

Deteksi Anemia Menggunakan Citra Konjungtiva Mata Berbasis Convolutional Neural Network (CNN)

Reza Aditya Pratama^{*1}, Nur Latifah Dwi Mutiara Sari²

^{1,2} Program Studi Informatika, Universitas Persatuan Guru Republik Indonesia Semarang, Kota Semarang

*Email: rezaaditya9132@gmail.com¹

Abstract.

Anemia is a relatively common medical condition, yet it is often overlooked despite its potentially serious consequences if left undetected. In this study, I aimed to address this issue by developing an anemia detection system powered by machine learning. The proposed method utilizes a Convolutional Neural Network (CNN) designed to classify anemia conditions based on images of the eye conjunctiva. The dataset consists of labeled conjunctival images categorized as either anemic or non-anemic. The model development process includes several stages, such as preprocessing, data augmentation, and training using an efficient and lightweight CNN architecture. Evaluation results indicate that the model can accurately and automatically detect anemia from images. These findings highlight the potential of computer vision technology as a fast, non-invasive, and practical tool to support early screening of anemia through visual analysis.

Keywords: anemia, convolutional neural network, eye conjunctiva, machine learning, image classification.

Abstrak

Anemia adalah kondisi yang cukup umum namun sering kali terabaikan, padahal dapat berdampak serius terhadap kesehatan jika tidak dikenali lebih awal. Dalam penelitian ini, saya mencoba menjawab tantangan tersebut dengan mengembangkan sistem deteksi anemia berbasis *machine learning*. Metode yang digunakan adalah *Convolutional Neural Network* (CNN), yang dirancang untuk mengklasifikasikan kondisi anemia melalui citra konjungtiva mata. Dataset yang digunakan terdiri dari gambar konjungtiva yang telah diberi label sebagai anemia dan non-anemia. Model dikembangkan melalui beberapa tahapan, mulai dari *preprocessing*, augmentasi data, hingga pelatihan dengan arsitektur CNN yang ringan dan efisien. Hasil evaluasi menunjukkan bahwa model ini mampu mendeteksi anemia secara otomatis dari gambar dengan akurasi yang baik. Temuan ini menunjukkan potensi penggunaan teknologi *computer vision* sebagai alat bantu diagnosis non-invasif yang cepat, praktis, dan mudah diterapkan dalam proses skrining awal anemia secara visual.

Kata kunci: anemia, *convolutional neural network*, konjungtiva mata, *machine learning*, klasifikasi citra.

