

Sistem Cerdas Deteksi Risiko Anemia Berbasis *Hybrid Convolutional Neural Network* dan *Expert System* pada Analisis Citra Konjungtiva Mata dan Gejala Klinis Pasien

Ghefira Zahra Nur Fadhilah¹, Muh. Yamin², Asa Hari Wibowo³

^{1,2,3}Program Studi Teknik Informatika, Universitas Halu Oleo, Kendari, Indonesia

Email : ghefirazahranurfadhilah@gmail.com, muh_yamin@uho.ac.id, asa.hari@uho.ac.id

Article Information

Article history

Received 20 April 2026

Revised 26 May 2026

Accepted 7 June 2026

Available 13 June 2026

Keywords

Anemia
Clinical Symptoms
Conjunctiva Image
Expert System
MobileNetV2

Corresponding Author:

Ghefira Zahra Nur Fadhilah,
Universitas Halu Oleo,
Email:
ghefirazahranurfadhilah@gmail.com

Abstract

Anemia remains a global health problem, requiring early detection to prevent serious complications. Hemoglobin testing is invasive, while previous *non-invasive* screening approaches rely on a single parameter, limiting early detection effectiveness. This study develops a *non-invasive* anemia screening system using conjunctival images and clinical symptoms based on a Convolutional Neural Network (CNN) with MobileNetV2, an expert system, and a weighted hybrid method. A total of 3,870 conjunctival images were used for training and validation, while 50 test samples were collected using a smartphone and clinical symptom data. The results show that the CNN achieved 94% accuracy, the expert system 90%, and the hybrid method achieved 96% accuracy, 100% precision, 89% recall, and a 94% F1-score. These findings indicate that the integration of methods improves screening performance and supports a fast, easy, *non-invasive*, and practical anemia screening system for early detection that can be used independently at home with accessible devices.

Keywords : *Anemia, Clinical Symptoms, Conjunctiva Image, Expert System, MobileNetV2*

Abstrak

Hingga saat ini Anemia masih menjadi masalah kesehatan dunia sehingga perlu deteksi dini untuk mencegahnya. Pemeriksaan hemoglobin bersifat invasif, sedangkan skrining *non-invasif* sebelumnya hanya memakai satu faktor parameter sehingga terbatas untuk deteksi awal. Penelitian ini membuat sistem skrining anemia secara *non-invasif* dengan parameter citra mata dan data gejala klinis menggunakan *Convolutional Neural Network* (CNN) berbasis MobileNetV2, sistem pakar, dan metode *weighted hybrid*. Sebanyak 3.870 citra mata digunakan untuk data latih dan validasi, sedangkan 50 data uji yang diambil melalui kamera *smartphone* dan data gejala klinis. Hasil ini menunjukkan *accuracy* CNN 94%, sistem pakar 90%, sedangkan metode *hybrid accuracy* mencapai 96%, 100% *precision*, 89% *recall*, serta *F1-score* 94%. Dari hasil ini terlihat integrasi metode meningkatkan hasil skrining dan mendukung sistem skrining anemia yang lebih cepat, mudah, dan *non-invasif* untuk deteksi awal yang lebih tepat dan praktis, serta efisien, hemat waktu, dan dapat digunakan mandiri di rumah dengan perangkat yang mudah diakses.

Kata Kunci : *Anemia, Citra Konjungtiva, Gejala Klinis, MobileNetV2, Sistem Pakar*

Copyright©2026 Ghefira Zahra Nur Fadhilah, Muh. Yamin, Asa Hari Wibowo
This is an open access article under the [CC-BY-NC-SA](https://creativecommons.org/licenses/by-nc-sa/4.0/) license.



1. Pendahuluan

Anemia merupakan suatu kondisi medis yang ditandai oleh penurunan kadar hemoglobin atau jumlah eritrosit di bawah nilai normal, yang menyebabkan terganggunya kemampuan darah dalam mengangkut oksigen ke seluruh jaringan tubuh (Pandapotan & Suhayanly, 2025). *World Health Organization* (WHO) melaporkan bahwa sekitar 1,9–2,4 miliar orang di dunia mengalami anemia, dengan prevalensi tinggi pada perempuan usia reproduksi. Data *Global Burden of Disease* (GBD) 2021 menunjukkan bahwa anemia pada kelompok tersebut diproyeksikan tetap menjadi masalah kesehatan global hingga tahun 2030 (Zheng et al., 2025). Anemia juga berpotensi menyebabkan komplikasi pada kehamilan, antara lain kelahiran prematur, bayi dengan berat badan lahir rendah, dan perdarahan pascapersalinan (Herlina et al., 2024). Kondisi ini juga memperburuk prognosis pasien selama perawatan medis (Dasarathy & Attaway, 2024).

Di Indonesia, sekitar 18% perempuan dewasa mengalami anemia pada tahun 2023 (Priliani et al., 2025), yang menunjukkan perlunya upaya deteksi dini yang lebih efektif dan mudah diakses. Pemeriksaan anemia umumnya dilakukan melalui pengukuran kadar hemoglobin menggunakan sampel darah (Liana et al., 2026). Meskipun memiliki akurasi tinggi, metode ini bersifat invasif, membutuhkan tenaga medis, dan fasilitas laboratorium yang memadai (Fan et al., 2022), sehingga kurang optimal pada kondisi dengan keterbatasan akses kesehatan. Keterbatasan tersebut menunjukkan perlunya metode skrining yang lebih praktis dan *non-invasif* sebagai pendukung deteksi dini.

Seiring meningkatnya kebutuhan terhadap metode skrining anemia yang lebih mudah diakses, perkembangan *Artificial Intelligence* (AI) mulai banyak dimanfaatkan dalam bidang kesehatan untuk mendukung proses skrining awal yang lebih cepat, efisien, dan praktis (Ahsan et al., 2022). Salah satu metode yang umum digunakan adalah analisis citra konjungtiva mata, karena perubahan warna pada area tersebut berkaitan dengan kadar hemoglobin (Amalia et al., 2023). Dalam pengolahan citra medis, *Convolutional Neural Network* (CNN) banyak digunakan karena mampu melakukan ekstraksi fitur secara otomatis dengan performa yang tinggi (Gunawan & Setiawan, 2022). Arsitektur MobileNetV2 dipilih karena memiliki keunggulan ringan, efisien, dan cocok diterapkan pada perangkat dengan keterbatasan komputasi (Askale et al., 2026).

Penelitian sebelumnya menunjukkan bahwa MobileNetV2 yang dikombinasikan dengan pendekatan multimodal mampu mencapai akurasi hingga 95% pada deteksi anemi (Ramzan et al., 2024), serta 97,19% pada klasifikasi anemia berbasis citra konjungtiva (Purwanti et al., 2023). Selain pendekatan berbasis citra, gejala klinis juga dapat dimanfaatkan dalam sistem pakar (*expert system*) berbasis aturan (*rule-based*) untuk mendukung proses pengambilan keputusan (Papadopoulos et al., 2022). Maulina et al., (2023) menunjukkan bahwa pendekatan tersebut mampu mencapai akurasi sekitar 93% pada skrining anemia.

Namun, penelitian-penelitian tersebut masih memiliki keterbatasan mendasar. Sebagian besar studi menggunakan pendekatan *single-modality*, hanya citra konjungtiva atau gejala klinis secara terpisah sehingga integrasi informasi visual dan klinis belum optimal (Purwanti et al., 2023). Pendekatan berbasis citra sangat rentan terhadap variasi pencahayaan, kualitas kamera, dan kondisi akuisisi gambar yang dapat menurunkan konsistensi performa model di lingkungan nyata (Asare et al., 2023), sedangkan pendekatan berbasis gejala klinis bergantung sepenuhnya pada informasi yang dilaporkan pengguna sehingga rentan terhadap subjektivitas dan ketidakakuratan dalam pelaporan gejala (Papadopoulos et al., 2022). Selain itu, sebagian besar sistem yang dikembangkan belum tersedia dalam *platform* yang dapat diakses secara mandiri oleh masyarakat umum. Keterbatasan-keterbatasan ini menunjukkan bahwa masing-masing pendekatan memiliki kelemahan signifikan apabila digunakan secara tunggal dalam sistem skrining anemia.

