

PEMANFAATAN ALGORITMA CONVOLUTIONAL NEURAL NETWORK (CNN) UNTUK KLASIFIKASI PENYAKIT MATA MENGGUNAKAN CITRA FUNDUS DALAM MENDUKUNG DIAGNOSIS MEDIS

Rizki Ikhwan Nur Rahim^{1*}, Taufik Rendi Anggara²

^{1,2}Universitas Esa Unggul; Jl. Arjuna Utara No.9, RT.1/RW.2, Duri Kepa, Kec. Kb. Jeruk, Kota Jakarta Barat, Daerah Khusus Ibukota Jakarta 11510; (021) 39529950

Keywords:

Klasifikasi Penyakit Mata;
Convolutional Neural
Network;
Citra Fundus;
Transfer Learning;
Fine-tuning.

Correspondent Email:

rizkiikhwan73@student.esaunggul.ac.id

Abstrak. Penyakit mata seperti katarak, retinopati diabetik, dan glaukoma merupakan penyebab utama gangguan penglihatan dan kebutaan yang dapat dicegah, namun proses diagnosisnya masih sangat bergantung pada interpretasi manual tenaga medis yang terbatas ketersediaannya. Penelitian ini bertujuan mengembangkan model klasifikasi otomatis berbasis Convolutional Neural Network untuk membedakan empat kondisi mata, yaitu mata normal, katarak, retinopati diabetik, dan glaukoma, menggunakan citra fundus digital. Tiga arsitektur jaringan saraf konvolusional yang telah dilatih sebelumnya, yakni EfficientNetV2B3, EfficientNetV2S, dan ConvNeXtTiny, diimplementasikan menggunakan pendekatan transfer learning dan fine-tuning. Dataset yang digunakan terdiri dari 4.217 gambar fundus berlabel yang terdistribusi merata pada empat kelas, dengan rasio pembagian data latih dan validasi sebesar 80:20. Proses pengembangan model mencakup augmentasi data, optimasi Bayesian untuk penyetelan hiperparameter, serta mekanisme callback untuk pengendalian pelatihan. Evaluasi dilakukan menggunakan metrik akurasi, presisi, recall, F1-score, dan matriks kebingungan. Hasil penelitian menunjukkan bahwa model EfficientNetV2B3 mencapai akurasi validasi tertinggi sebesar 93,48% dengan efisiensi waktu pelatihan yang lebih unggul dibandingkan arsitektur lainnya. Temuan ini mengindikasikan bahwa pendekatan berbasis jaringan saraf konvolusional memiliki potensi signifikan sebagai alat bantu skrining penyakit mata yang efisien dan akurat dalam mendukung tenaga medis.



Copyright © 2026 The Author(s),
Published by Jurnal Informatika
dan Teknik Elektro Terapan. This
is an open-access article
distributed under the terms of the
Creative Commons Attribution-
NonCommercial 4.0 International
License (CC BY-NC 4.0).

Abstract. Eye diseases such as cataracts, diabetic retinopathy, and glaucoma are among the leading causes of preventable visual impairment and blindness; however, their diagnosis remains heavily dependent on manual interpretation by medical professionals whose availability is limited. This study aims to develop an automated classification model based on Convolutional Neural Networks (CNN) to distinguish four ocular conditions — normal eyes, cataracts, diabetic retinopathy, and glaucoma — using digital fundus images. Three pre-trained convolutional neural network architectures, namely EfficientNetV2B3, EfficientNetV2S, and ConvNeXtTiny, were implemented using transfer learning and fine-tuning approaches. The dataset comprised 4,217 labeled fundus images evenly distributed across four classes, with a training-to-validation split ratio of 80:20. The model development process encompassed data augmentation, Bayesian optimization for hyperparameter tuning, and callback mechanisms for training control. Evaluation was

conducted using accuracy, precision, recall, F1-score, and confusion matrix metrics. The results demonstrated that the EfficientNetV2B3 model achieved the highest validation accuracy of 93.48%, with superior training efficiency compared to the other architectures. These findings indicate that the convolutional neural network-based approach holds significant potential as an efficient and accurate eye disease screening tool to support medical professionals.

1. PENDAHULUAN

Gangguan penglihatan merupakan salah satu masalah kesehatan global yang berdampak luas terhadap kualitas hidup jutaan orang. World Health Organization (WHO) melaporkan bahwa sedikitnya 2,2 miliar orang di seluruh dunia mengalami gangguan penglihatan, dengan sekitar 1 miliar kasus di antaranya sebenarnya dapat dicegah atau belum tertangani secara optimal [1]. Di Indonesia, kondisi ini bahkan menempatkan negara ini di peringkat ketiga dunia dalam jumlah penderita gangguan penglihatan, di mana terdapat 1,6 juta orang buta dan 6,4 juta orang mengalami gangguan penglihatan sedang hingga berat berdasarkan data tahun 2017 [2]. Tiga jenis penyakit mata yang paling dominan sebagai penyebab kondisi tersebut adalah retinopati diabetik, katarak, dan glaukoma, yang secara kolektif bertanggung jawab atas jutaan kasus kebutaan yang dapat dicegah apabila terdeteksi sejak dini [1].

Diagnosis penyakit mata saat ini masih sangat bergantung pada pemeriksaan manual terhadap citra fundus oleh tenaga medis spesialis. Citra fundus merupakan teknik pencitraan non-invasif yang merekam permukaan bagian dalam mata dan telah terbukti efektif sebagai media diagnosis berbagai kondisi okular, termasuk retinopati diabetik, katarak, dan glaukoma [3]. Namun, proses interpretasi manual ini memiliki keterbatasan yang signifikan, meliputi kelangkaan tenaga spesialis mata, waktu pemeriksaan yang relatif panjang, serta potensi variasi hasil interpretasi antarpraktisi [4]. Kondisi ini diperparah oleh meningkatnya jumlah pasien yang membutuhkan pemeriksaan mata, sementara ketersediaan tenaga medis spesialis, terutama di daerah dengan akses kesehatan terbatas, tidak sebanding dengan kebutuhan tersebut.

