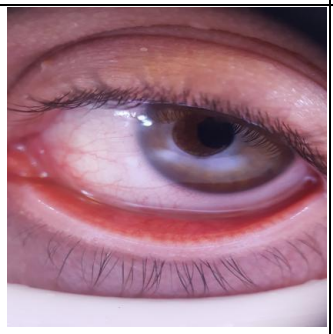
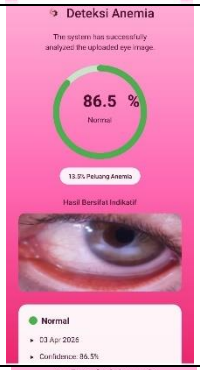
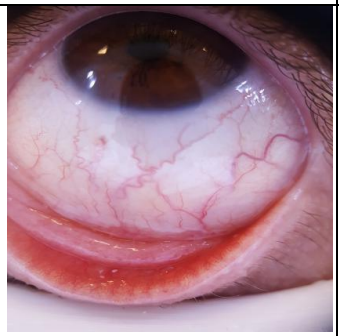
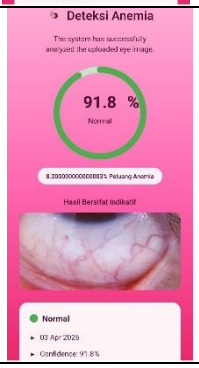
mampu melakukan proses klasifikasi secara fungsional. Pengujian dilakukan dengan melakukan percobaan deteksi sebanyak 30 kali menggunakan citra baru yang tidak pernah digunakan pada proses pelatihan model. Data pengujian diperoleh dari sumber terpercaya, dokumentasi edukasi medis, serta pengujian langsung pada individu yang sebelumnya telah melakukan pemeriksaan kadar hemoglobin oleh tenaga medis. Pada proses pengujian, pengguna mengambil gambar area konjungtiva palpebral melalui aplikasi, kemudian citra dikirim ke sistem untuk dilakukan proses prediksi oleh model klasifikasi. Hasil pengujian menunjukkan bahwa sistem mampu memberikan hasil deteksi yang sesuai dengan kondisi sebenarnya, baik pada citra dengan kategori anemia maupun normal

Selain pengujian menggunakan citra individu nyata, sistem juga diuji menggunakan contoh citra dari video edukasi dokter yang menampilkan kondisi konjungtiva dengan diagnosis medis yang telah diketahui. Hasil prediksi aplikasi menunjukkan kesesuaian antara hasil deteksi sistem dengan diagnosis pada sumber referensi tersebut, sehingga memperkuat validitas implementasi model dalam mengenali karakteristik visual konjungtiva palpebral.

Tabel 4.2 Validasi Implementasi Model Pada Citra

No	Gambar Asli (Normal/Anemia)	Hasil Deteksi
1	Anemia 	

2	Anemia		
3	Anemia		
4	Normal		
5	Normal		
6	Normal		

7	Anemia		
8	Anemia		
9	Normal		
10	Normal		

Selama proses pengujian, sistem tidak menunjukkan kegagalan komunikasi antara aplikasi dan server, yang ditandai dengan respons server yang konsisten pada setiap permintaan deteksi. Sebagaimana ditunjukkan pada gambar dan tabel hasil pengujian, dari total 30 kali percobaan deteksi dipilih enam sampel

representatif yang menampilkan perbandingan antara citra asli (Normal atau Anemia) dengan hasil prediksi aplikasi. Seluruh sampel menunjukkan bahwa label klasifikasi yang dihasilkan sistem sesuai dengan kondisi citra sebenarnya. Hal ini menunjukkan bahwa model yang telah diintegrasikan ke dalam aplikasi mampu mendeteksi kondisi anemia maupun normal secara konsisten. Hasil pengujian juga memperlihatkan bahwa kualitas pencahayaan dan posisi pengambilan gambar berpengaruh terhadap tingkat kepercayaan prediksi. Pengambilan citra dengan pencahayaan yang cukup dan fokus yang baik menghasilkan nilai kepercayaan yang lebih stabil dan akurat. Dengan demikian, prosedur pengambilan gambar yang sesuai menjadi faktor penting dalam memperoleh hasil deteksi yang optimal.