Beberapa penelitian menunjukkan bahwa pendekatan *multimodal* yang mengintegrasikan data citra dan klinis berpotensi menghasilkan performa lebih baik dibandingkan penggunaan satu modalitas secara terpisah, karena kedua sumber informasi tersebut saling melengkapi dan menutupi kelemahan masing-masing (Ramzan et al., 2024). Namun, penelitian yang secara khusus menggabungkan CNN berbasis MobileNetV2 dan *Expert System* berbasis aturan klinis dalam satu sistem skrining anemia terpadu menggunakan metode *weighted hybrid decision fusion* masih sangat terbatas. Kesenjangan ini menegaskan perlunya pengembangan pendekatan *Hybrid AI* yang mampu mengintegrasikan informasi visual yang bersifat objektif dan informasi klinis yang bersifat subjektif secara simultan, sehingga menghasilkan sistem skrining anemia yang lebih komprehensif dan konsisten dalam berbagai kondisi penggunaan nyata.

Berdasarkan kesenjangan tersebut, penelitian ini mengusulkan sistem skrining anemia *non-invasif* berbasis *Hybrid AI* yang mengintegrasikan CNN MobileNetV2 untuk analisis citra konjungtiva dan *Expert System* berbasis aturan klinis untuk analisis gejala pasien, digabungkan melalui metode *weighted hybrid decision fusion*. Kebaruan penelitian ini terletak pada integrasi simultan kedua modalitas tersebut dalam satu sistem terpadu berbasis *web* yang dapat digunakan secara mandiri dan cepat menjadikannya berbeda dari penelitian sebelumnya yang umumnya memanfaatkan satu informasi secara terpisah.

Penelitian ini bertujuan merancang, mengimplementasikan, dan mengevaluasi kinerja sistem *hybrid* tersebut dibandingkan pendekatan tunggal, dengan ruang lingkup klasifikasi biner anemia dan *non-anemia* menggunakan citra konjungtiva dari kamera smartphone dan gejala klinis berbasis kuesioner. Sistem ini difokuskan sebagai alat skrining awal, bukan diagnosis medis, sehingga diharapkan berkontribusi secara ilmiah dalam pengembangan pendekatan *hybrid* untuk skrining *non-invasif* sekaligus memberikan manfaat praktis dalam memperluas akses deteksi dini anemia, khususnya di daerah dengan keterbatasan fasilitas kesehatan.

2. Kajian Terdahulu

Artificial Intelligence (AI) telah banyak dimanfaatkan dalam bidang kesehatan untuk mendukung sistem skrining penyakit secara *non-invasif*. Dalam konteks deteksi anemia, dua pendekatan utama yang berkembang adalah analisis citra konjungtiva berbasis *deep learning* dan inferensi gejala klinis berbasis *Expert System*. Konjungtiva palpebral dipilih sebagai area analisis karena perubahan warna pada konjungtiva (*conjunctival pallor*) digunakan sebagai indikator klinis yang berhubungan dengan kadar hemoglobin, serta dapat diperiksa secara *non-invasif* dalam evaluasi anemia (Chen et al., 2026). Perkembangan kedua pendekatan ini membuka peluang pengembangan sistem skrining anemia yang lebih komprehensif melalui integrasi keduanya.

2.1 *Convolutional Neural Network dalam Pengolahan Citra Medis*

Convolutional Neural Network (CNN) merupakan arsitektur *deep learning* yang dirancang khusus untuk memproses data berbentuk grid seperti citra, melalui serangkaian lapisan konvolusi, *pooling*, dan *fully connected* yang mampu mengekstraksi fitur hierarkis secara otomatis tanpa rekayasa fitur manual (Gunawan & Setiawan, 2022). Kemampuan ini menjadikan CNN unggul dalam tugas klasifikasi citra medis dibandingkan metode konvensional berbasis fitur manual. Magdalena et al., (2022) menunjukkan bahwa CNN mampu membedakan kondisi anemia dan *non-anemia* berdasarkan karakteristik visual pada konjungtiva secara otomatis. Keunggulan pendekatan ini terletak pada kemampuan ekstraksi fitur tanpa rekayasa fitur manual, meskipun performanya dapat dipengaruhi oleh kompleksitas model dan kualitas data.

2.2 *Transfer Learning dan MobileNetV2*

Transfer learning adalah teknik yang memanfaatkan pengetahuan yang telah dipelajari model dari dataset berskala besar untuk diterapkan pada tugas baru dengan data yang lebih terbatas, sehingga dapat meningkatkan efisiensi dan performa pembelajaran model (Hosna et al., 2022). Pendekatan ini terbukti efektif dalam domain medis karena ketersediaan data berlabel yang terbatas, mengingat proses anotasi data medis membutuhkan waktu, biaya, serta keahlian tenaga medis (Chae & Kim, 2023). MobileNetV2 merupakan arsitektur *Convolutional Neural Network* (CNN) ringan yang dirancang untuk efisiensi komputasi, dan telah banyak digunakan pada analisis citra medis termasuk deteksi anemia berbasis citra konjungtiva karena mampu menghasilkan performa yang baik dengan kompleksitas yang rendah (Ilmadina et al., 2025).

Arsitektur ini sangat sesuai untuk implementasi pada perangkat dengan keterbatasan komputasi seperti *smartphone*. Purwanti et al., (2023) menunjukkan bahwa MobileNetV2 dengan pendekatan *transfer learning* mampu mencapai akurasi 97,19% pada klasifikasi anemia berbasis citra konjungtiva, mengonfirmasi efektivitasnya untuk tugas skrining berbasis citra. Ramzan et al., (2024) juga melaporkan bahwa MobileNetV2

mampu mencapai akurasi 95% pada deteksi anemia berbasis citra konjungtiva dan data klinis, yang menunjukkan potensinya dalam analisis citra medis.

2.3 Sistem Pakar Berbasis Aturan Klinis

Sistem Pakar (*Expert System*) adalah sistem kecerdasan buatan yang menggunakan basis pengetahuan dan mesin inferensi untuk meniru kemampuan pengambilan keputusan seorang pakar dalam domain tertentu (Mustafa et al., 2023). Mekanisme inferensi yang umum digunakan adalah aturan *IF-THEN* yang merepresentasikan pengetahuan klinis secara terstruktur. Dalam konteks skrining anemia, *Expert System* berbasis aturan memanfaatkan gejala klinis seperti pucat, kelelahan, dan sesak napas sebagai basis inferensi. Maulina et al., (2023) menunjukkan bahwa pendekatan ini mampu mencapai akurasi sekitar 93% pada skrining anemia berbasis gejala klinis. Papadopoulos et al., (2022) juga mengonfirmasi efektivitas sistem berbasis aturan dalam mendukung pengambilan keputusan medis. Keterbatasan utama pendekatan ini terletak pada subjektivitas pengguna dalam melaporkan gejala yang dialami, sehingga hasil inferensi sangat bergantung pada akurasi input yang diberikan.

2.4 Segmentasi Citra Konjungtiva

Segmentasi merupakan proses penting dalam analisis citra karena digunakan untuk membagi citra menjadi beberapa *region* dan menghilangkan *noise* sehingga analisis menjadi lebih mudah. Metode *Hue-Saturation-Value* (HSV) digunakan untuk memisahkan area konjungtiva berdasarkan karakteristik warna, sedangkan GrabCut merupakan metode segmentasi iteratif berbasis *Graph Cut* yang memanfaatkan model probabilistik untuk segmentasi interaktif yang lebih presisi. Kombinasi kedua metode ini membantu meningkatkan kualitas segmentasi terutama pada kondisi pencahayaan tidak stabil, meskipun masih sensitif terhadap parameter awal segmentasi (Zhao et al., 2023). Kualitas segmentasi yang baik secara langsung berkontribusi pada konsistensi performa model klasifikasi CNN pada kondisi nyata.