Perkembangan kecerdasan buatan, khususnya Convolutional Neural Network (CNN), telah membuka peluang baru yang

menjanjikan dalam bidang analisis citra medis. CNN bekerja dengan meniru cara otak manusia mengenali pola visual melalui operasi konvolusi bertingkat, sehingga mampu mengekstraksi fitur visual secara otomatis dari citra medis dengan tingkat akurasi yang tinggi [5]. Pendekatan transfer learning, yakni pemanfaatan kembali model yang telah dilatih pada dataset berskala besar untuk disesuaikan dengan tugas baru, semakin memperluas kemampuan CNN dalam domain citra medis di mana ketersediaan data berlabel umumnya terbatas [6]. Sejumlah penelitian terdahulu telah mendemonstrasikan potensi pendekatan ini. Das et al. [7] mencapai akurasi 98,7% dalam deteksi retinopati diabetik menggunakan arsitektur CNN kustom berbasis citra fundus. Fuadah et al. [8] mengembangkan model CNN sekuensial untuk klasifikasi glaukoma dengan akurasi validasi mencapai 99%. Arslan et al. [9] membandingkan beberapa arsitektur CNN pre-trained dan menemukan bahwa EfficientNet mencapai akurasi tertinggi sebesar 94,88% dalam mendeteksi tiga jenis penyakit mata sekaligus. Yasashvini et al. [10] menunjukkan bahwa pendekatan hybrid CNN dengan transfer learning menggunakan DenseNet-121 mampu mencapai akurasi validasi hingga 96,22% pada klasifikasi retinopati diabetik.

Dalam konteks yang lebih luas, CNN juga telah terbukti efektif untuk diagnosis berbagai jenis penyakit berbasis citra. Novriandy et al. [11] menunjukkan bahwa arsitektur ResNet50 dengan optimizer Adam mampu mengklasifikasikan citra penyakit kanker mulut dengan performa yang kompetitif melalui pendekatan transfer learning, yang semakin memperkuat posisi CNN sebagai alat bantu diagnosis medis berbasis citra secara umum.

Meskipun penelitian-penelitian tersebut menunjukkan hasil yang menjanjikan, terdapat beberapa kesenjangan yang perlu diatasi. Pertama, sebagian besar penelitian hanya berfokus pada satu atau dua jenis penyakit mata

sehingga belum mencakup klasifikasi multi-kelas yang komprehensif untuk empat kondisi secara sekaligus dalam satu sistem. Kedua, perbandingan sistematis antara beberapa arsitektur CNN modern, khususnya keluarga EfficientNetV2 dan ConvNeXt, dalam konteks klasifikasi citra fundus multi-kelas masih sangat terbatas di dalam literatur yang ada. Ketiga, banyak penelitian tidak menerapkan teknik optimasi hiperparameter secara otomatis dan terstruktur, yang berpotensi menghasilkan konfigurasi model yang kurang optimal [12]. Keempat, aspek efisiensi waktu pelatihan sebagai pertimbangan praktis dalam pemilihan arsitektur jarang dianalisis secara komparatif, padahal faktor ini sangat relevan dalam konteks implementasi nyata.

Berdasarkan analisis kesenjangan tersebut, penelitian ini bertujuan untuk mengembangkan dan membandingkan tiga arsitektur CNN modern, yaitu EfficientNetV2B3, EfficientNetV2S, dan ConvNeXtTiny, dalam mengklasifikasikan empat kondisi mata secara serentak, meliputi mata normal, katarak, retinopati diabetik, dan glaukoma, berbasis citra fundus digital. Secara spesifik, penelitian ini menerapkan Bayesian Optimization untuk pencarian hiperparameter secara otomatis, mengombinasikan transfer learning dan fine-tuning secara terstruktur, serta mengevaluasi performa model secara komprehensif menggunakan metrik akurasi, presisi, recall, F1-score, dan efisiensi waktu pelatihan. Sebagai langkah akhir, model terbaik diimplementasikan ke dalam aplikasi berbasis web menggunakan platform Streamlit guna memudahkan pengujian dan interpretasi hasil prediksi secara interaktif.

2. TINJAUAN PUSTAKA

2.1. Citra Fundus Photography

Citra fundus photography (CFP) adalah teknik pencitraan non-invasif yang merekam permukaan bagian dalam mata untuk memantau dan mendeteksi potensi gangguan okular. Sebagai pendekatan yang ekonomis dan efisien, CFP direkomendasikan untuk pemeriksaan fundus berkala, khususnya pada populasi dewasa tanpa gejala [1]. Gambar fundus memberikan representasi visual langsung dari struktur internal mata, mencakup komponen morfologis dan patologis seperti pembuluh darah, makula, fovea, diskus optikus, serta

berbagai indikator kelainan lainnya [3]. Dibandingkan dengan modalitas pencitraan lain seperti Optical Coherence Tomography (OCT) atau angiografi, citra fundus lebih unggul dari sisi biaya dan sifatnya yang non-invasif, sehingga sangat sesuai untuk skrining berskala luas terhadap penyakit seperti retinopati diabetik, katarak, dan glaukoma [3].

2.2. Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) adalah jenis jaringan saraf tiruan yang dirancang secara khusus untuk memproses data berbentuk citra. CNN bekerja dengan meniru mekanisme pengenalan pola visual pada otak manusia melalui operasi konvolusi bertingkat yang mampu mengekstraksi fitur hierarkis secara otomatis, mulai dari fitur tingkat rendah seperti tepi dan tekstur hingga fitur tingkat tinggi yang lebih abstrak [5]. Arsitektur CNN secara umum terdiri atas lapisan konvolusi, lapisan pooling, lapisan normalisasi, dan lapisan fully connected yang diakhiri dengan fungsi aktivasi untuk menghasilkan prediksi kelas. Pada penelitian ini, fungsi aktivasi Softmax digunakan pada lapisan keluaran untuk mengonversi logit menjadi distribusi probabilitas pada empat kelas target, sehingga cocok digunakan pada permasalahan klasifikasi multi-kelas [13].