Secara keseluruhan, implementasi model deep learning ke dalam aplikasi mobile dapat berjalan dengan baik dan mampu melakukan deteksi anemia secara real-time, sehingga aplikasi berpotensi digunakan sebagai alat bantu deteksi dini anemia yang bersifat non-invasif dan praktis.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil perancangan, implementasi, serta pengujian sistem deteksi anemia berbasis citra konjungtiva palpebral menggunakan pendekatan deep learning, diperoleh beberapa kesimpulan sebagai berikut:

1. Penelitian ini mengembangkan model deteksi anemia berbasis citra konjungtiva palpebral dengan pendekatan transfer learning dengan arsitektur MobileNetV2. Model deep learning yang dibangun mampu mengklasifikasikan kondisi anemia dan non-anemia secara otomatis melalui analisis karakteristik visual citra, sehingga tujuan penelitian dalam merancang metode deteksi anemia non-invasif dapat tercapai.
2. Hasil pelatihan menunjukkan kinerja model yang stabil dengan akurasi pelatihan sekitar 82% dan akurasi validasi sebesar 79,82% serta nilai AUC 0,9003 pada epoch terbaik, yang menandakan kemampuan model dalam mempelajari fitur visual citra dengan baik. Pada tahap pengujian, performa meningkat dengan akurasi 90,71%, AUC 0,9768, dan loss 0,2802, sehingga menunjukkan kemampuan generalisasi model yang baik terhadap data citra baru di luar proses pelatihan.
3. Visualisasi confusion matrix menunjukkan hasil klasifikasi setelah penggunaan threshold optimal 0,64. Model berhasil mengklasifikasikan 329 data Anemic dan 298 data Non-Anemic dengan benar, sementara kesalahan prediksi masing-masing sebesar 29 dan 22 data. Hasil ini menunjukkan bahwa model memiliki sensitivitas dan spesifisitas yang

baik dalam mengenali kedua kategori citra.

4. Kurva ROC pada data uji menunjukkan nilai AUC sebesar 0,977 dengan posisi kurva jauh di atas garis diagonal acak, yang menandakan kemampuan model sangat baik dalam membedakan citra anemia dan non-anemia, dimana Model mampu menjaga *true positive rate* tetap tinggi dengan tingkat kesalahan prediksi positif yang rendah pada berbagai nilai threshold. Kurva Precision–Recall menghasilkan nilai *Average Precision* (AP) sebesar 0,978, yang menunjukkan precision tetap terjaga saat recall meningkat, yang menandakan sebagian besar kasus anemia dapat terdeteksi dengan baik tanpa menghasilkan prediksi positif berlebih.
5. Model yang telah dikembangkan kemudian diimplementasikan ke dalam aplikasi mobile berbasis Android menggunakan React Native dengan dukungan backend Flask sebagai API, sehingga proses prediksi dapat dilakukan secara real-time oleh pengguna.

5.2 Saran

Berdasarkan hasil penelitian yang telah dilakukan, terdapat beberapa saran yang dapat dipertimbangkan untuk pengembangan penelitian selanjutnya, antara lain:

1. Penambahan jumlah dan keberagaman dataset citra perlu dilakukan dengan mempertimbangkan variasi pencahayaan, kualitas perangkat kamera, sudut pengambilan gambar, serta perbedaan karakteristik pengguna. Dataset yang lebih beragam diharapkan mampu meningkatkan kemampuan generalisasi model pada kondisi penggunaan nyata.
2. Penelitian selanjutnya dapat mengembangkan sistem klasifikasi menjadi multi-kelas berdasarkan rentang kadar hemoglobin (Hb), misalnya

kategori sangat rendah, rendah, dan normal. Pendekatan ini berpotensi menghasilkan informasi deteksi yang lebih detail serta mendukung kebutuhan skrining awal, termasuk pada kegiatan donor darah.

3. Pengembangan selanjutnya dapat mencakup optimasi model agar dapat berjalan sepenuhnya secara *on-device* menggunakan model yang lebih ringan, sehingga sistem tetap dapat digunakan tanpa koneksi internet dan meningkatkan fleksibilitas penggunaan di berbagai lingkungan.

DAFTAR PUSTAKA

Kasiviswanathan, S., Vijayan, B., Simone, G., & Dimauro, G. (2020). Semantic segmentation of conjunctiva images for non-invasive anemia detection. *Electronics*, *9*(8), 1309. https://doi.org/10.3390/electronics9081309

Suryani, A., & Putra, I. (2022). Implementasi deep learning dalam sistem diagnosis kesehatan non-invasif. *Jurnal Teknologi Informasi dan Komputer*, *9*(2), 55–62.