1. Pendahuluan

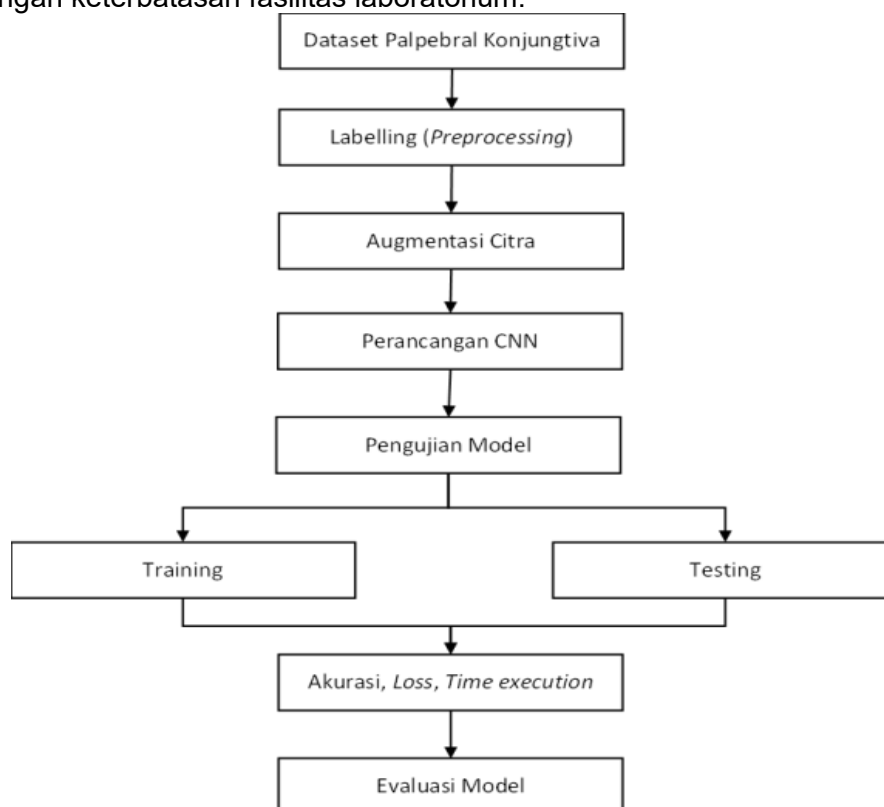
Anemia adalah kondisi yang sering kali luput dari perhatian, padahal dampaknya bisa sangat mengganggu kualitas hidup seseorang. Gejala seperti mudah lelah, wajah pucat, atau sering pusing sering dianggap sepele, padahal bisa menjadi tanda bahwa tubuh kekurangan hemoglobin zat penting dalam darah yang berfungsi mengangkut oksigen ke seluruh tubuh. Sayangnya, untuk memastikan apakah seseorang mengalami anemia, dibutuhkan pemeriksaan darah di laboratorium, yang tidak selalu mudah diakses oleh semua orang, terutama di daerah terpencil atau dengan fasilitas kesehatan terbatas. Melihat tantangan tersebut, teknologi hadir sebagai solusi. Perkembangan *machine learning* dalam dunia medis telah membuka peluang baru untuk mendeteksi penyakit dengan cara yang lebih cepat, murah, dan tidak menyakitkan. Salah satu pendekatan menarik adalah dengan menganalisis

warna dan kondisi konjungtiva mata lapisan bening di bagian dalam kelopak dan putih mata yang bisa mencerminkan kadar hemoglobin seseorang. Mata yang tampak pucat, misalnya, bisa menjadi sinyal awal adanya anemia.

Penelitian ini mengembangkan sistem pendeteksi anemia otomatis menggunakan metode *Convolutional Neural Network* (CNN), sebuah teknik *deep learning* yang terbukti efektif dalam pengenalan gambar. Sistem ini dilatih menggunakan kumpulan gambar konjungtiva mata yang sudah diberi label sesuai kondisi medisnya. Uniknya, model ini tidak hanya dikembangkan untuk keperluan laboratorium atau klinik, tetapi juga akan diintegrasikan ke dalam aplikasi mobile berbasis Android. Dengan begitu, siapa pun dapat melakukan pemeriksaan awal secara mandiri hanya dengan memotret mata mereka melalui kamera ponsel. Harapannya, teknologi ini bisa menjadi langkah awal yang sederhana namun bermakna dalam membantu deteksi dini anemia, terutama di tempat-tempat yang akses medisnya masih terbatas.

2. Metode

Penelitian ini berupaya menjawab pertanyaan: bagaimana mendeteksi anemia secara non-invasif hanya melalui citra konjungtiva mata? Untuk itu, pendekatan yang digunakan berfokus pada pemanfaatan teknik *machine learning*, khususnya *Convolutional Neural Network* (CNN), guna mengenali pola-pola visual pada mata yang berkaitan dengan kondisi anemia. Metode ini dirancang agar mudah direplikasi dan diimplementasikan secara praktis dalam bentuk aplikasi berbasis web, sehingga dapat diakses lebih luas, termasuk di lingkungan dengan keterbatasan fasilitas laboratorium.