2.3. Pre-trained Model

Pre-trained model adalah model pembelajaran mendalam yang sebelumnya telah dilatih pada dataset berskala besar untuk tugas umum, kemudian dimanfaatkan kembali untuk tugas yang berbeda namun berkaitan. Pendekatan ini memungkinkan pemanfaatan representasi fitur yang telah dipelajari sebelumnya, sehingga dapat mengurangi waktu pelatihan sekaligus meningkatkan performa model, terutama ketika data untuk tugas target bersifat terbatas [14]. Penelitian ini menggunakan tiga arsitektur pre-trained model sebagai berikut.

EfficientNetV2B3 merupakan varian dari keluarga EfficientNetV2 yang dibangun menggunakan kombinasi blok MBConv dan Fused-MBConv. Arsitektur ini dirancang untuk mencapai akurasi tinggi dengan jumlah parameter yang relatif kecil dan waktu pelatihan yang lebih efisien melalui pendekatan progressive learning dan compound scaling

[15]. Keluarga EfficientNet secara umum telah terbukti efektif pada berbagai tugas klasifikasi citra, termasuk dalam domain penyakit tanaman menggunakan EfficientNet-B6 dengan hasil yang memuaskan [16]. EfficientNetV2S adalah varian lain dari keluarga yang sama, dikembangkan menggunakan pendekatan training-aware Neural Architecture Search (NAS) yang mempertimbangkan kecepatan pelatihan, ukuran parameter, dan akurasi secara bersamaan. Perbedaan utamanya terletak pada penggunaan blok Fused-MBConv di lapisan awal jaringan serta strategi scaling yang tidak seragam [15]. ConvNeXtTiny merupakan varian dari arsitektur ConvNeXt, yaitu CNN modern yang dimodernisasi berdasarkan praktik terbaik dari arsitektur Vision Transformer, seperti penggunaan depthwise convolution, inverted bottleneck, kernel konvolusi berukuran besar, normalisasi layer, serta fungsi aktivasi GELU sebagai pengganti ReLU [17].

2.4. Transfer Learning dan Fine-tuning

Transfer learning adalah teknik yang memungkinkan model yang telah dilatih pada dataset berskala besar diadaptasi untuk menyelesaikan tugas baru dengan data yang lebih terbatas. Dalam konteks CNN, pendekatan ini dilakukan dengan membekukan (freeze) seluruh lapisan pre-trained model pada tahap awal pelatihan, sehingga bobot yang telah dipelajari tetap terjaga sementara lapisan klasifikasi baru dilatih untuk menyesuaikan diri dengan domain target [6]. Fine-tuning merupakan kelanjutan dari transfer learning, di mana sebagian lapisan akhir dari pre-trained model dibuka kembali (unfreeze) dan dilatih ulang menggunakan learning rate yang lebih kecil. Pendekatan ini memungkinkan model menyesuaikan representasi fitur tingkat tinggi agar lebih relevan dengan karakteristik data target, sehingga menghasilkan performa yang lebih baik dibandingkan apabila model hanya dilatih dari awal [18].

2.5. Hyperparameter Tuning dengan Bayesian Optimization

Hyperparameter adalah variabel yang ditetapkan sebelum proses pelatihan berlangsung dan berpengaruh signifikan terhadap arsitektur maupun kinerja model, seperti learning rate, dropout rate, dan jenis

optimizer. Pemilihan hyperparameter yang optimal secara langsung memengaruhi kemampuan generalisasi model [12]. Bayesian Optimization merupakan salah satu teknik hyperparameter tuning yang menggunakan model probabilistik untuk menyempurnakan pemilihan hyperparameter secara berulang berdasarkan hasil percobaan sebelumnya, sehingga pencarian konfigurasi terbaik menjadi lebih efisien dibandingkan metode pencarian acak atau grid search konvensional [12].

2.6. Teknik Callback

Callback adalah mekanisme yang dipanggil secara otomatis pada tahap-tahap tertentu selama pelatihan model untuk memantau dan mengontrol perilaku pelatihan. Tiga jenis callback utama yang digunakan dalam penelitian ini adalah EarlyStopping, yang menghentikan pelatihan secara otomatis ketika tidak ada peningkatan performa pada data validasi dalam sejumlah epoch tertentu guna mencegah overfitting; ReduceLROnPlateau, yang menurunkan learning rate secara adaptif ketika performa validasi mengalami stagnasi; serta ModelCheckpoint, yang menyimpan bobot model terbaik berdasarkan metrik validasi yang dipantau [19].

2.7. Preprocessing dan Augmentasi Data

Preprocessing data bertujuan untuk mempersiapkan dataset agar sesuai dengan kebutuhan model CNN. Tahapan yang diterapkan meliputi resizing untuk menyeragamkan dimensi citra, normalisasi nilai piksel ke rentang 0 hingga 1, serta label encoding untuk mengonversi label kategori menjadi format numerik [13]. Augmentasi data merupakan teknik yang digunakan untuk memperkaya variasi data pelatihan secara artifisial guna mengurangi risiko overfitting dan meningkatkan kemampuan generalisasi model. Teknik augmentasi yang diterapkan mencakup random flipping, random rotation, random zoom, random contrast, random brightness, dan gaussian noise [20].