Amalia, E., Lamada, M., Kaswar, A. B., & Andayani, D. D. (2023). Klasifikasi penyakit anemia berbasis citra palpebral konjungtiva dengan algoritma transfer learning. *Jurnal Media Elektrik, 20*(2), 73–86. https://doi.org/10.59562/metrik.v20i2.5538

Tan, M., & Le, Q. V. (2020). EfficientNet: Rethinking model scaling for convolutional neural networks. Proceedings of the 37th International Conference on Machine Learning (ICML). *arXiv:1905*.11946. https://arxiv.org/abs/1905.11946

World Health Organization. (2021). Global anemia estimates in women of reproductive age, 2000–2019. *Geneva: World Health Organization.* https://www.who.int/publications/i/item/9789240018389

Kementerian Kesehatan Republik Indonesia. (2022). Profil kesehatan Indonesia tahun 2022. *Jakarta: Kemenkes RI*. https://www.kemkes.go.id/

United Nations. (2020). The Sustainable Development Goals report 2020. *New York: United Nations*. https://unstats.un.org/sdgs/report/2020/

Vos, T., Lim, S. S., Abbafati, C., Abbas, K. M., Abd-Allah, F., Abera, S. F., … Murray, C. J. L. (2021). Global burden of anemia and its underlying causes, 1990–2019. *Journal of Hematology & Oncology, 14*(1), 36. https://doi.org/10.1186/s13045-021-01202-2

Yazdani, M., Simegn, W., Kumera, G., Tewabe, T., & Tesfa, T. (2025). Anemia among women of reproductive age: Global trends and contributing factors, 1990–2021. *Frontiers in Nutrition, 8, Article* 1588496. https://doi.org/10.3389/fnut.2025.1588496

Kassebaum, N. J. (2016). The global burden of anemia. *Blood*, *128*(22), 486–495. https://doi.org/10.1182/blood-2016-05-712488

Yadav, K., Jain, M., & Bharadwaj, A. (2019). Portable system for the prediction of anemia based on ocular conjunctiva using machine learning. *arXiv:1910*.12399. https://arxiv.org/abs/1910.12399

Dwijayana, I. G. D., & Wibawa, I. G. A. (2022). Implementasi transfer learning dalam klasifikasi penyakit pada daun teh menggunakan MobileNetV2. Jurnal Nasional *Teknologi Informasi dan Aplikasnya, 1*(1), 379-388. https://ojs.unud.ac.id/index.php/jnatia/article/view/92600

Luo, H., Sun, J., Cao, Y., Li, X., Zhang, Y., & GBD 2021 Anemia Collaborators. (2025). Global, regional, and national burden of anemia and its trends from 1990 to 2021: A systematic analysis of the Global Burden of Disease Study 2021. *Journal of Global Health*, 15(1), Article 01012. https://doi.org/10.7189/jogh.15.01012

Magdalena, R., Saidah, S., Ubaidah, I. D. S., Fuadah, Y. N., Herman, N., & Ibrahim, N. (2022). Convolutional neural network for anemia detection based on conjunctiva palpebral images. *Jurnal Teknik Informatika (JUTIF), 3*(2), 349–354.

Florestiyanto, R., & Peksi, A. (2020). Deteksi anemia non-invasif menggunakan citra kuku dan telapak tangan. *Jurnal Teknologi Informasi dan Ilmu Komputer, 7*(2), 123–130.

Android Developers. (2023). *Android app fundamentals*. https://developer.android.com/guide

Winarsih, M. A. D. (2024). Sistem deteksi anemia non-invasif berdasarkan konsentrasi hemoglobin melalui segmentasi U-Net dengan analisis warna konjungtiva mata (Skripsi, Institut Teknologi Sepuluh Nopember). *ITS Institutional Repository*. https://repository.its.ac.id/110956/

Hartono, A. C., & Muslikh, A. R. (2025). Penerapan transfer learning MobileNetV2 pada klasifikasi citra jenis buah-buahan. *Journal of Information System and Application Development, 3*(2), 1-10. https://jurnal.unmer.ac.id/index.php/jisad/article/view/16187

Anaemia detection using deep learning with conjunctiva, nail, palm and tongue images. (2023). *International Research Journal of Advanced Engineering and Health, 3*(2). https://irjaeh.com/index.php/journal/article/view/390

Appiahene, P., Asare, J. W., Donkoh, E. T., Dimauro, G., & Maglietta, R. (2023). Detection of iron deficiency anemia by medical images: A comparative study of machine learning algorithms. *BioData Mining, 16, Article* 2. https://doi.org/10.1186/s13040-023-00319-z

Chowdhury, R., Dey, S., & Chattopadhyay, S. (2020). Image-based anemia detection: A review. *Biomedical Signal Processing and Control, 62*, 102115. https://doi.org/10.1016/j.bspc.2020.102115

Dutta, R., Bhattacharjee, H., Das, D., & Deka, S. (2019). Ocular indicators of anemia. *Indian Journal of Ophthalmology, 67*(2), 202–208. https://doi.org/10.4103/ijo.IJO_920_18

Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep learning. *MIT Press*.