2.5 Pendekatan *Hybrid Artificial Intelligence* (AI) dalam Skrining Medis

Pendekatan *Hybrid AI* mengombinasikan dua atau lebih metode kecerdasan buatan untuk memanfaatkan keunggulan masing-masing metode serta mengatasi keterbatasan yang dimiliki oleh metode tunggal, sehingga dapat meningkatkan kinerja sistem secara keseluruhan (Azevedo et al., 2024). Dalam bidang medis, pendekatan *Hybrid AI* menggabungkan kemampuan deep learning dalam menganalisis data dengan pengetahuan pakar yang direpresentasikan melalui sistem berbasis aturan untuk mendukung pengambilan keputusan yang lebih komprehensif (Wang et al., 2024). *Weighted hybrid decision fusion* merupakan strategi penggabungan keputusan yang memberikan bobot berbeda pada setiap modalitas berdasarkan tingkat kepercayaan

masing-masing sumber, sehingga keputusan akhir lebih representatif terhadap seluruh informasi yang tersedia (Ge et al., 2025). Terdapat juga penelitian yang menunjukkan bahwa pendekatan *multimodal* yang mengintegrasikan data citra dan klinis berpotensi menghasilkan performa lebih baik karena saling melengkapi (Ramzan et al., 2024).

2.6 Perbandingan Penelitian Terdahulu

Untuk memperoleh gambaran mengenai perkembangan penelitian terkait deteksi anemia *non-invasif*, dilakukan perbandingan terhadap beberapa penelitian terdahulu yang menggunakan berbagai pendekatan, mulai dari metode berbasis citra, sistem pakar, hingga pendekatan *multimodal*. Perbandingan tersebut mencakup metode yang digunakan, jenis modalitas data, tingkat akurasi yang diperoleh, serta keterbatasan penelitian. Ringkasan perbandingan penelitian terdahulu disajikan pada Tabel 1.

Tabel 1. Perbandingan State-of-the-Art Penelitian Terdahulu

No.	Peneliti	Metode	Modalitas	Akurasi	Keterbatasan
1.	Magdalena et al., (2022)	CNN	Citra Konjungtiva	94%	<i>Single-modality</i> , tanpa data klinis
2.	(Purwanti et al., 2023)	MobileNetV2	Citra Konjungtiva	97,19%	<i>Single-modality</i> , rentan variasi pencahayaan
3.	Maulina et al., (2023)	<i>Expert System Rule-based</i>	Gejala Klinis	93%	Subjektivitas pengguna, tanpa data visual
4.	(Ramzan et al., 2024),	<i>Multimodal Fusion</i> MobileNetV2 + EHR	Citra konjungtiva + EHR	95%	Membutuhkan data EHR selain citra, sehingga kurang praktis untuk skrining mandiri.

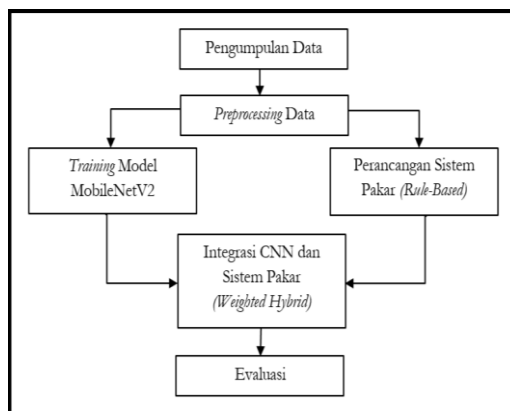
Berdasarkan sintesis literatur yang telah dilakukan, masih terdapat beberapa kesenjangan penelitian dalam pengembangan sistem skrining anemia *non-invasif*. Sebagian besar penelitian menggunakan pendekatan *single-modality*, baik berbasis citra konjungtiva maupun gejala klinis secara terpisah, sehingga pemanfaatan informasi visual dan klinis secara simultan belum optimal. Selain itu, belum ditemukan penelitian yang khusus mengintegrasikan CNN MobileNetV2 dan *Expert System* berbasis aturan klinis dengan metode *weighted hybrid decision fusion* dalam satu skrining anemia berbasis *web*.

Oleh karena itu, penelitian ini mengusulkan sistem Hybrid AI yang menggabungkan analisis citra konjungtiva menggunakan CNN MobileNetV2 dan

analisis gejala klinis menggunakan *Expert System*, kemudian mengintegrasikan keduanya melalui metode *weighted hybrid decision fusion*. Kebaruan penelitian ini terletak pada integrasi simultan informasi visual yang bersifat objektif dan informasi klinis yang bersifat subjektif dalam satu platform *web* mandiri untuk mendukung skrining anemia *non-invasif*. Kontribusi penelitian ini mencakup pengembangan pendekatan *hybrid decision fusion* untuk meningkatkan kualitas keputusan serta penyediaan sistem skrining yang mudah diakses, khususnya pada wilayah dengan keterbatasan fasilitas kesehatan.

3. Metodologi Penelitian

Penelitian ini menerapkan pendekatan eksperimental (*experimental research*) dengan tujuan mengembangkan dan mengevaluasi sistem skrining risiko anemia *non-invasif* berbasis kecerdasan buatan. Pendekatan ini dipilih karena memungkinkan pengujian kinerja model secara terukur melalui proses pelatihan, pengujian, dan evaluasi terhadap data citra konjungtiva serta gejala klinis pengguna. Metode ini relevan dengan tujuan penelitian untuk menghasilkan sistem skrining yang mampu mengidentifikasi risiko anemia secara lebih akurat melalui integrasi model *Convolutional Neural Network* (CNN) dan sistem pakar. Tahapan penelitian ini disajikan pada Gambar 1.



Gambar 1. Alur Tahapan Penelitian

Rancangan studi ini terdiri atas enam tahapan inti, meliputi pengumpulan data, praproses citra, pelatihan model MobileNetV2, pembangunan sistem pakar berbasis aturan, integrasi kedua metode menggunakan pendekatan *weighted hybrid*, serta evaluasi performa sistem. Kerangka penelitian didasarkan pada konsep penggabungan informasi visual dari citra konjungtiva dan informasi klinis dari gejala pengguna untuk meningkatkan kualitas keputusan skrining anemia.

3.1 Pengumpulan Data

Sumber data dalam penelitian ini terdiri atas data sekunder dan data primer. Data sekunder berupa citra konjungtiva mata dengan label anemia dan *non-anemia* yang

diperoleh dari *platform* Roboflow serta penelitian sebelumnya. Citra tersebut telah melalui proses seleksi dan *cropping* sehingga hanya menampilkan area konjungtiva. Oleh karena itu, pada data sekunder *preprocessing* hanya berupa *resizing* dan data *augmentation*. Total pada data pelatihan sebanyak 3.870 citra, terdiri atas 1.970 citra anemia dan 1.900 citra *non-anemia*, dengan komposisi 80% untuk pelatihan dan 20% untuk validasi.

Sementara itu, data primer berupa 50 citra konjungtiva dan data gejala klinis yang dikumpulkan langsung dari responden menggunakan kamera *smartphone* dan kuesioner. Berbeda dengan data pelatihan, citra pada data primer masih berupa citra mentah sehingga memerlukan tahap *preprocessing* tambahan berupa *cropping*, segmentasi HSV dan GrabCut sebelum digunakan pada proses klasifikasi. Seluruh responden pada data primer telah menjalani pemeriksaan kadar hemoglobin (Hb) sehingga dimanfaatkan untuk validasi pada data uji.

3.2 Preprocessing Citra

Tahap *Preprocessing* dilakukan guna memastikan bahwa data sesuai digunakan pada proses klasifikasi berbasis *deep learning* (Agmalario et al., 2023). Pada penelitian ini, tahap *preprocessing* dilakukan pada data latih dan data uji. Karena citra konjungtiva dari Roboflow dan penelitian sebelumnya sudah dalam bentuk *cropping*, maka *preprocessing* pada data latih hanya mencakup *resizing* dengan ukuran 224×224 piksel yang merupakan proses penyesuaian ukuran citra ke dimensi tertentu agar sesuai dengan kebutuhan input model sebagai input model MobileNetV2, serta *data augmentation* yang meliputi rotasi, pergeseran, *zoom*, *flipping*, perubahan kecerahan, dan *shear* untuk meningkatkan variasi data serta ketahanan model terhadap data baru (Sardika & Widhiarso, 2025).