2.8. GlobalAveragePooling2D dan Dropout

GlobalAveragePooling2D (GAP) adalah metode reduksi dimensi yang menghitung rata-rata dari setiap feature map, menggantikan peran fully connected layer pada bagian klasifikasi. GAP tidak memiliki parameter yang

dilatih sehingga berperan sebagai structural regularizer yang efektif dalam mengurangi risiko overfitting [21]. Dropout layer merupakan teknik regularisasi yang bekerja dengan menonaktifkan sejumlah neuron secara acak selama pelatihan, sehingga memaksa jaringan untuk mempelajari representasi fitur yang lebih tergeneralisasi dan tidak bergantung pada jalur komputasi tertentu [22].

2.9. *Evaluasi Model dengan Confusion Matrix*

Confusion matrix adalah tabel yang menyajikan distribusi prediksi benar dan salah dari sebuah model klasifikasi, yang mencakup nilai True Positive (TP), True Negative (TN), False Positive (FP), dan False Negative (FN). Dari matriks ini diturunkan empat metrik evaluasi utama, yaitu akurasi yang mengukur proporsi prediksi benar secara keseluruhan, presisi yang mengukur ketepatan prediksi positif, recall yang mengukur kemampuan model mendeteksi seluruh sampel positif, serta F1-score sebagai rata-rata harmonik dari presisi dan recall yang memberikan gambaran keseimbangan antara keduanya [13].

3. METODE PENELITIAN

3.1. *Rancangan Penelitian*

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen berbasis algoritma Convolutional Neural Network (CNN) untuk mengklasifikasikan citra fundus mata ke dalam empat kategori kondisi okular, yaitu normal, katarak, retinopati diabetik, dan glaukoma. Metodologi pengembangan sistem mengikuti kerangka Software Development Life Cycle (SDLC) dengan model Evolutionary Prototyping, yang memungkinkan proses pengembangan berlangsung secara iteratif hingga diperoleh model dengan performa optimal [23]. Seluruh proses implementasi dilakukan menggunakan bahasa pemrograman Python versi 3.11.13 dengan pustaka TensorFlow versi 2.18.0 sebagai kerangka kerja utama, dijalankan pada platform Google Colab Pro dengan tipe runtime GPU T4 dan konfigurasi memori tinggi. Nilai seed ditetapkan sebesar 42 pada seluruh proses untuk memastikan hasil yang konsisten dan dapat direproduksi.

3.2. *Dataset*

Dataset yang digunakan dalam penelitian ini adalah "eye_diseases_classification" yang bersumber dari platform Kaggle, dikompilasi oleh Doddi [24] dari beberapa sumber terbuka, meliputi IDRiD, HRF, Ocular Recognition, retinal dataset, dan DRIVE. Dataset ini terdiri dari 4.217 gambar fundus berlabel yang terdistribusi ke dalam empat kelas: katarak (1.038 gambar), retinopati diabetik (1.098 gambar), glaukoma (1.007 gambar), dan normal (1.074 gambar). Distribusi kelas yang relatif seimbang ini berkontribusi positif terhadap proses pelatihan dengan meminimalkan potensi bias terhadap kelas tertentu. Dataset dibagi menggunakan teknik stratified splitting dengan rasio 80% data latih (3.374 gambar) dan 20% data validasi (843 gambar).

3.3. *Preprocessing Data*

Sebelum digunakan dalam proses pelatihan, seluruh citra fundus melewati tahap preprocessing yang mencakup tiga langkah utama. Pertama, resizing dilakukan untuk menyeragamkan dimensi citra sesuai dengan ukuran input yang disyaratkan oleh masing-masing arsitektur pre-trained model, yaitu 300x300 piksel untuk EfficientNetV2B3 dan 384x384 piksel untuk EfficientNetV2S serta ConvNeXtTiny. Kedua, normalisasi nilai piksel dilakukan ke rentang 0 hingga 1 dalam format float32 untuk memudahkan konvergensi selama pelatihan. Ketiga, teknik prefetching diterapkan untuk memuat data secara paralel saat model memproses batch berjalan, sehingga efisiensi penggunaan sumber daya komputasi meningkat secara signifikan. Batch size yang digunakan secara seragam pada seluruh proses pelatihan adalah 32.


3.4. *Augmentation Data*

Augmentasi data diterapkan secara terpisah pada dua tahap pelatihan dengan konfigurasi yang berbeda untuk menyesuaikan kebutuhan masing-masing tahap. Pada tahap transfer learning, augmentasi dirancang lebih agresif untuk memperkuat kemampuan awal model dalam mengenali variasi data, mencakup RandomFlip horizontal, RandomRotation dengan faktor 0,2, RandomZoom dengan faktor 0,1, RandomContrast dengan faktor 0,15, dan RandomBrightness dengan faktor 0,15. Pada tahap fine-tuning, augmentasi bersifat lebih

ringan dan selektif guna menjaga stabilitas parameter model yang telah disesuaikan, terdiri dari RandomFlip horizontal, RandomContrast dengan faktor 0,075, RandomBrightness dengan faktor 0,075, dan GaussianNoise dengan nilai 0,02.

3.5. Arsitektur Model

Tiga model arsitektur dikembangkan secara paralel, masing-masing menggunakan satu pre-trained model sebagai base model, yaitu EfficientNetV2B3, EfficientNetV2S, dan ConvNeXtTiny. Pada setiap arsitektur, lapisan klasifikasi asli dari pre-trained model dihapus dan digantikan dengan tiga lapisan tambahan yang identik: GlobalAveragePooling2D untuk mereduksi dimensi feature map, Dropout untuk regularisasi, dan Dense layer dengan fungsi aktivasi Softmax untuk menghasilkan probabilitas prediksi pada empat kelas target. Pada proses kompilasi, diterapkan teknik label smoothing dengan nilai 0,1 untuk mengurangi risiko overfitting dan overconfidence terhadap kelas tertentu.