Gonzalez, R. C., & Woods, R. E. (2018). Digital image processing (4th ed.). Pearson.

Google Developers. (2022). TensorFlow Lite for mobile and edge devices. *Retrieved from* https://www.tensorflow.org/lite

Guyton, A. C., & Hall, J. E. (2016). Textbook of medical physiology (13th ed.). *Elsevier.*

Kaur, P., & Singh, G. (2021). Mobile AI applications in health diagnostics. *Mobile Computing and Health Informatics Journal, 8*(3), 45–52.

Kementerian Kesehatan Republik Indonesia. (2022*). Laporan hasil Riskesdas 2022. Jakarta: Badan Litbangkes*.

Khurana, A. K. (2018). Comprehensive ophthalmology (6th ed.). *Jaypee Brothers Medical Publishers.*

LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, *521*(7553), 436–444. https://doi.org/10.1038/nature14539

Rahman, M., Islam, M. S., & Hasan, M. M. (2022). Lightweight CNN models for medical image classification. *Journal of Medical Systems, 46*(1), 1–13. https://doi.org/10.1007/s10916-021-01762-5

Reddy, M., Ramesh, V., & Basha, M. S. (2020). Non-invasive anemia detection using conjunctival images. *IEEE Access, 8*, 180978–180985. https://doi.org/10.1109/ACCESS.2020.3028018

Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L. C. (2018). *MobileNetV2: Inverted residuals and linear bottlenecks*. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 4510–4520). https://doi.org/10.1109/CVPR.2018.00474

Sokolova, M., & Lapalme, G. (2009). Performance measures in classification tasks. *Information Processing & Management, 45*(4), 427–437. https://doi.org/10.1016/j.ipm.2009.03.002