Berbeda dengan data latih, data uji yang diperoleh dari kamera *smartphone* masih berupa citra mentah sehingga memerlukan *preprocessing* tambahan. Tahap awal dilakukan *cropping* pada area mata untuk memfokuskan *region of interest*, kemudian dilanjutkan dengan transformasi warna menggunakan ruang HSV (*Hue*, *Saturation*, *Value*) untuk mengurangi pengaruh pencahayaan. Selanjutnya, metode GrabCut digunakan untuk memisahkan area konjungtiva dari latar belakang guna meningkatkan kejelasan area yang dianalisis sebelum proses ekstraksi fitur (Zhao et al., 2023), sebagaimana terlihat pada Gambar 2.



Gambar 2. Segmentasi Citra Konjungtiva Menggunakan HSV dan GrabCut

3.3 Training Model MobileNetV2

MobileNetV2 digunakan sebagai arsitektur *Convolutional Neural Network* (CNN) untuk proses identifikasi citra konjungtiva menjadi kelas anemia dan *non-anemia* karena memiliki kompleksitas komputasi yang rendah namun tetap menghasilkan performa klasifikasi yang baik (Ilmadina et al., 2025). *Input* citra berukuran 224×224 piksel digunakan dengan penerapan *transfer learning* berbasis bobot *pretrained ImageNet* untuk mempercepat proses pembelajaran. Model ini diperluas dengan lapisan *Global Average Pooling*, *Batch Normalization*, dan *Dense layer* dengan 128 *neuron* beraktivasi *ReLU*, *dropout* 0,3, serta lapisan *output* dengan aktivasi *sigmoid* untuk klasifikasi biner. Sebagian lapisan awal MobileNetV2 dibekukan (*freeze*), sementara lapisan akhir dilakukan *fine-tuning* agar model dapat menyesuaikan karakteristik data pada penelitian ini.

Proses pelatihan menggunakan optimasi Adam dengan *learning rate* 0,00003, *batch size* 32, dan maksimal 50 *epoch*. Untuk meningkatkan stabilitas, diterapkan *EarlyStopping* dan *ReduceLRonPlateau* sehingga proses *training* otomatis dihentikan ketika tidak terdapat peningkatan kinerja pada data validasi. Pelatihan dilakukan sebanyak lima kali dengan *random seed* berbeda, dan model terbaik dipilih sebagai model akhir. MobileNetV2 juga menggunakan pendekatan *depthwise separable convolution* yang memisahkan proses ekstraksi fitur dan penggabungan kanal menjadi operasi *depthwise* dan *pointwise*, sehingga lebih efisien dibandingkan konvolusi konvensional (Rajendra & Wardhana, 2025).

3.4 Sistem Pakar (Rule-Based)

Dalam penelitian ini, sistem pakar digunakan sebagai komponen pendukung keputusan untuk melengkapi hasil klasifikasi citra sehingga proses skrining risiko anemia menjadi lebih komprehensif. Metode yang digunakan adalah *weighted rule-based expert system*, yaitu sistem berbasis aturan yang memberikan bobot pada setiap gejala berdasarkan tingkat pengaruhnya (Mustafa et al., 2023). Setiap gejala memiliki kontribusi yang berbeda, sehingga gejala yang lebih dominan diberikan bobot lebih tinggi (Wahyudi et al., 2025). *Input* sistem diperoleh dari kuesioner gejala anemia yang disusun berdasarkan literatur medis dan divalidasi melalui konsultasi dengan tenaga kesehatan, kemudian diisi secara mandiri oleh pengguna. Setiap gejala direpresentasikan dalam bentuk biner, yaitu bernilai 1 jika gejala dialami dan 0 jika tidak dialami. Keputusan akhir diperoleh dengan menjumlahkan seluruh bobot gejala yang dipilih oleh pengguna. Berikut aturan sistem pakar direpresentasikan dalam bentuk *IF-THEN* sebagai berikut.

- *IF* kelelahan atau lemas *THEN* anemia (20%)
- *IF* pusing *THEN* anemia (20%)
- *IF* mengantuk atau kurang bertenaga *THEN* anemia (10%)
- *IF* sesak napas ringan saat aktivitas *THEN* anemia (10%)
- *IF* jantung berdebar *THEN* anemia (10%)
- *IF* sakit kepala *THEN* anemia (10%)

- *IF* sulit berkonsentrasi THEN anemia (10%)
- *IF* tangan atau kaki terasa dingin THEN anemia (10%)

Proses penentuan risiko dilakukan dengan menjumlahkan seluruh bobot gejala yang dipilih oleh pengguna, kemudian dihitung sebagai skor total sistem pakar. Perhitungan skor sistem pakar ditunjukkan pada Persamaan (1).

$$\text{Score} = \sum_{i=1}^n w_i \cdot x_i \quad (1)$$

Keterangan:

- w_i = Bobot Gejala ke - i
- x_i = Nilai gejala (1 = Ya, 0 = Tidak)
- n = Jumlah Gejala

Skor yang diperoleh kemudian dibandingkan dengan nilai ambang (*threshold*) untuk menentukan keputusan skrining. Jika total skor > 50 , maka pengguna dikategorikan berisiko anemia, sedangkan jika ≤ 50 maka tidak berisiko anemia. Nilai ambang 50 digunakan karena merepresentasikan lebih dari setengah total bobot gejala yang tersedia, sehingga dapat membedakan kedua kondisi secara sederhana. Penggunaan *threshold* ini bertujuan untuk menyederhanakan proses klasifikasi berbasis bobot gejala agar hasil lebih mudah diinterpretasikan, konsisten, serta memberikan batas keputusan yang jelas dalam sistem pakar berbasis aturan. (Wahyudi et al., 2025).

3.5 Hybrid CNN and Sistem Pakar

Dalam penelitian ini, hasil klasifikasi citra konjungtiva menggunakan CNN diintegrasikan dengan analisis gejala dari sistem pakar untuk menghasilkan keputusan skrining anemia yang lebih komprehensif. Integrasi dilakukan menggunakan metode *weighted hybrid*, yaitu pendekatan yang menggabungkan probabilitas keluaran kedua metode dengan pemberian bobot tertentu untuk memperoleh keputusan yang lebih optimal [12]. Probabilitas CNN dan sistem pakar digabungkan dengan pembobotan 60% untuk CNN dan 40% untuk sistem pakar yang ditetapkan secara empiris dengan memberikan bobot lebih besar pada hasil klasifikasi citra karena merepresentasikan kondisi fisiologis secara langsung, sedangkan sistem pakar digunakan sebagai informasi pendukung gejala klinis. Perhitungan kombinasi ini ditunjukkan pada Persamaan (2).

$$P_{\text{final}} = (0,6 \times P_{\text{cnn}}) + (0,4 \times P_{\text{expert}}) \quad (2)$$

Keterangan:

- P_{final} = Nilai probabilitas akhir hasil penggabungan (*weighted hybrid*)
- P_{cnn} = Probabilitas hasil klasifikasi dari model *Convolutional Neural Network*
- P_{pakar} = Probabilitas hasil analisis dari sistem pakar

Hasil probabilitas akhir kemudian dibandingkan dengan nilai ambang 0,5. *If* $P_{\text{final}} > 0.5$, maka dikategorikan berisiko anemia, sedangkan *if* $P_{\text{final}} \leq 0.5$, maka

dikategorikan *non-anemia*. Pendekatan ini digunakan untuk meningkatkan kestabilan keputusan dengan menggabungkan informasi citra dan gejala klinis pengguna.

3.6 Evaluasi

Untuk menentukan efektivitas skrining, model *Convolutional Neural Network* (CNN), sistem pakar, serta pendekatan *hybrid* dievaluasi menggunakan data citra konjungtiva. Evaluasi dilakukan menggunakan data uji yang terdiri atas sampel anemia dan *non-anemia* dengan menerapkan *confusion matrix*. Hasil klasifikasi dianalisis melalui *confusion matrix* yang membandingkan hasil prediksi dengan label sebenarnya berdasarkan *true positive* (TP), *true negative* (TN), *false positive* (FP), dan *false negative* (FN) (Arian et al., 2026). Bentuk *confusion matrix* yang digunakan dalam tahap evaluasi disajikan pada Tabel 2.