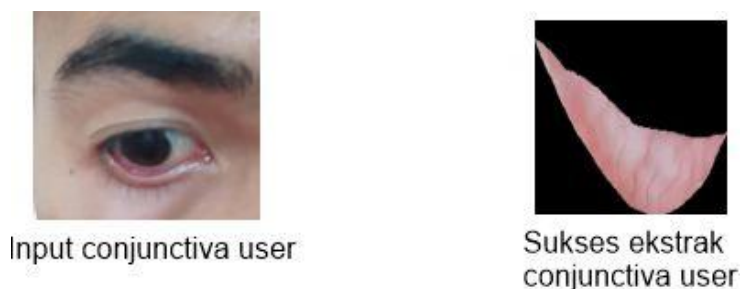
Gambar. 1. Langkah Langkah Penelitian

2.1. Pengumpulan Data

Langkah pertama adalah mengumpulkan citra konjungtiva mata dari berbagai sumber, baik dari basis data terbuka maupun dokumentasi langsung yang dilakukan dengan persetujuan dan protokol etis. Citra-citra tersebut diberi label berdasarkan hasil diagnosis anemia atau non-anemia.

2.2. Pra-pemrosesan Citra

Agar gambar dapat dibaca oleh sistem dengan optimal, dilakukan beberapa tahapan pra-pemrosesan. Gambar diubah ukurannya menjadi 224×224 piksel, distandarkan nilai pikselnya (normalisasi), dan dilakukan augmentasi seperti rotasi atau pencahayaan acak untuk meningkatkan variasi data serta mencegah overfitting saat pelatihan model.



Gambar. 2. Conjunctiva Ekstrak

2.3. Pelatihan Model CNN

Model CNN yang digunakan adalah arsitektur MobileNetV2 yang ringan namun efektif dalam mengenali pola visual. Model ini dilatih untuk membedakan antara citra konjungtiva penderita anemia dan yang tidak. Proses pelatihan melibatkan ratusan hingga ribuan iterasi dengan data yang telah disiapkan, sehingga sistem mampu “belajar” dari contoh-contoh yang diberikan.

2.4. Evaluasi Model

Setelah model selesai dilatih, dilakukan evaluasi dengan metrik seperti akurasi, presisi, recall, dan F1-score untuk mengetahui seberapa baik model mampu mengenali anemia dari gambar mata. Evaluasi ini penting untuk memastikan bahwa sistem yang dibangun bukan hanya canggih, tapi juga akurat dan dapat diandalkan.

2.5. Konversi Model dan Integrasi Web

Model yang telah dilatih kemudian dikonversi ke format yang lebih ringan, seperti TensorFlow.js atau ONNX, agar dapat diintegrasikan ke dalam platform berbasis web. Tujuannya adalah agar sistem deteksi anemia ini dapat diakses dengan mudah melalui peramban (browser), tanpa perlu instalasi perangkat khusus. Pada tahap akhir, dilakukan validasi dengan data nyata untuk memastikan konsistensi hasil prediksi terhadap label medis yang sebenarnya.

3. Hasil dan Pembahasan

3.1. Arsitektur Model

Model yang digunakan dalam penelitian ini dibangun dengan pendekatan *transfer learning*, di mana arsitektur MobileNetV2 dimanfaatkan sebagai *feature extractor* utama. Pada tahap awal pelatihan, lapisan-lapisan awal dari MobileNetV2 dibekukan (*freeze*) untuk mempertahankan bobot yang telah dilatih sebelumnya dari dataset berskala besar. Pendekatan ini memungkinkan sistem fokus pada pembelajaran pola-pola visual spesifik dari citra konjungtiva tanpa harus mempelajari ulang fitur-fitur dasar dari awal. Setelah itu, beberapa lapisan tambahan seperti Conv2D, MaxPooling2D, GlobalAveragePooling2D, dan Dense ditambahkan sebagai bagian dari *head* klasifikasi. Lapisan-lapisan ini dirancang untuk mengolah fitur yang telah diekstraksi dan menghasilkan output klasifikasi antara anemia dan non-anemia. Arsitektur lengkap dari model dapat dilihat pada gambar. 3.