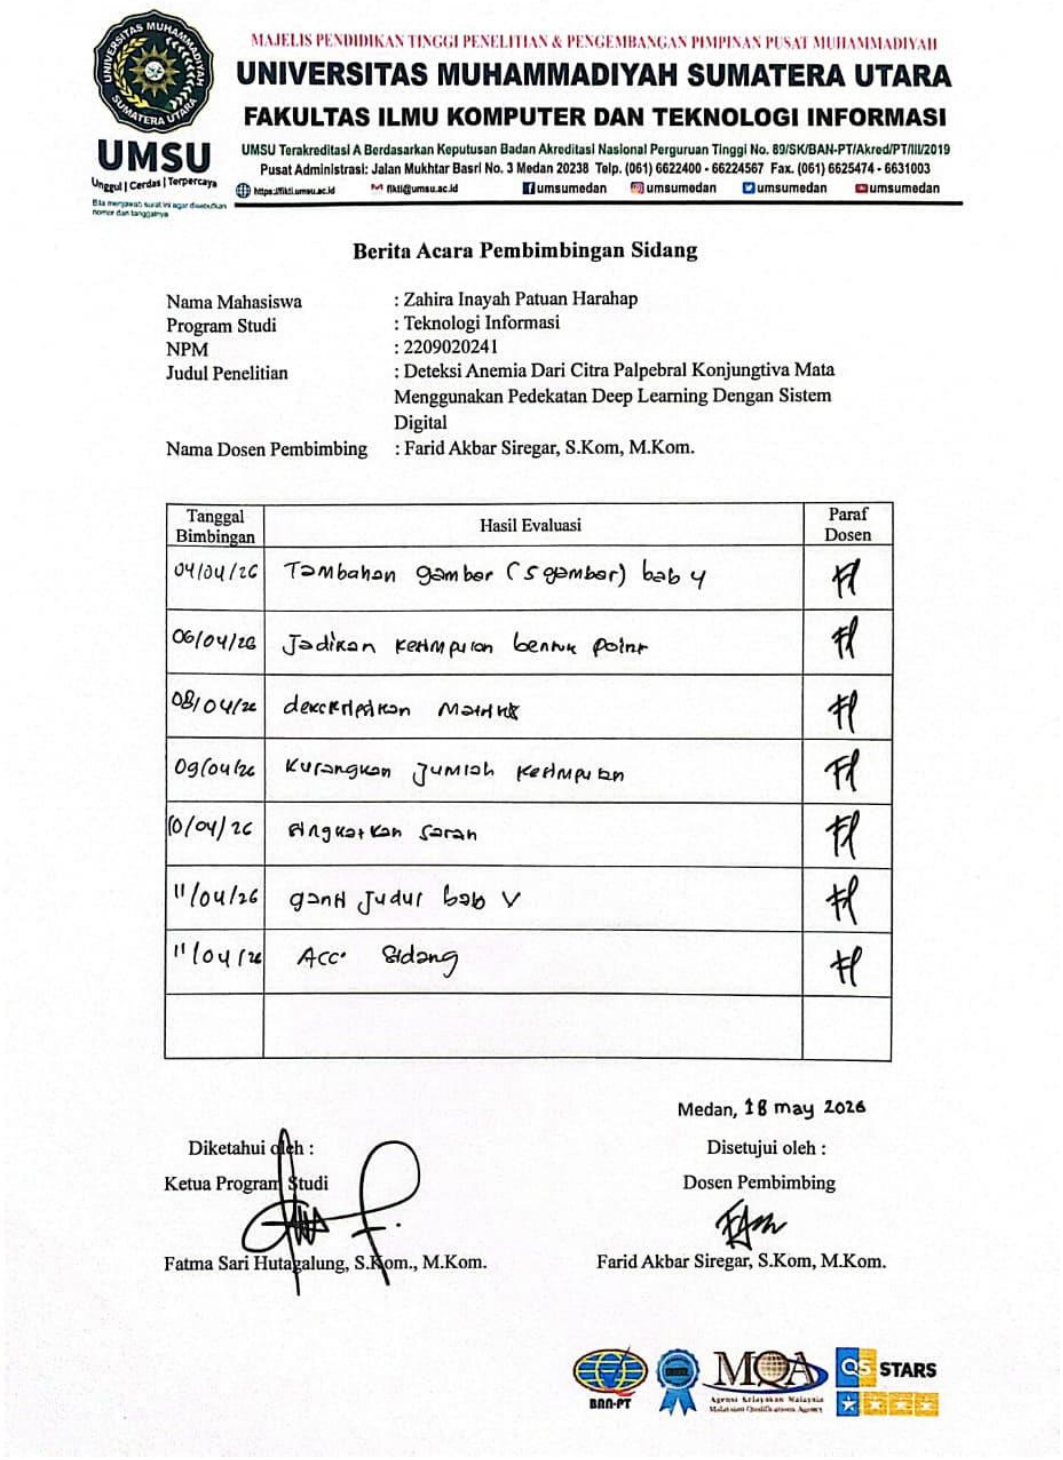
Tan, C., Sun, F., Kong, T., Zhang, W., Yang, C., & Liu, C. (2019). A survey on transfer learning. *IEEE Transactions on Neural Networks and Learning Systems, 31*(5), 1–23. https://doi.org/10.1109/TNNLS.2019.2906152

World Health Organization. (2021). Haemoglobin concentrations for the diagnosis of anaemia and assessment of severity. *Geneva: WHO*.

Gupta, S., Singh, R., & Mehra, A. (2021). Preprocessing in medical image classification. *Procedia Computer Science, 192*, 2832–2841. https://doi.org/10.1016/j.procs.2021.08.283

LAMPIRAN

1. Berita Acara Pembimbingan Skripsi



MAJELIS PENDIDIKAN TINGGI PENELITIAN & PENGEMBANGAN PIMPINAN PUSAT MUHAMMADIYAH
UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA
FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI
UMSU Terakreditasi A Berdasarkan Keputusan Badan Akreditasi Nasional Perguruan Tinggi No. 89/SK/BAN-PT/Akred/PT/III/2019
Pusat Administrasi: Jalan Mukhtar Basri No. 3 Medan 20238 Telp. (061) 6622400 - 66224567 Fax. (061) 6625474 - 6631003
https://fikti.umsu.ac.id fikti@umsu.ac.id umsumedan umsumedan umsumedan umsumedan

UMSU
Unggul | Cerdas | Terpercaya

Berita Acara Pembimbingan Sidang

Nama Mahasiswa : Zahira Inayah Patuan Harahap
Program Studi : Teknologi Informasi
NPM : 2209020241
Judul Penelitian : Deteksi Anemia Dari Citra Palpebral Konjungtiva Mata Menggunakan Pedekatan Deep Learning Dengan Sistem Digital
Nama Dosen Pembimbing : Farid Akbar Siregar, S.Kom, M.Kom.