Gambar 1. Alur arsitektur model CNN pada penelitian ini


3.6. Proses Pelatihan

Pelatihan model dilakukan melalui tiga tahap berurutan. Tahap pertama adalah hyperparameter tuning menggunakan pustaka Keras Tuner dengan algoritma Bayesian Optimization. Pada tahap ini, seluruh lapisan pre-trained model dibekukan dan proses pencarian dilakukan dalam ruang tiga hyperparameter, yaitu dropout rate, jenis optimizer, dan learning rate. Konfigurasi tuning

ditetapkan dengan maksimal 15 percobaan (trial), setiap percobaan menggunakan 20 epoch, dengan callback EarlyStopping dan TensorBoard. Tiga percobaan terbaik dari setiap arsitektur kemudian dipilih untuk digunakan pada tahap selanjutnya.

Tahap kedua adalah transfer learning, di mana model dilatih menggunakan tiga konfigurasi hyperparameter terbaik hasil tuning dengan seluruh lapisan pre-trained model tetap dibekukan. Jumlah epoch maksimum ditetapkan sebesar 100 dengan callback EarlyStopping (patience 14), ReduceLROnPlateau, ModelCheckpoint, dan TensorBoard. Dari tiga percobaan tersebut, dipilih satu model terbaik berdasarkan kombinasi nilai akurasi validasi tertinggi, loss validasi terendah, dan gap antara performa pelatihan dan validasi yang paling kecil.

Tahap ketiga adalah fine-tuning, di mana bobot model terbaik dari tahap transfer learning dimuat kembali dan sebagian blok akhir dari pre-trained model dibuka untuk dilatih ulang. Untuk EfficientNetV2B3 dan EfficientNetV2S, dilakukan unfreeze secara bertahap pada Block 6 kemudian Block 5, sementara seluruh lapisan Batch Normalization tetap dibekukan untuk menjaga stabilitas statistik internal. Untuk ConvNeXtTiny, dilakukan unfreeze pada Stage 3 kemudian Stage 2 tanpa pembekuan lapisan normalisasi, karena arsitektur ini menggunakan Layer Normalization. Nilai learning rate pada tahap fine-tuning ditetapkan dengan mengalikan learning rate terbaik dari transfer learning dengan faktor 0,001 untuk memastikan penyesuaian bobot berlangsung secara halus dan stabil.



Gambar 2. Tahap-tahap pembuatan model

3.7. Evaluasi dan Analisis

Evaluasi performa model dilakukan pada dataset validasi menggunakan empat metrik

klasifikasi standar: akurasi, presisi, recall, dan F1-score, yang dihitung secara per-kelas maupun secara keseluruhan (weighted average). Selain itu, confusion matrix divisualisasikan untuk memberikan gambaran distribusi prediksi benar dan salah pada setiap kelas secara lebih terperinci [13]. Analisis tambahan dilakukan terhadap dua aspek, yaitu selisih nilai akurasi dan loss antara data pelatihan dan validasi (gap akurasi dan gap loss) sebagai indikator kestabilan generalisasi model, serta rata-rata waktu pelatihan per epoch yang dihitung menggunakan rumus total waktu pelatihan dibagi jumlah epoch sebagai ukuran efisiensi komputasi. Seluruh model terbaik dari masing-masing arsitektur kemudian diintegrasikan ke dalam aplikasi berbasis web menggunakan pustaka Streamlit dan di-deploy melalui platform Streamlit Community Cloud untuk keperluan pengujian interaktif.

4. HASIL DAN PEMBAHASAN

4.1. Hasil Hyperparameter Tuning

Proses pencarian hyperparameter optimal dilakukan menggunakan Keras Tuner dengan algoritma Bayesian Optimization pada masing-masing arsitektur model. Setiap percobaan dijalankan selama maksimal 20 epoch dengan 15 total percobaan. Tiga konfigurasi terbaik untuk setiap arsitektur disajikan pada Tabel 1, Tabel 2, dan Tabel 3.

Tabel 1. Tiga Hasil Terbaik Hyperparameter Tuning Model EfficientNetV2S

Trial	Dropout	Optimizer	Learning Rate
			Score
Trial 10	0.35	Adam	0.000696
			0.8577
Trial 14	0.35	Adam	0.000620
			0.8553
Trial 7	0.35	Adam	0.000806
			0.8541

Tabel 2. Tiga Hasil Terbaik Hyperparameter Tuning Model EfficientNetV2B3

Trial	Dropout	Optimizer	Learning Rate
			Score
Trial 8	0.50	Adam	0.000622
			0.8138
Trial 0	0.35	Adam	0.000684
			0.8114
Trial 14	0.40	Adam	0.000150
			0.7770

Tabel 3. Tiga Hasil Terbaik Hyperparameter Tuning Model ConvNeXtTiny

Trial	Dropout	Optimizer	Learning Rate
			Score
Trial 3	0.40	Adam	0.000998
			0.8932
Trial 9	0.35	Adam	0.000758
			0.8849
Trial 6	0.35	Adam	0.000379
			0.8754

Hasil tuning menunjukkan bahwa optimizer Adam secara konsisten dipilih sebagai konfigurasi terbaik pada ketiga arsitektur, dengan rentang learning rate optimal berada di antara 0,0001 hingga 0,001. Temuan ini sejalan dengan literatur yang menyatakan bahwa Adam merupakan optimizer yang stabil dan adaptif untuk pelatihan CNN pada dataset citra berukuran sedang [15]. Nilai dropout rate terbaik berkisar antara 0,35 hingga 0,50, yang mengindikasikan bahwa tingkat regularisasi moderat sudah cukup efektif untuk mencegah overfitting pada dataset dengan distribusi kelas yang seimbang.


4.2. Hasil Transfer Learning

Menggunakan tiga konfigurasi terbaik dari tahap tuning, proses transfer learning dijalankan dengan maksimal 100 epoch pada masing-masing arsitektur. Tabel 4 merangkum hasil terbaik dari setiap arsitektur pada tahap ini.