Model: "sequential_1"

Layer (type)	Output Shape	Param #
mobilenetv2_1.00_224 (Functional)	(None, 7, 7, 1280)	2,257,984
conv2d_2 (Conv2D)	(None, 5, 5, 128)	1,474,688
max_pooling2d_2 (MaxPooling2D)	(None, 2, 2, 128)	0
conv2d_3 (Conv2D)	(None, 2, 2, 256)	295,168
max_pooling2d_3 (MaxPooling2D)	(None, 1, 1, 256)	0
global_average_pooling2d_1 (GlobalAveragePooling2D)	(None, 256)	0
dense_2 (Dense)	(None, 128)	32,896
dropout_1 (Dropout)	(None, 128)	0
dense_3 (Dense)	(None, 1)	129

Total params: 4,060,865 (15.49 MB)
Trainable params: 3,664,321 (13.98 MB)
Non-trainable params: 396,544 (1.51 MB)

Gambar. 3. Arsitektur Model

3.2 Hasil Pelatihan Model (Initial Training)

Model pertama kali dilatih dengan data citra konjungtiva selama 12 epoch dengan parameter pelatihan menggunakan fungsi aktivasi ReLU dan fungsi loss *categorical_crossentropy*. Hasil pelatihan menunjukkan tren peningkatan yang stabil baik pada akurasi maupun penurunan loss. Grafik akurasi dan loss ditampilkan pada gambar. 4. dan gambar. 5. berikut:

Epoch 11/50
64/64 — 349s 5s/step - accuracy: 0.8458 - loss: 0.3657 - val_accuracy: 0.7724 - val_loss: 0.4809
Epoch 12/50
64/64 — 0s 5s/step - accuracy: 0.8597 - loss: 0.3375
Reached 85.0% accuracy, stopping training!
64/64 — 337s 5s/step - accuracy: 0.8596 - loss: 0.3374 - val_accuracy: 0.7899 - val_loss: 0.4497

Gambar. 4. Akurasi dan Loss Model pada Pelatihan Awal



Gambar 5. Grafik Akurasi dan Loss Model pada Pelatihan Awal

Pada epoch ke-12, model mencapai performa sebagai berikut:

- *Training Accuracy*: 85.96%
- *Validation Accuracy*: 78.99%
- *Training Loss*: 0.3374
- *Validation Loss*: 0.4497

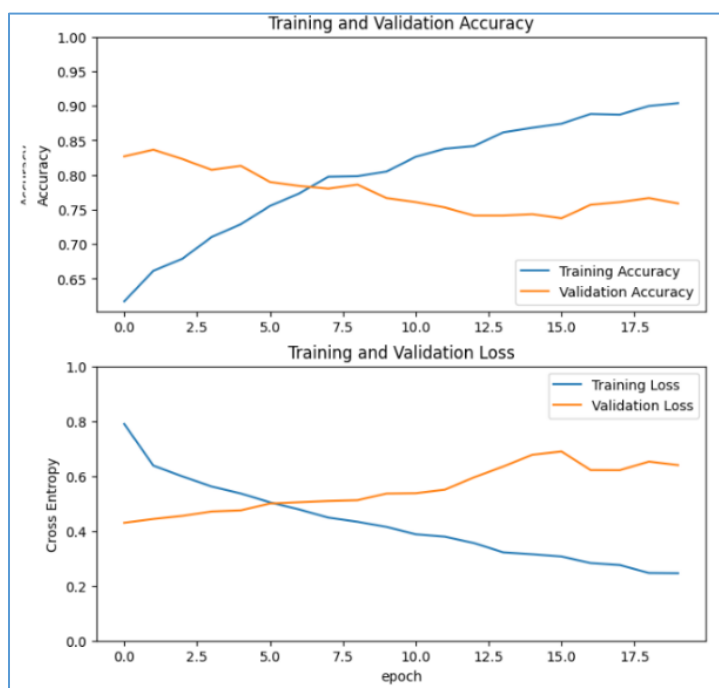
Model otomatis berhenti pada epoch ke-12 melalui *early stopping* karena telah mencapai ambang akurasi 85%.