Tanggal Bimbingan	Hasil Evaluasi	Paraf Dosen
04/04/26	Tambahan gambar (5 gambar) bab 4	
06/04/26	Jadikan kelompokan bentuk point	
08/04/26	dekripsikan matriks	
09/04/26	Kurangkan jumlah kelompokan	
10/04/26	Angkatkan saran	
11/04/26	ganti judul bab V	
11/04/26	Acc sidang	

Medan, 18 may 2026

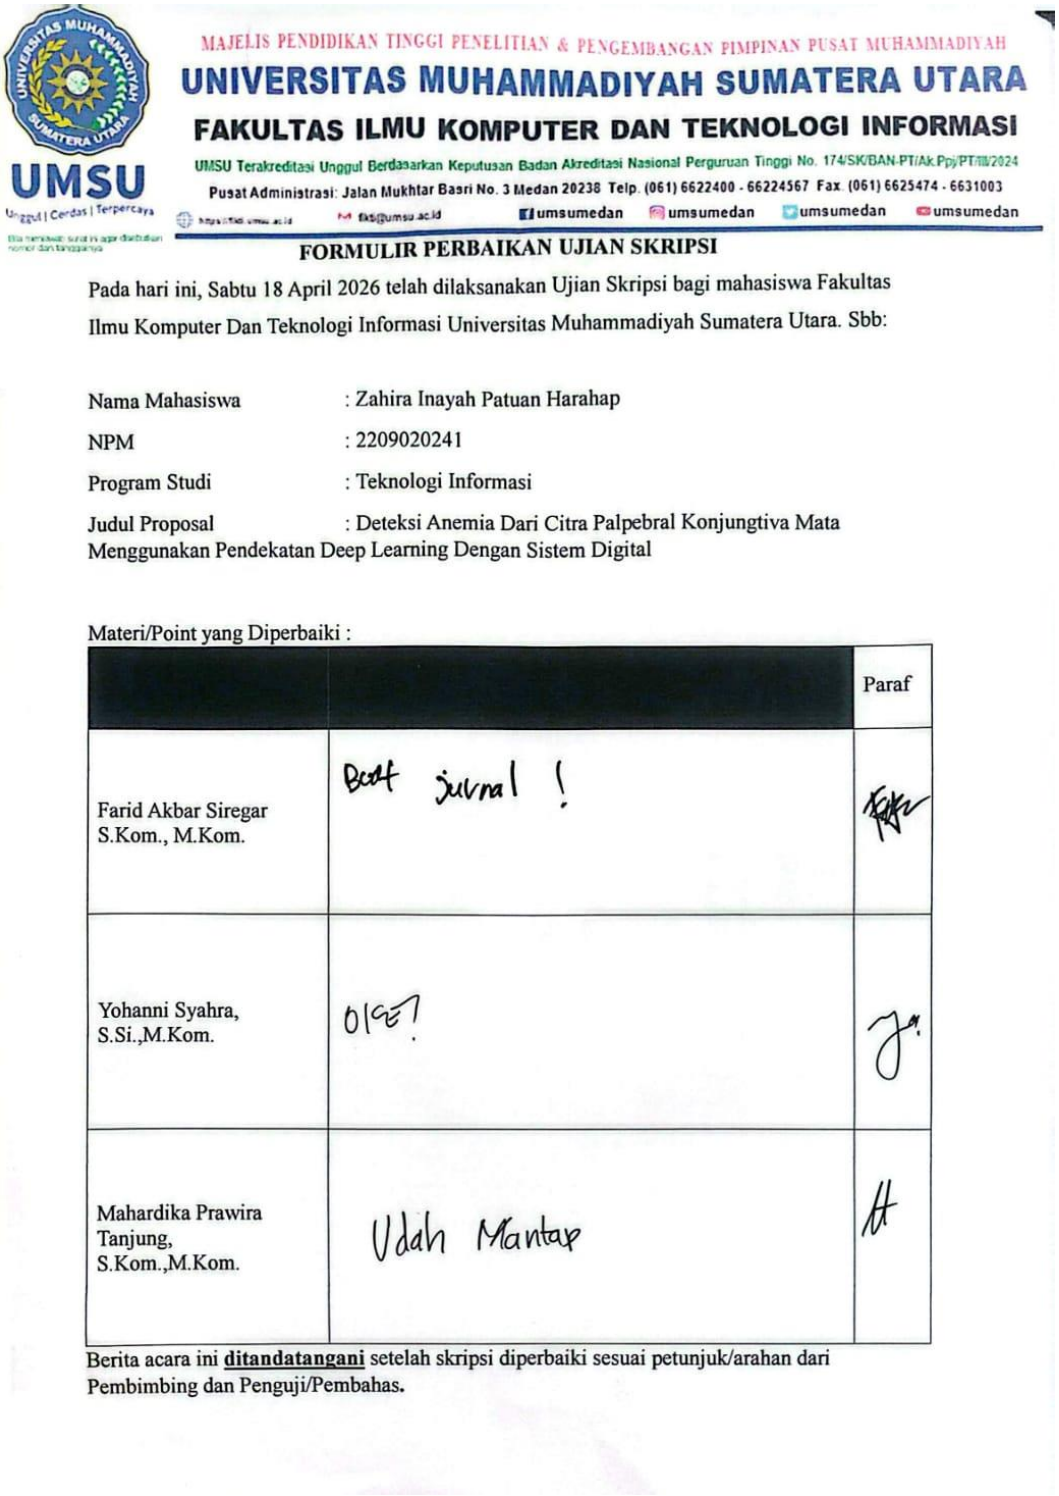
Diketahui oleh :
Ketua Program Studi

Fatma Sari Hutagalung, S.Kom., M.Kom.

Disetujui oleh :
Dosen Pembimbing

Farid Akbar Siregar, S.Kom, M.Kom.

2. Formulir Perbaikan Ujian Skripsi



MAJELIS PENDIDIKAN TINGGI PENELITIAN & PENGEMBANGAN PIMPINAN PUSAT MUHAMMADIYAH

UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA

FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI

UMSU Terakreditasi Unggul Berdasarkan Keputusan Badan Akreditasi Nasional Perguruan Tinggi No. 174/SK/BAN-PT/Ak.Ppj/PT/III/2024

Pusat Administrasi: Jalan Mukhtar Basri No. 3 Medan 20238 Telp. (061) 6622400 - 66224567 Fax. (061) 6625474 - 6631003

fiki@umsu.ac.id umsumedan umsumedan umsumedan umsumedan

UMSU Unggul | Cerdas | Terpercaya

FORMULIR PERBAIKAN UJIAN SKRIPSI

Pada hari ini, Sabtu 18 April 2026 telah dilaksanakan Ujian Skripsi bagi mahasiswa Fakultas Ilmu Komputer Dan Teknologi Informasi Universitas Muhammadiyah Sumatera Utara. Sbb:

Nama Mahasiswa : Zahira Inayah Patuan Harahap

NPM : 2209020241

Program Studi : Teknologi Informasi

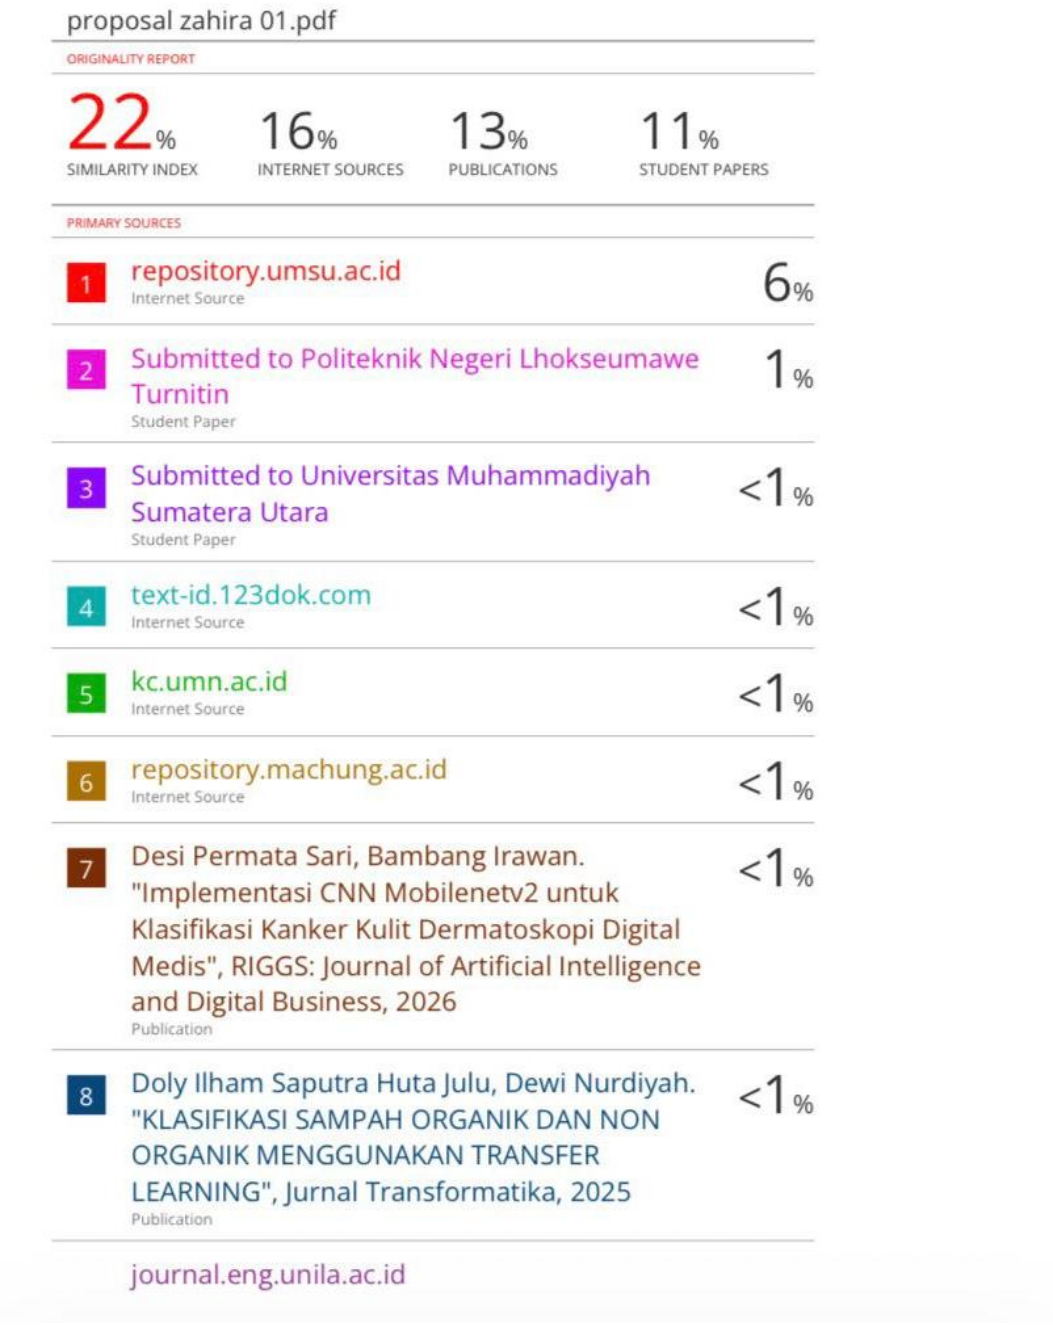
Judul Proposal : Deteksi Anemia Dari Citra Palpebral Konjungtiva Mata Menggunakan Pendekatan Deep Learning Dengan Sistem Digital

Materi/Point yang Diperbaiki :

		Paraf
Farid Akbar Siregar S.Kom., M.Kom.	Best jurnal !	
Yohanni Syahra, S.Si.,M.Kom.	OKE!	
Mahardika Prawira Tanjung, S.Kom.,M.Kom.	Udah Mantap	

Berita acara ini **ditandatangani** setelah skripsi diperbaiki sesuai petunjuk/arahan dari Pembimbing dan Penguji/Pembahas.

3. Hasil Turnitin Skripsi



proposal zahira 01.pdf

ORIGINALITY REPORT

22%	16%	13%	11%
SIMILARITY INDEX	INTERNET SOURCES	PUBLICATIONS	STUDENT PAPERS

PRIMARY SOURCES

1	repository.umsu.ac.id Internet Source	6%
2	Submitted to Politeknik Negeri Lhokseumawe Turnitin Student Paper	1%
3	Submitted to Universitas Muhammadiyah Sumatera Utara Student Paper	<1%
4	text-id.123dok.com Internet Source	<1%
5	kc.umn.ac.id Internet Source	<1%
6	repository.machung.ac.id Internet Source	<1%
7	Desi Permata Sari, Bambang Irawan. "Implementasi CNN Mobilenetv2 untuk Klasifikasi Kanker Kulit Dermatoskopi Digital Medis", RIGGS: Journal of Artificial Intelligence and Digital Business, 2026 Publication	<1%
8	Doly Ilham Saputra Huta Julu, Dewi Nurdiyah. "KLASIFIKASI SAMPAH ORGANIK DAN NON ORGANIK MENGGUNAKAN TRANSFER LEARNING", Jurnal Transformatika, 2025 Publication	<1%

journal.eng.unila.ac.id