Tabel 4. Hasil Terbaik Transfer Learning Setiap Arsitektur

Model	Akurasi Pelatihan	Akurasi Validasi
	Loss Pelatihan	Loss Validasi
EfficientNetV2S (Trial 7)	0.8584	0.8648
EfficientNetV2B3 (Trial 0)	0.6533	0.6480
	0.8555	0.8233
ConvNeXtTiny (Trial 9)	0.6503	0.6974
	0.8460	0.7900
	0.6633	0.7448

Pada tahap ini, model EfficientNetV2S menunjukkan gap akurasi yang paling kecil (+0,0064), mengindikasikan kemampuan generalisasi yang paling stabil di antara ketiga arsitektur. Sebaliknya, ConvNeXtTiny mencatatkan gap akurasi terbesar (−0,0560) disertai gap loss yang cukup signifikan (+0,0815), yang menunjukkan bahwa arsitektur ini memerlukan penyesuaian fitur yang lebih mendalam terhadap domain citra fundus, dan transfer learning saja belum cukup untuk mengoptimalkan performanya.

**Gambar 3.** Learning curve proses Transfer learning

4.3. Hasil Fine-tuning


Proses fine-tuning dilakukan secara bertahap dengan membuka blok akhir dari masing-masing pre-trained model. Tabel 5 menyajikan hasil terbaik yang diperoleh dari seluruh tahap fine-tuning.

Tabel 5. Hasil Terbaik Fine-tuning Setiap Arsitektur

Model	Akurasi Pelatihan	Akurasi Validasi	Gap Akurasi
	Loss Pelatihan	Loss Validasi	Gap Loss
Efficient NetV2S Block 6	0.9377	0.9241	−0.0136
	0.4970	0.5123	+0.0153
Efficient NetV2B3 Block 6	0.9173	0.9348	+0.0175
	0.5324	0.5116	−0.0208
Conv NeXt Tiny Stage 2	0.9506	0.9348	−0.0158
	0.4841	0.5223	+0.0382

Fine-tuning memberikan peningkatan akurasi validasi yang signifikan pada semua arsitektur dibandingkan tahap transfer learning. Peningkatan paling substansial terjadi pada EfficientNetV2B3, yang akurasi validasinya meningkat dari 0,8233 menjadi 0,9348, atau naik sebesar 11,15 poin persentase. Hal ini membuktikan bahwa lapisan akhir dari pre-trained model yang awalnya dioptimalkan untuk dataset ImageNet memerlukan penyesuaian terhadap karakteristik visual spesifik dari citra fundus untuk mencapai performa maksimalnya [18].

Temuan menarik teridentifikasi pada model EfficientNetV2B3, di mana akurasi validasi (0,9348) justru sedikit lebih tinggi dibandingkan akurasi pelatihan (0,9173), dengan gap akurasi positif sebesar +0,0175 dan gap loss negatif sebesar −0,0208. Fenomena ini merupakan indikator kuat bahwa model memiliki kemampuan generalisasi yang sangat baik dan tidak mengalami overfitting. Kondisi ini dapat terjadi karena kombinasi antara teknik augmentasi data, label smoothing, dan mekanisme dropout yang bekerja secara sinergis sebagai regularizer selama pelatihan [22].



Gambar 4. Learning Curve proses Fine-tuning

4.4. Evaluasi Model Akhir

Setelah proses fine-tuning selesai, evaluasi akhir dilakukan pada dataset validasi menggunakan model terbaik dari masing-masing arsitektur. Hasil evaluasi per-kelas disajikan pada Tabel 6, Tabel 7, dan Tabel 8.

Tabel 6. Evaluasi Per-kelas Model *EfficientNetV2B3*


Kelas	Presisi	Recall	F1-Score
Katarak	0.9400	0.9216	0.9307
Diabetik Retinopati	1.0000	1.0000	1.0000
Glaukoma	0.8867	0.8955	0.8911
Normal	0.9103	0.9186	0.9144
Weighted Average	0.9350	0.9348	0.9348

Tabel 7. Evaluasi Per-kelas Model *ConvNeXtTiny*


Kelas	Presisi	Recall	F1-Score
Katarak	0.9534	0.9020	0.9270
Diabetik Retinopati	1.0000	1.0000	1.0000
Glaukoma	0.8873	0.9005	0.8938
Normal	0.8996	0.9321	0.9156
Weighted Average	0.9355	0.9348	0.9349

Tabel 8. Evaluasi Per-kelas Model *EfficientNetV2S*

Kelas	Presisi	Recall	F1-Score
Katarak	0.9171	0.9216	0.9193
Diabetik Retinopati	0.9953	0.9862	0.9907
Glaukoma	0.8872	0.8607	0.8737
Normal	0.8947	0.9231	0.9087
Weighted Average	0.9242	0.9241	0.9240



Gambar 5. Confusion matrix model *EfficientNetV2B3* dan *ConvNeXtTiny*



Gambar 6. Confusion matrix model *EfficientNetV2S*

Berdasarkan hasil evaluasi, *EfficientNetV2B3* dan *ConvNeXtTiny* mencapai akurasi keseluruhan tertinggi yang setara, yaitu 93,48%, sedangkan *EfficientNetV2S* mencapai 92,41%. Sebuah pola konsisten ditemukan pada ketiga model, di mana kelas diabetik retinopati secara konsisten memperoleh nilai presisi, recall, dan F1-score tertinggi, bahkan mencapai nilai sempurna (1,0000) pada *EfficientNetV2B3* dan *ConvNeXtTiny*. Hal ini mengindikasikan bahwa fitur visual retinopati diabetik pada citra fundus, seperti perdarahan mikro dan eksudat, memiliki pola yang cukup khas dan mudah dibedakan dari kondisi lainnya oleh arsitektur CNN [3]. Sebaliknya, kelas glaukoma secara konsisten menunjukkan nilai recall terendah di antara keempat kelas pada semua arsitektur, dengan nilai terendah tercatat pada *EfficientNetV2S* sebesar 0,8607. Kondisi ini kemungkinan disebabkan oleh kemiripan visual antara citra fundus glaukoma dan kondisi normal pada kasus glaukoma stadium awal, di mana perubahan struktural pada saraf optik belum terlihat secara jelas [4].