3.3 Hasil Fine-Tuning

Setelah pelatihan awal selesai, dilakukan proses *fine-tuning* dengan membuka (unfreeze) lapisan-lapisan dalam MobileNetV2 agar bobotnya ikut diperbarui. Pelatihan dilanjutkan hingga 20 epoch. Hasil pelatihan fine-tuning menunjukkan peningkatan akurasi pelatihan yang signifikan, tetapi akurasi validasi cenderung stagnan atau sedikit menurun, menunjukkan potensi *overfitting*. Grafik hasil ditampilkan pada gambar. 6. gambar. 7. berikut:

```
Epoch 19/20
64/64 416s 6s/step - accuracy: 0.8982 - loss: 0.2556 - val_accuracy: 0.7665 - val_loss: 0.6524
Epoch 20/20
64/64 0s 7s/step - accuracy: 0.9112 - loss: 0.2403
Reached 90.0% accuracy, stopping training!
64/64 507s 7s/step - accuracy: 0.9111 - loss: 0.2404 - val_accuracy: 0.7588 - val_loss: 0.6397
```

Gambar 6. Akurasi dan Loss Model pada Fine-Tuning



Gambar 7. Akurasi dan Loss Model pada Fine-Tuning

Performa model pada epoch ke-20:

- *Training Accuracy*: 91.11%
- *Validation Accuracy*: 75.88%
- *Training Loss*: 0.2404
- *Validation Loss*: 0.6397

Meskipun akurasi pelatihan meningkat, perbedaan signifikan dengan akurasi validasi mengindikasikan model mulai kehilangan kemampuan generalisasi.

3.4 Pengujian Model

Untuk mengukur kemampuan prediksi model terhadap data baru, dilakukan pengujian dengan beberapa gambar yang tidak termasuk dalam data pelatihan maupun validasi. Hasil pengujian menunjukkan bahwa model berhasil mengklasifikasikan gambar dengan benar. Dua contoh hasil prediksi model ditampilkan pada gambar. 8. berikut:



Gambar. 8. Hasil Model untuk Gambar Anemia

Prediksi:

- Gambar pertama diklasifikasikan sebagai non-anemia
- Gambar kedua diklasifikasikan sebagai anemia

Hal ini menunjukkan bahwa model telah mampu mengenali pola visual yang membedakan antara konjungtiva penderita anemia dan non-anemia.

3.5 Pembahasan

Model pendeteksi anemia yang dikembangkan dalam penelitian ini menggunakan pendekatan *Convolutional Neural Network* (CNN) dengan arsitektur MobileNetV2 dan dataset citra konjungtiva mata. Hasil pelatihan menunjukkan akurasi yang tinggi, yaitu 91,11% pada data pelatihan dan 75,88% pada data validasi. Hal ini mengindikasikan bahwa model memiliki performa klasifikasi yang baik, meskipun terdapat gejala *overfitting* yang kemungkinan disebabkan oleh keterbatasan jumlah dan variasi data citra. Arsitektur model ini sengaja dirancang ringan agar dapat diintegrasikan ke dalam sistem berbasis web. Hal ini menjadi keunggulan dibandingkan pendekatan lain yang menggunakan model lebih kompleks seperti ResNet atau Inception, yang meskipun mampu menghasilkan akurasi lebih tinggi, memerlukan daya komputasi yang besar dan kurang cocok untuk aplikasi yang diakses melalui peramban. MobileNetV2 dipilih karena memiliki keseimbangan yang baik antara efisiensi dan akurasi, sehingga ideal untuk implementasi dalam platform web yang lebih ringan dan mudah diakses.