Tabel 2. Evaluasi Model Klasifikasi Menggunakan *Confusion Matrix*

	Actually Positive	Actually Negative
Predicted Positive	<i>True Positive</i>	<i>False Positive</i>
Predicted Negative	<i>False Negative</i>	<i>True Negative</i>

Keterangan:

True Positive (TP) : Sampel positif yang terklasifikasi benar sebagai positif.

False Positive (FP) : Sampel negatif yang salah terklasifikasi sebagai positif.

True Negative (TN) : Sampel negatif yang terklasifikasi benar sebagai negatif.

False Negative (FN) : Sampel positif yang salah terklasifikasi sebagai negatif.

Berdasarkan *confusion matrix* tersebut, digunakan beberapa metrik evaluasi.

1. *Accuracy* digunakan untuk menilai tingkat keberhasilan model dalam memberikan prediksi yang sesuai pada keseluruhan sampel.

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \tag{3}$$

2. *Sensitivity (recall)* digunakan untuk mengukur kemampuan model untuk mengidentifikasi sampel positif secara tepat.

$$Sensitivity = \frac{TP}{TP+FN} \tag{4}$$

3. *Precision* merupakan metrik yang digunakan untuk menilai seberapa tepat model dalam memberikan prediksi pada kelas positif.

$$Precision = \frac{TP}{TP+FP} \tag{5}$$

4. *F1-score* merupakan metrik yang digunakan untuk mengevaluasi keseimbangan antara *precision* dan *sensitivity (recall)* dalam menilai kinerja model.

$$F1-Score = 2 \times \frac{Precision \times Sensitivity}{Precision + Sensitivity} \tag{6}$$

Untuk meningkatkan reliabilitas hasil, proses pelatihan model dilakukan sebanyak lima kali menggunakan *random seed* yang berbeda. Model dengan performa validasi terbaik dipilih sebagai model akhir. Validasi sistem dilakukan menggunakan data uji yang telah memiliki label berdasarkan hasil pemeriksaan kadar hemoglobin (Hb), sehingga hasil prediksi dapat dibandingkan dengan kondisi sebenarnya.

4. Hasil dan Pembahasan

Bagian ini menyajikan temuan dari hasil pengujian sistem skrining anemia *non-invasif* yang mencakup performa model *Convolutional Neural Network* (CNN) berbasis MobileNetV2, evaluasi sistem pakar berbasis aturan, serta integrasi keduanya menggunakan pendekatan *weighted hybrid*. Pengujian dilakukan menggunakan 50 citra konjungtiva dari kamera *smartphone* yang terdiri atas 19 sampel anemia dan 31 sampel *non-anemia* untuk merepresentasikan kondisi nyata di lapangan.


4.1 Hasil MobilenetV2

Data citra yang telah melalui *preprocessing* dan augmentasi digunakan untuk melatih model MobileNetV2. Untuk mengurangi pengaruh variasi inisialisasi bobot awal, pelatihan dilakukan sebanyak lima kali dengan *random seed* berbeda. Hasil akurasi validasi setiap percobaan yang disajikan pada Tabel 3.

Tabel 3. Hasil Akurasi Validasi MobileNetV2 pada Pelatihan *Multi-Run*

<i>Run</i>	<i>Validation Accuracy</i>
<i>Run 1</i>	0,9638
<i>Run 2</i>	0,9689
<i>Run 3</i>	0,9754
<i>Run 4</i>	0,9638
<i>Run 5</i>	0,9547
<i>Mean</i>	0.9654
<i>Standard Deviation</i>	0.0068

Berdasarkan hasil tersebut, model pada Run 3 menghasilkan performa terbaik dengan akurasi 0,9754 dan dipilih sebagai model akhir. Rata-rata akurasi 0,9654 dengan standar deviasi rendah menunjukkan bahwa model memiliki stabilitas pembelajaran yang baik. Stabilitas ini menunjukkan bahwa MobileNetV2 mampu menangkap fitur penting dari citra konjungtiva secara konsisten. Hal ini terjadi karena kombinasi transfer learning dan data augmentation membantu model belajar fitur yang lebih general, sehingga tidak terlalu bergantung pada data pelatihan tertentu. Dengan demikian, model lebih tahan terhadap variasi data uji. Jika dibandingkan dengan penelitian (Purwanti et al., 2023) hasil ini masih konsisten dan mendukung temuan bahwa MobileNetV2 efektif untuk klasifikasi citra medis, khususnya pada deteksi anemia berbasis konjungtiva.



Gambar 3. Grafik Akurasi dan *Loss* Pelatihan dan Validasi Model MobileNetV2 Terbaik (Run 3)

Berdasarkan visualisasi pada Gambar 3, Nilai akurasi pada data pelatihan maupun validasi mengalami peningkatan secara bertahap hingga mencapai kondisi stabil, sementara nilai *loss* mengalami penurunan secara konsisten. Pola ini menunjukkan bahwa model *MobileNetV2* mampu melakukan proses pembelajaran secara efektif dalam mengenali karakteristik citra konjungtiva. Kondisi tersebut juga mengindikasikan bahwa proses pelatihan berjalan dengan baik tanpa adanya indikasi *overfitting* yang signifikan, sehingga menunjukkan bahwa model memiliki generalisasi yang baik pada data validasi.

Stabilnya kurva akurasi dan penurunan *loss* tersebut dipengaruhi oleh penerapan *transfer learning* serta *data augmentation* yang membantu model dalam mempelajari variasi data secara lebih luas. Dengan demikian, model tidak hanya menyesuaikan terhadap data pelatihan, tetapi juga mampu mempertahankan performa pada data yang sebelumnya belum pernah digunakan. Selanjutnya, evaluasi kinerja klasifikasi dilakukan menggunakan *confusion matrix* untuk menilai kemampuan model dalam mengelompokkan data secara lebih rinci, sebagaimana ditunjukkan pada Gambar 4.

	precision	recall	f1-score	support
non-anemia	0.91	1.00	0.95	31
anemia	1.00	0.84	0.91	19
accuracy			0.94	50
macro avg	0.96	0.92	0.93	50
weighted avg	0.95	0.94	0.94	50

Gambar 4. *Confusion Matrix* Hasil Klasifikasi Menggunakan MobileNetV2

Berdasarkan hasil *confusion matrix*, model berhasil mengklasifikasikan dengan benar 31 sampel *non-anemia* dan 16 sampel anemia. Selain itu, terdapat 3 sampel anemia yang salah diprediksi sebagai *non-anemia* (*false negative*). Secara keseluruhan, model MobileNetV2 memperoleh *accuracy* sebesar 0,94, *precision* sebesar 1,00, *recall* sebesar 0,84, dan *F1-score* sebesar 0,91 pada kelas anemia. Hasil tersebut menunjukkan bahwa sebagian besar kasus anemia berhasil dikenali oleh model, meskipun masih terdapat sejumlah kecil kasus yang belum terdeteksi.

Hasil tersebut menunjukkan bahwa MobileNetV2 mampu mengidentifikasi sebagian besar kasus anemia dengan baik. Namun, keberadaan beberapa *false negative* mengindikasikan bahwa masih terdapat kasus anemia yang belum terdeteksi sehingga pengembangan lebih lanjut diperlukan untuk meningkatkan sensitivitas model. Hasil pengujian menunjukkan bahwa pendekatan berbasis *Convolutional Neural Network* (CNN), khususnya MobileNetV2, efektif dalam mengenali pola visual pada citra yang berhubungan dengan anemia. Kemampuan tersebut dipengaruhi oleh MobileNetV2 yang ringan dan efisien, namun tetap mampu menghasilkan klasifikasi yang benar.

Hasil tersebut sejalan dengan studi terdahulu yang melaporkan bahwa MobileNetV2 menunjukkan kinerja yang tinggi pada tugas klasifikasi citra medis, termasuk deteksi anemia berbasis citra konjungtiva (Ilmadina et al., 2025). Namun demikian, variasi performa model masih dapat dipengaruhi oleh kualitas citra, jumlah data, karakteristik responden, serta tahapan *preprocessing* dan augmentasi yang diterapkan dalam penelitian.