4.5. Perbandingan Efisiensi Waktu Pelatihan

Aspek efisiensi komputasi dievaluasi melalui perbandingan rata-rata waktu pelatihan per epoch dari seluruh model, termasuk model dari penelitian pembandingan yang dilatih ulang pada dataset yang sama. Tabel 9 menyajikan hasil perbandingan tersebut.

Tabel 9. Perbandingan Efisiensi Waktu Pelatihan Antar Model

Model	Total Epoch	Total Waktu (detik)	Rata-rata per Epoch (detik)
CNN (Fuadah et al. [8])	24	41	2
Hybrid CNN (Yasashvini et al. [10])	15	532	35
EfficientNet V2B3	100	2.560	25
EfficientNet V2S	100	4.966	49
ConvNeXt Tiny	100	10.829	108

EfficientNetV2B3 mencatatkan rata-rata waktu pelatihan per epoch tercepat di antara ketiga model yang dikembangkan, yaitu 25 detik per epoch, bahkan lebih cepat dibandingkan model Hybrid CNN dari Yasashvini et al. [10] yang memerlukan 35 detik per epoch meskipun hanya menyelesaikan 15 epoch sebelum dihentikan oleh EarlyStopping. *ConvNeXtTiny* memerlukan waktu rata-rata paling lama sebesar 108 detik per epoch, yang sejalan dengan kompleksitas arsitekturnya yang memiliki jumlah parameter terbesar, yaitu sekitar 49,4 juta parameter dibandingkan 14,5 juta parameter pada *EfficientNetV2B3*.



Gambar 7. Perbandingan rata-rata per-epoch (detik)


4.6. Perbandingan Stabilitas Generalisasi Model

Tabel 10 menyajikan perbandingan gap akurasi dan gap loss antara data pelatihan dan validasi dari seluruh model, sebagai ukuran stabilitas generalisasi.

Tabel 10. Perbandingan Gap Akurasi dan Gap Loss Antar Model

Model	Akurasi Pelatihan	Akurasi Validasi	Gap Akurasi
	Loss Pelatihan	Loss Validasi	Gap Loss
CNN (Fuadah et al. [8])	0.9355	0.8553	-0.0802
	0.1838	0.4279	+0.2441
Hybrid CNN (Yasashvini et al. [10])	1.0000	0.9442	-0.0558
	0.00075	0.3174	+0.3166
Efficient Net V2S	0.9377	0.9241	-0.0136
	0.9506	0.9348	-0.0158
Conv NeXt Tiny	0.9173	0.9348	+0.0175
	0.9377	0.9241	-0.0136
Efficient Net V2B3	0.9506	0.9348	-0.0158
	0.9173	0.9348	+0.0175

Ketiga model yang dikembangkan dalam penelitian ini secara konsisten menunjukkan gap akurasi dan gap loss yang jauh lebih kecil dibandingkan model dari penelitian terdahulu. Model Hybrid CNN dari Yasashvini et al. [10], meskipun mencatatkan akurasi pelatihan sempurna (1,0000) dan akurasi validasi tertinggi keseluruhan (0,9442), menunjukkan gap loss yang sangat besar sebesar +0,3166, yang merupakan indikasi kuat terjadinya overfitting. Demikian pula model CNN dari Fuadah et al. [8] yang memiliki gap akurasi -0,0802 dan gap loss +0,2441, menandakan bahwa model tersebut kesulitan untuk menggeneralisasi fitur yang dipelajari ke data yang belum pernah dilihat sebelumnya.



Gambar 8. Perbandingan Gap Akurasi dan Loss

4.7. Perbandingan Metrik Evaluasi Antar Model

Tabel 11 menyajikan perbandingan komprehensif metrik evaluasi dari seluruh model yang diujikan pada dataset validasi yang sama.

Tabel 11. Perbandingan Metrik Evaluasi Antar Model

Model	Akurasi	Presisi
	Recall	F1-Score
DNN + ML (Thanki [25])	0.8800	0.8800
	0.8800	0.8800
CNN (Fuadah et al. [8])	0.8553	0.8549
	0.8553	0.8541
Hybrid CNN (Yasashvini et al. [10])	0.9442	0.9444
	0.9442	0.9442
EfficientNet V2S	0.9241	0.9242
	0.9241	0.9240
ConvNeXt Tiny	0.9348	0.9355
	0.9348	0.9349
EfficientNet V2B3	0.9348	0.9350
	0.9348	0.9348

Dari perspektif akurasi semata, model Hybrid CNN dari Yasashvini et al. [10] mencatatkan nilai tertinggi sebesar 94,42%, unggul 0,94 poin persentase dibandingkan EfficientNetV2B3 dan ConvNeXtTiny. Namun demikian, keunggulan akurasi tersebut harus diinterpretasikan secara kritis dengan mempertimbangkan temuan pada Tabel 10, di mana model tersebut menunjukkan gap loss yang sangat besar (+0,3166), mengindikasikan adanya overfitting yang signifikan. Hal ini berarti performa tinggi pada data validasi kemungkinan tidak akan bertahan ketika model dihadapkan pada data dari distribusi yang berbeda atau data dunia nyata. Model

EfficientNetV2B3 dan ConvNeXtTiny yang dikembangkan dalam penelitian ini menawarkan trade-off yang lebih seimbang antara akurasi tinggi dan stabilitas generalisasi yang lebih terjamin.