Temuan ini sejalan dengan beberapa studi sebelumnya yang juga menggunakan CNN untuk deteksi citra medis, namun penelitian ini menekankan pentingnya efisiensi model dan potensi penerapannya dalam sistem berbasis web untuk skrining anemia secara cepat dan non-invasif. Dengan pendekatan ini, sistem deteksi anemia tidak hanya dapat digunakan di lingkungan klinis, tetapi juga bisa diakses lebih luas melalui jaringan internet, termasuk oleh tenaga kesehatan lapangan maupun masyarakat umum. Meskipun demikian, performa validasi yang belum sepenuhnya stabil menunjukkan bahwa model masih perlu dikembangkan lebih lanjut. Variasi data yang lebih beragam—baik dari segi pencahayaan, resolusi, maupun latar belakang gambar—dapat membantu meningkatkan kemampuan generalisasi model terhadap data dunia nyata. Secara keseluruhan, pendekatan ini menawarkan arah baru dalam deteksi anemia yang lebih praktis dan terjangkau. Penelitian ini memberikan dasar awal bagi pengembangan sistem diagnosis dini yang dapat diakses secara daring, khususnya untuk mendukung layanan kesehatan di wilayah dengan keterbatasan fasilitas laboratorium atau pemeriksaan darah.

4. Kesimpulan

Penelitian ini berhasil mengembangkan model deteksi anemia berbasis *Convolutional Neural Network* (CNN) dengan arsitektur MobileNetV2, menggunakan dataset citra konjungtiva mata. Model menunjukkan performa yang cukup baik dalam mengklasifikasikan dua kondisi anemia dan non-anemia dengan akurasi pelatihan mencapai 91,11% dan akurasi validasi 75,88% setelah proses *fine-tuning*. Hasil ini mencerminkan potensi pendekatan ini untuk mendeteksi anemia secara non-invasif dengan metode yang efisien dan terjangkau. Selaras

dengan tujuan awal, penelitian ini membuktikan bahwa model ringan seperti MobileNetV2 dapat diadaptasi untuk kebutuhan diagnostik awal dan diintegrasikan ke dalam sistem berbasis web. Hal ini membuka peluang untuk pengembangan platform deteksi anemia yang mudah diakses melalui peramban, tanpa memerlukan perangkat khusus, sehingga sangat relevan untuk diterapkan di lingkungan dengan keterbatasan fasilitas laboratorium.

Kontribusi utama dari penelitian ini tidak hanya terletak pada akurasi model, tetapi juga pada pendekatannya yang praktis dan aplikatif menghadirkan alternatif skrining dini anemia berbasis visual dengan bantuan teknologi yang dapat menjangkau masyarakat luas melalui internet. Untuk pengembangan lebih lanjut, disarankan agar jumlah dan variasi dataset ditingkatkan, serta dilakukan integrasi dengan data klinis tambahan guna mendukung keakuratan prediksi. Pendekatan multimodal serta evaluasi langsung dalam lingkungan penggunaan nyata juga penting untuk memastikan sistem ini dapat berfungsi secara optimal dalam praktik pelayanan kesehatan berbasis digital.