4.2 Evaluasi Hasil Sistem Pakar *Rule Based*

Pengujian sistem pakar dilakukan menggunakan input gejala anemia yang diisi oleh pengguna melalui kuesioner. Sistem kemudian menghitung total bobot gejala untuk menentukan tingkat risiko anemia berdasarkan pendekatan *weighted rule-based expert system*. Evaluasi dilakukan menggunakan 50 sampel data uji untuk menilai kemampuan sistem dalam mengidentifikasi kondisi anemia dan *non-anemia*. Hasil evaluasi menggunakan *confusion matrix* ditunjukkan pada Gambar 5.

	precision	recall	f1-score	support
Non-Anemia	0.93	0.90	0.92	31
Anemia	0.85	0.89	0.87	19
accuracy			0.90	50
macro avg	0.89	0.90	0.89	50
weighted avg	0.90	0.90	0.90	50

Gambar 5. *Confusion Matrix* Hasil Klasifikasi Menggunakan Sistem Pakar *Rule Based*

Berdasarkan *confusion matrix*, sistem pakar mampu mengklasifikasikan dengan benar 28 sampel *non-anemia* dan 17 sampel anemia. Namun, terdapat 3 sampel *non-anemia* yang keliru diklasifikasikan sebagai anemia (*false positive*) serta 2 sampel anemia yang keliru diklasifikasikan sebagai *non-anemia* (*false negative*). Secara keseluruhan, sistem pakar menghasilkan *accuracy* sebesar 0,90, *precision* 0,85, *recall* 0,89, dan *F1-score* 0,87 pada kelas anemia. Hasil ini menunjukkan bahwa sistem memiliki kemampuan yang cukup baik dalam mengidentifikasi kasus anemia, meskipun masih terdapat sejumlah kesalahan klasifikasi.

Performa tersebut menunjukkan bahwa sistem pakar berbasis aturan cukup efektif digunakan untuk skrining awal anemia melalui analisis gejala klinis. Hal ini didukung oleh mekanisme inferensi *IF-THEN* dan pembobotan gejala yang memungkinkan keputusan didasarkan pada tingkat kontribusi setiap gejala. Namun demikian, hasil sistem masih dapat dipengaruhi oleh subjektivitas pengguna dalam mengisi kuesioner. Temuan ini sejalan dengan (Maulina et al., 2023) yang menyatakan bahwa sistem pakar berbasis gejala memiliki keterbatasan pada aspek subjektivitas input, meskipun tetap relevan sebagai metode skrining awal.

4.3 Hasil *Hybrid CNN* dan Sistem Pakar

Metode *weighted hybrid* digunakan untuk mengintegrasikan probabilitas prediksi dari model *Convolutional Neural Network* (CNN) dan sistem pakar guna menghasilkan keputusan skrining risiko anemia yang lebih komprehensif. Integrasi dilakukan dengan menggabungkan informasi citra konjungtiva dan gejala klinis pengguna melalui skema pembobotan. Berdasarkan Tabel 4, hasil prediksi *hybrid* meliputi probabilitas CNN, probabilitas sistem pakar, probabilitas akhir hasil penggabungan, serta keputusan klasifikasi. Kombinasi kedua metode ini diharapkan menghasilkan keputusan skrining yang lebih stabil dan relevan.

Tabel 4. Hasil Prediksi Sampel Menggunakan *Hybrid CNN* dan Sistem Pakar

Id	Label Asli	CNN Prob	Expert Prob	Hybrid Prob	Prediksi Hybrid	Confidence
R01	anemia	0.9725	0.7000	0.8635	anemia	0.8635
R02	anemia	0.9015	0.8000	0.8609	anemia	0.8609
R03	<i>non-anemia</i>	0.0049	0.2000	0.0829	<i>non-anemia</i>	0.9171
R04	<i>non-anemia</i>	0.0009	0.2000	0.0805	<i>non-anemia</i>	0.9195
R05	anemia	0.0072	0.7000	0.2843	<i>non-anemia</i>	0.7157

Berdasarkan hasil pada Tabel 4 metode *weighted hybrid* mampu menghasilkan keputusan skrining dengan menggabungkan probabilitas anemia dari model *Convolutional Neural Network* (CNN) dan sistem pakar. Pada beberapa kasus, penggabungan kedua metode membantu meningkatkan ketepatan prediksi karena informasi citra konjungtiva dan gejala klinis saling melengkapi dalam proses pengambilan keputusan.

Hasil klasifikasi akhir dipengaruhi oleh kombinasi probabilitas dari CNN dan sistem pakar, sehingga keputusan *hybrid* mencerminkan kontribusi kedua pendekatan dalam proses skrining risiko anemia. Dengan demikian, pendekatan ini tidak hanya mempertimbangkan pola visual pada citra, tetapi juga kondisi klinis pengguna untuk menghasilkan keputusan yang lebih komprehensif. Selanjutnya, metode *hybrid* dievaluasi menggunakan *confusion matrix* sebagaimana disajikan pada Gambar 6.

=== CLASSIFICATION REPORT HYBRID ===				
	precision	recall	f1-score	support
non-anemia	0.94	1.00	0.97	31
anemia	1.00	0.89	0.94	19
accuracy			0.96	50
macro avg	0.97	0.95	0.96	50
weighted avg	0.96	0.96	0.96	50

Gambar 6. *Confusion Matrix* Hasil Klasifikasi Menggunakan *Hybrid MobileNetV2* dan Sistem Pakar

Berdasarkan hasil *confusion matrix*, metode *weighted hybrid* berhasil mengklasifikasikan dengan benar 31 sampel *non-anemia* dan 17 sampel anemia, sementara terdapat 2 sampel anemia yang salah diprediksi sebagai *non-anemia* (*false negative*). Hasil evaluasi menunjukkan bahwa metode *weighted hybrid* memperoleh *accuracy* sebesar 0,96, *precision* sebesar 1,00, *recall* sebesar 0,89, dan *F1-score* sebesar 0,94 pada kelas anemia.

Tabel 5. Perbandingan Performa Metode Skrining Anemia

Metode	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
MobileNetV2	0,94	1,00	0,84	0,91
Sistem Pakar	0,90	0,85	0,89	0,87
<i>Weighted Hybrid</i>	0,96	1,00	0,89	0,94

Berdasarkan Tabel 5, metode *weighted hybrid* menunjukkan performa terbaik dibandingkan MobileNetV2 dan sistem pakar secara terpisah. Integrasi informasi visual dari citra konjungtiva dan gejala klinis pengguna mampu meningkatkan kualitas klasifikasi sehingga menghasilkan nilai *accuracy* dan *F1-score* yang lebih tinggi. Selain itu, metode *hybrid* mampu mempertahankan tingkat *precision* yang sangat baik serta menghasilkan *recall* yang lebih tinggi dibandingkan model CNN tunggal. Hasil tersebut menunjukkan bahwa kombinasi kedua pendekatan dapat mengurangi keterbatasan masing-masing metode dan menghasilkan keputusan skrining yang lebih andal. Dengan demikian, pendekatan *weighted hybrid* mampu memberikan hasil skrining yang lebih komprehensif dibandingkan penggunaan metode tunggal.

4.4 Diskusi dan Pengembangan Penelitian

Hasil penelitian menunjukkan bahwa pendekatan *Convolutional Neural Network* (CNN) berbasis MobileNetV2 memiliki performa yang baik dalam mengklasifikasikan citra konjungtiva dengan tingkat akurasi yang tinggi dan konsisten pada beberapa percobaan pelatihan. Hal ini menunjukkan bahwa fitur visual pada area konjungtiva mengandung informasi yang cukup kuat untuk mendeteksi indikasi anemia. Sistem

pakar berbasis aturan (*rule-based expert system*) juga mampu memberikan hasil yang cukup baik, namun masih dipengaruhi oleh subjektivitas pengguna dalam pengisian kuesioner sehingga dapat menyebabkan variasi pada hasil prediksi.