5. Referensi

- [1]. Purbolaksono MD, Tantowi MI, Hidayat AI, Adiwijaya. Perbandingan Support Vector Machine dan Modified Balanced Random Forest dalam Deteksi Pasien Penyakit Diabetes. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*. 2021;5(2):393–399. Available from: <https://doi.org/10.29207/resti.v5i2.3008>
- [2]. Sitanggang BF, Sitompul P. Deteksi Awal Kelangsungan Hidup Pasien Gagal Jantung Menggunakan Machine Learning Metode Random Forest. *INNOVATIVE: Journal of Social Science Research*. 2024;4(2):3347–3357.
- [3]. Aditya MFR, Azizah NL, Indahyanti U. Prediksi Penyakit Hipertensi Menggunakan Metode Decision Tree dan Random Forest. *Jurnal Ilmiah KOMPUTASI*. 2024;23(1):9–14. Available from: <http://dx.doi.org/10.32409/jikstik.23.1.3503>
- [4]. Erlin, Marlim YN, Junadhi, Suryati L, Agustina N. Deteksi Dini Penyakit Diabetes Menggunakan Machine Learning dengan Algoritma Logistic Regression. *Jurnal Nasional Teknik Elektro dan Teknologi Informasi*. 2022;11(2):88–96.
- [5]. Tarimana AA, Fajar MRS, Saktiawan MA, Saputra RA. Prediksi Penyakit Hipertensi Menggunakan Machine Learning dengan Algoritma Regresi Logistik. *JATI (Jurnal Mahasiswa Teknik Informatika)*. 2024;8(6):12062–12066.
- [6]. Akbar I, Supriadi F, Junaedi DI. Pemanfaatan Machine Learning di Bidang Kesehatan. *JATI (Jurnal Mahasiswa Teknik Informatika)*. 2025;9(1):1744–1748
- [7]. Hidayatullah I, Septihadi AN, Susanto F, Ryando MB. Analisis Performa Deteksi Penyakit Padi dengan Model Klasifikasi Gambar Menggunakan Teachable Machine. *AJCSR (Academic Journal of Computer Science Research)*. 2025;7(1):1–6.
- [8]. Mellina ADF, Suhartono, Yaqin MA. Algoritma Decision Tree untuk Prediksi Deteksi Penyakit Kanker Payudara. *JISKA (Jurnal Informatika Sunan Kalijaga)*. 2024;9(1):70–78
- [9]. Mucholladin AW, Bachtiar FA, Furqon MT. Klasifikasi Penyakit Diabetes Menggunakan Metode Support Vector Machine. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*. 2021;5(2):622–633
- [10]. Husein MM, Gunawan D. Sistem Klasifikasi Penyakit Kulit pada Manusia Menggunakan Machine Learning Berbasis Android. Skripsi. Universitas Muhammadiyah Surakarta; 2024
- [11]. Saputra H, Stephane I, Sundara TA, Bahri AH. Deteksi Penyakit Tanaman Padi Berbasis Android Melalui Pemanfaatan Teachable Machine. *Indonesian Journal of Computer Science*. 2024;13(1):1256–1259
- [12]. Juliani D, Soleh M. Implementasi Machine Learning untuk Klasifikasi Penyakit Kanker Paru Menggunakan Metode Naïve Bayes dengan Tambahan Fitur Chatbot. *Jurnal IPTEK*. 2024;8(2):12–17
- [13]. Maspaeni M, Imran B, Hidayat A, Erniwati S. Implementasi Machine Learning untuk Mendeteksi Penyakit Katarak Menggunakan Kombinasi Ekstraksi Fitur dan Neural Network Berdasarkan Citra. *JTIM (Jurnal Teknologi Informasi dan Multimedia)*. 2025;7(2):232–251

- [14]. Kurniadi FI, Larasati PD. Light Gradient Boosting Machine untuk Deteksi Penyakit Stroke. *Jurnal Sistem Komputer dan Kecerdasan Buatan*. 2022;6(1):67–70
- [15]. Wirya MA. Deteksi Penyakit Alzheimer pada Citra Magnetic Resonance Imaging Menggunakan Machine Learning dengan Metode Convolutional Neural Network. Skripsi. Universitas Islam Negeri Syarif Hidayatullah Jakarta; 2023
- [16]. Mucholladin AW, Bachtiar FA, Furqon MT. Klasifikasi Penyakit Diabetes menggunakan Metode Support Vector Machine. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*. 2021;5(2):622–633.
- [17]. Juliani D, Soleh M. Implementasi Machine Learning untuk Klasifikasi Penyakit Kanker Paru Menggunakan Metode Naïve Bayes dengan Tambahan Fitur Chatbot. *Jurnal IPTEK*. 2024;8(2):12–17.
- [18]. Husein MM, Gunawan D. Sistem Klasifikasi Penyakit Kulit pada Manusia Menggunakan Machine Learning Berbasis Android. Skripsi. Universitas Muhammadiyah Surakarta; 2024.
- [19]. Saputra H, Stephane I, Sundara TA, Bahri AH. Deteksi Penyakit Tanaman Padi Berbasis Android Melalui Pemanfaatan Teachable Machine. *Indonesian Journal of Computer Science*. 2024;13(1):1256–1259.
- [20]. Appiahene P, Arthur EJ, Korankye S, Afrifa S, Asare JW, Donkoh ET. Detection of anemia using conjunctiva images: A smartphone application approach. *Medicine in Novel Technology and Devices*. 2023;18:100237. <https://doi.org/10.1016/j.medntd.2023.100237>