Pendekatan *weighted hybrid* yang menggabungkan CNN dan sistem pakar terbukti mampu meningkatkan performa skrining secara keseluruhan dibandingkan masing-masing metode secara terpisah. Integrasi ini memungkinkan sistem memanfaatkan keunggulan tiap pendekatan, yaitu objektivitas citra dari CNN dan informasi klinis dari gejala pengguna. Secara teori, hasil ini sejalan dengan konsep *ensemble learning* yang menyatakan penggabungan beberapa model dapat meningkatkan stabilitas dan akurasi.

Namun demikian, studi ini tetap memiliki sejumlah keterbatasan. Pertama, jumlah data uji masih relatif kecil yaitu 50 sampel, sehingga generalisasi model pada populasi yang lebih luas, masih diperlukan pengujian lanjutan. Kedua, data primer yang diperoleh melalui kamera smartphone masih dipengaruhi oleh kondisi pencahayaan dan kualitas perangkat, yang dapat memengaruhi hasil segmentasi citra. Ketiga, sistem pakar masih bergantung pada bobot gejala yang ditentukan secara manual sehingga belum sepenuhnya adaptif terhadap variasi kondisi pengguna.

Dari sisi implikasi, secara praktis sistem ini berpotensi digunakan sebagai alat skrining awal anemia *non-invasif* yang dapat diterapkan pada perangkat berbasis mobile atau *web*, sehingga membantu deteksi dini di masyarakat. Secara teoritis, penelitian ini memperkuat penerapan integrasi CNN dan sistem pakar dalam bidang kesehatan digital, khususnya pada klasifikasi berbasis multimodal data. Sementara itu, dari sisi pengembangan teknologi, pendekatan ini dapat digunakan sebagai landasan untuk pengembangan sistem skrining cerdas yang lebih kompleks di masa depan.

Untuk penelitian selanjutnya, disarankan agar jumlah dataset diperbesar dan mencakup variasi kondisi pencahayaan serta etnis yang lebih beragam untuk meningkatkan generalisasi model. Selain itu, model CNN yang lebih modern seperti EfficientNet atau Vision Transformer dapat dieksplorasi untuk meningkatkan performa klasifikasi. Pengembangan sistem pakar juga dapat diarahkan ke metode adaptif berbasis pembelajaran (*learning-based rule system*) agar tidak sepenuhnya bergantung pada bobot manual. Integrasi data multimodal tambahan seperti kadar hemoglobin estimasi atau fitur wajah juga dapat dipertimbangkan untuk meningkatkan akurasi secara keseluruhan.

5. Kesimpulan

Penelitian ini berhasil mengembangkan sistem skrining risiko anemia *non-invasif* berbasis *Hybrid Artificial Intelligence* yang mengintegrasikan analisis citra konjungtiva menggunakan *Convolutional Neural Network* (CNN) berbasis MobileNetV2 dan analisis gejala klinis menggunakan sistem pakar berbasis aturan. Hasil pengujian menunjukkan bahwa model MobileNetV2 memperoleh akurasi sebesar 94%, sistem pakar sebesar 90%, sedangkan pendekatan *weighted hybrid* menghasilkan performa terbaik dengan

accuracy 96%, *precision* 100%, *recall* 89%, dan *F1-score* 94% pada kelas anemia. Hasil tersebut menunjukkan bahwa integrasi informasi visual dan gejala klinis mampu meningkatkan performa skrining dibandingkan penggunaan pendekatan secara terpisah.

Temuan penelitian ini memberikan kontribusi pada bidang *Medical AI* dengan menunjukkan bahwa pendekatan *multimodal* yang menggabungkan data citra dan data klinis dapat menghasilkan sistem skrining yang lebih akurat, komprehensif, dan *robust* dibandingkan pendekatan *single-modality*. Selain itu, penelitian ini juga berkontribusi pada pengembangan *Clinical Decision Support System* (CDSS) melalui integrasi kemampuan pembelajaran otomatis dari CNN dan pengetahuan pakar yang direpresentasikan dalam sistem berbasis aturan. Pendekatan tersebut memperlihatkan bagaimana konsep *Hybrid Intelligence* dapat dimanfaatkan untuk menggabungkan keunggulan kecerdasan berbasis data dan kecerdasan berbasis pengetahuan dalam pengambilan keputusan kesehatan.

Secara ilmiah, penelitian ini memperkaya kajian mengenai penerapan *weighted hybrid decision fusion* pada skrining anemia *non-invasif* dengan memanfaatkan dua sumber informasi yang berbeda namun saling melengkapi. Temuan ini memperkuat bahwa integrasi data visual dan data klinis mampu meningkatkan kualitas keputusan sistem dibandingkan penggunaan satu modalitas saja. Secara praktis, sistem yang dikembangkan berpotensi digunakan sebagai alat skrining awal yang cepat, *non-invasif*, dan mudah diakses melalui *platform* berbasis *web*, sehingga dapat mendukung upaya deteksi dini anemia terutama pada wilayah dengan keterbatasan fasilitas kesehatan.

Meskipun demikian, penelitian ini masih memiliki beberapa keterbatasan, antara lain jumlah data uji yang relatif terbatas serta pengaruh variasi pencahayaan dan kualitas perangkat kamera terhadap citra konjungtiva. Oleh karena itu, penelitian selanjutnya disarankan untuk memperluas dataset dengan variasi kondisi yang lebih beragam, mengeksplorasi arsitektur yang lebih mutakhir seperti EfficientNet atau Transformer, serta mengembangkan mekanisme pembelajaran adaptif pada sistem pakar. Integrasi sumber data *multimodal* lainnya, seperti estimasi kadar hemoglobin atau parameter klinis tambahan, juga berpotensi meningkatkan akurasi dan kemampuan generalisasi sistem pada implementasi nyata.

6. Ucapan Terima Kasih

Penulis menyampaikan apresiasi kepada semua pihak yang telah mendukung terselesainya penelitian ini. Penulis juga mengucapkan terima kasih kepada dosen pembimbing atas bimbingan, arahan, dan masukan yang diberikan. Selain itu, terima kasih disampaikan kepada seluruh pihak yang telah berkontribusi hingga penelitian ini dapat diselesaikan.

7. Pernyataan Penulis

Penulis menyatakan bahwa tidak ada konflik kepentingan terkait publikasi artikel ini. Penulis menyatakan bahwa data dan makalah bebas dari plagiarisme serta penulis bertanggung jawab secara penuh atas keaslian artikel.

Bibliografi

- Agmalaro, M. A., Kusuma, W. A., Rifati, L., Andarwati, P., Suryatama, A., Aldina, R., Novita, H. D., & Sofia, O. (2023). Implementasi Pendekatan Algoritma Deep Learning CNN untuk Identifikasi Citra Pasien Keratitis. *Jurnal Ilmu Komputer Dan Agri-Informatika (JIKA)*, 10(2), 164–175. <https://doi.org/10.29244/jika.10.2.164-175>
- Ahsan, M. M., Lun, S. A., & Siddique, Z. (2022). Machine-Learning-Based Disease Diagnosis: A Comprehensive Review. *Healthcare*, 10(3), 541. <https://doi.org/10.3390/healthcare10030541>
- 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), 128–134. <https://doi.org/10.59562/metrik.v20i2.44503>
- Arian, S. A., Alifia, P. R., Prihantoro, B., Disriansyah, M. I., Tania, K. D., Meiriza, A., & Rifai, A. (2026). *Comparison of Supervised Machine Learning Classification Models in Knowledge Discovery of Pertamina Prabumulih IT Services*. 6(2), 705–715. <https://doi.org/10.57152/malcom.v6i2.2617>
- Asare, J. W., Appiahene, P., Arthur, E. J., Korankye, S., Afrifa, S., & Donkoh, E. T. (2023). Detection of anemia using conjunctiva images: A smartphone application approach. *Medicine in Novel Technology and Devices*, 18(May), 100237. <https://doi.org/10.1016/j.medntd.2023.100237>
- Askale, G. T., Yibel, A. B., Munie, A. T., & Areru, S. B. (2026). A customized MobileNetV2-based lightweight CNN for monkeypox detection and classification. *Scientific Reports*, 16, 5028. <https://doi.org/10.1038/s41598-026-35871-1>
- Azevedo, B. F., Maria, A., & Ana, A. C. R. (2024). Hybrid approaches to optimization and machine learning methods : a systematic literature review. In *Machine Learning* (Vol. 113, Issue 7). Springer US. <https://doi.org/10.1007/s10994-023-06467-x>
- Chae, J., & Kim, J. (2023). An Investigation of Transfer Learning Approaches to Overcome Limited Labeled Data in Medical Image Analysis. *Applied Sciences*, 13(15), 1–32. <https://doi.org/10.3390/app13158671>
- Chen, Y.-C., Hsu, S.-S., Liew, C. Q., Sung, C.-W., Ko, C.-H., Huang, C.-H., Cheng, M.-T., & Tsai, C.-L. (2026). Physician Gestalt for Anemia Detection in the Emergency Department : A Prospective Study. *Western Journal of Emergency Medicine*, 27(2), 337–344. <https://doi.org/10.5811/westjem.48717>
- Dasarathy, D., & Attaway, A. H. (2024). Acute blood loss anemia in hospitalized patients is associated with adverse outcomes: An analysis of the Nationwide Inpatient Sample. *The American Journal of the Medical Sciences*, 367(4), 243–250. <https://doi.org/10.1016/j.amjms.2024.01.003>
- Fan, Z., Zhou, Y., Zhai, H., Wang, Q., & He, H. (2022). A Smartphone-Based Biosensor

- for Non-Invasive Monitoring of Total Hemoglobin Concentration in Humans with High Accuracy. *Biosensors*, 12(10), 781. <https://doi.org/10.3390/bios12100781>
- Ge, X., Yao, Z., & Du, Y. (2025). Medical Priority Fusion: Achieving Dual Optimization of Sensitivity and Interpretability in NIPT Anomaly Detection. *ArXiv*. <https://doi.org/10.48550/arXiv.2509.17924>
- Gunawan, D., & Setiawan, H. (2022). Convolutional Neural Network dalam Analisis Citra Medis. *KONSTELASI: Konvergensi Teknologi Dan Sistem Informasi*, 2(2), 376–390. <https://doi.org/10.24002/konstelasi.v2i2.5367>
- Herlina, N., Oktariyani, S. D., Dharmawan, A. K., & Shariff, F. O. (2024). Hubungan Anemia pada Ibu Hamil dengan Bayi Berat Lahir Rendah (BBLR). *Jurnal Penelitian Perawat Profesional*, 6(6), 2367–2372. <https://doi.org/10.37287/jppp.v6i6.3404>
- Hosna, A., Merry, E., Gyalmo, J., Alom, Z., Aung, Z., & Azim, M. A. (2022). Transfer learning: a friendly introduction. *Journal of Big Data*, 9(1), 1–19. <https://doi.org/10.1186/s40537-022-00652-w>
- Ilmadina, H. Z., Nisa, J., Apriliani, D., Anisa, L. N., & Rakhmah, F. A. (2025). CesLA (Cegah Stunting Lewat Anemia): Deteksi Anemia Non-Invasif pada Remaja Putri Berbasis Citra Konjungtiva. *Jurnal Informatika: Jurnal Pengembangan IT*, 10(3), 717–726. <https://doi.org/10.30591/jpit.v10i3.8873>
- Liana, D., Yudhya, E., Maratis, J., Dwijayanti, F., & Fauziah, N. (2026). Analisis faktor determinan terhadap kejadian anemia pada wanita usia subur: Studi analitik. *SAGO: Gizi Dan Kesehatan*, 7(1), 253–265. <https://doi.org/10.30867/gikes.v7i1.3066>
- Magdalena, R., Saidah, S., Da'wan, I., Ubaidah, 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. <https://doi.org/10.20884/1.jutif.2022.3.2.197>
- Maulina, Y., Gunaryati, A., & Aldisa, R. T. (2023). Sistem Pakar Diagnosis Awal Penyakit Anemia Menggunakan Metode Naïve Bayes dan Certainty Factor. *STRING (Satuan Tulisan Riset Dan Inovasi Teknologi)*, 8(1), 110. <https://doi.org/10.30998/string.v8i1.16468>
- Mustafa, E. M., Saad, M. M., & Rizkallah, L. W. (2023). Building an enhanced case - based reasoning and rule - based systems for medical diagnosis. *Journal of Engineering and Applied Science*, 70, 1–12. <https://doi.org/10.1186/s44147-023-00315-4>
- Pandapotan, R. A., & Suhayanly, N. (2025). Pola Pasien Anemia yang Dirawat Inap di RS UKRIDA Tahun 2021-2023 Patterns of Anemia Patients Admitted To Ukrida Hospital In 2021-2023. *Jurnal MedScientiae*, 4(1), 54–57. <https://doi.org/10.36452/jmedscientiae.v4i1.3653>
- Papadopoulos, P., Soflano, M., Chaudy, Y., Adejo, W., & Connolly, T. M. (2022). A systematic review of technologies and standards used in the development of rule - based clinical decision support systems. *Health and Technology*, 12, 713–727. <https://doi.org/10.1007/s12553-022-00672-9>
- Priliani, L., Harahap, A. R., Satyagraha, A. W., Noviyanti, R., Apriyana, I., Nanine, I., Sudoyo, H., & Malik, S. G. (2025). Mapping anemia prevalence across Indonesia. *Asia Pacific Journal of Clinical Nutrition*, 34(3), 430–439.

- [https://doi.org/10.6133/apjcn.202506_34\(3\).0017](https://doi.org/10.6133/apjcn.202506_34(3).0017)
- Purwanti, E., Amelia, H., Winarno, Bustomi, M. A., Yatijan, M. A., & Putri, R. N. (2023). Anemia Detection Using Convolutional Neural Network Based on Palpebral Conjunctiva Images. *2023 14th International Conference on Information and Communication Technology and System, ICTS 2023*, 117–122. <https://doi.org/10.1109/ICTS58770.2023.10330869>
- Rajendra, D. F., & Wardhana, A. K. (2025). Development of MobileNetV2 for CT-Scan Lung Classification Using Transfer Learning. *Journal of Applied Informatics and Computing (JAIC)*, 9(5), 2703–2710. <https://doi.org/10.30871/jaic.v9i5.10282>
- Ramzan, M., Saeed, M. U., & Ali, G. (2024). Enhancing anemia detection through multimodal data fusion: a non-invasive approach using EHRs and conjunctiva images. *Discover Artificial Intelligence*, 4(1), 100. <https://doi.org/10.1007/s44163-024-00196-3>
- Sardika, R. P., & Widhiarso, W. (2025). Klasifikasi Otomatis Tingkat Kerusakan Retak Bangunan pada Citra Digital Menggunakan MobileNetV2 dan Augmentasi Data. *Arcitech: Journal of Computer Science and Artificial Intelligence*, 5(1), 108–124. <https://doi.org/10.29240/arcitech.v5i1.13938>
- Wahyudi, A., Gama, O., Gede, D., Divayana, H., Ngurah, I. G., & Paramartha, D. (2025). Expert judgment , limitation inference , and threshold values to optimize diagnosis in eye diseases expert system. *Asia Pacific Journal of Clinical Nutrition*, 14(1), 429–437. <https://doi.org/10.11591/eci.v14i1.8204>
- Wang, R., Jayathunge, K., Page, R., Li, H., Zhang, J. J., & Yang, X. (2024). Hybrid architecture based intelligent diagnosis assistant for GP. *BMC Medical Informatics and Decision Making*, 24, 1–12. <https://doi.org/10.1186/s12911-023-02398-8>
- Zhao, Y., Xu, Y., & B, T. W. (2023). *Image Segmentation Method Based on Grabcut and Hue-Saturation-Value Color Space Model* (Vol. 170). Springer International Publishing. https://doi.org/10.1007/978-3-031-29097-8_108
- Zheng, W., Peng, B., Wu, Y., & Gauan, L. (2025). Global , regional , and national anemia burden among women of reproductive age (15 – 49 years) from 1990 to 2021 : an analysis of the Global Burden of Disease Study 2021. *Frontiers in Nutrition*, 12, 1588496. <https://doi.org/10.3389/fnut.2025.1588496>