4.8. Pembahasan Implikasi Hasil

Secara keseluruhan, EfficientNetV2B3 terbukti sebagai arsitektur paling optimal dalam konteks penelitian ini dengan mempertimbangkan empat dimensi evaluasi secara simultan: akurasi validasi (93,48%), efisiensi waktu pelatihan (25 detik per epoch), jumlah parameter yang lebih rendah ($\pm 14,5$ juta), dan stabilitas generalisasi yang terbaik. Temuan ini memperkuat argumen teoritis bahwa besarnya jumlah parameter tidak selalu berbanding lurus dengan peningkatan akurasi, dan bahwa pemilihan arsitektur serta strategi pelatihan yang tepat jauh lebih menentukan dibandingkan sekadar memilih model dengan kapasitas terbesar [15].

Konsistensi penggunaan Bayesian Optimization dalam pencarian hyperparameter terbukti memberikan kontribusi nyata terhadap kualitas model akhir. Pendekatan ini secara efisien mengeksplorasi ruang hyperparameter yang kompleks dan menghasilkan konfigurasi yang lebih baik dibandingkan pendekatan trial-and-error manual, sejalan dengan temuan Passos dan Mishra [12] yang menegaskan pentingnya optimasi hyperparameter yang terstruktur dalam pengembangan model pembelajaran mendalam.

Tantangan pada kelas glaukoma yang ditemukan secara konsisten di semua arsitektur memiliki implikasi klinis yang penting. Mengingat glaukoma dikenal sebagai "pencuri penglihatan diam-diam" yang gejalanya baru disadari setelah kerusakan signifikan terjadi [4], tingkat recall yang lebih rendah pada kelas ini perlu mendapatkan perhatian khusus dalam pengembangan lanjutan. Strategi yang dapat dieksplorasi mencakup penerapan teknik oversampling yang lebih agresif pada kelas glaukoma, penggunaan fungsi loss yang memberikan bobot lebih besar pada kelas tersebut, atau eksplorasi teknik interpretabilitas seperti Grad-CAM untuk memahami fitur visual mana yang paling berpengaruh dalam prediksi glaukoma.

5. KESIMPULAN

Penelitian ini berhasil mengembangkan sistem klasifikasi otomatis penyakit mata berbasis citra fundus menggunakan tiga arsitektur Convolutional Neural Network modern, yaitu EfficientNetV2B3, EfficientNetV2S, dan ConvNeXtTiny, dengan menggabungkan pendekatan transfer learning, fine-tuning, dan Bayesian Optimization untuk pencarian hyperparameter secara terstruktur. Seluruh tujuan penelitian yang ditetapkan telah terjawab secara eksplisit melalui serangkaian eksperimen yang terukur dan dapat direproduksi.

Dari sisi performa klasifikasi, EfficientNetV2B3 dan ConvNeXtTiny mencapai akurasi validasi tertinggi sebesar 93,48%, melampaui target awal penelitian sebesar 85%. Kelas diabetik retinopati secara konsisten memperoleh nilai metrik sempurna (presisi, recall, dan F1-score = 1,0000) pada kedua arsitektur tersebut, yang mengindikasikan bahwa fitur visual kondisi ini pada citra fundus bersifat sangat distinktif dan dapat dipelajari secara optimal oleh arsitektur CNN modern. Sebaliknya, kelas glaukoma secara konsisten menunjukkan nilai recall terendah di antara keempat kelas pada semua arsitektur, mencerminkan tantangan inherent dalam membedakan perubahan struktural saraf optik pada stadium awal dari kondisi normal, yang merupakan keterbatasan yang perlu diatasi dalam pengembangan lanjutan.

Mempertimbangkan empat dimensi evaluasi secara simultan, yakni akurasi validasi, efisiensi waktu pelatihan, jumlah parameter, dan stabilitas generalisasi, EfficientNetV2B3 terbukti sebagai arsitektur paling optimal dalam konteks penelitian ini. Model ini mencapai akurasi 93,48% dengan rata-rata waktu pelatihan hanya 25 detik per epoch dan jumlah parameter sekitar 14,5 juta, jauh lebih efisien dibandingkan ConvNeXtTiny yang memerlukan 108 detik per epoch dengan parameter mencapai 49,4 juta namun menghasilkan akurasi yang setara. Temuan ini secara tegas menunjukkan bahwa besarnya kapasitas model tidak selalu berbanding lurus dengan peningkatan akurasi, dan bahwa kombinasi antara pemilihan arsitektur yang tepat dengan strategi pelatihan yang terstruktur jauh lebih menentukan kualitas model akhir.

Dibandingkan dengan penelitian terdahulu yang dilatih ulang pada dataset yang sama, ketiga model yang dikembangkan dalam penelitian ini menunjukkan keunggulan yang signifikan dari sisi stabilitas generalisasi, dengan gap akurasi dan gap loss yang jauh lebih kecil. Model Hybrid CNN dari Yasashvini et al. [10], meskipun mencatatkan akurasi validasi tertinggi sebesar 94,42%, menunjukkan gap loss sebesar +0,3166 yang mengindikasikan overfitting signifikan, sehingga reliabilitasnya pada data dunia nyata patut dipertanyakan. Hal ini menegaskan bahwa evaluasi model yang komprehensif tidak boleh hanya bertumpu pada satu metrik akurasi semata, melainkan harus mencakup analisis stabilitas generalisasi secara menyeluruh.

Untuk penelitian mendatang, beberapa rekomendasi diajukan berdasarkan keterbatasan yang ditemukan. Pertama, eksplorasi arsitektur yang lebih mutakhir seperti Vision Transformer atau model berbasis attention mechanism disarankan untuk mengatasi tantangan klasifikasi pada kelas glaukoma. Kedua, perluasan dataset dengan melibatkan data dari berbagai institusi kesehatan akan meningkatkan kemampuan generalisasi model terhadap variasi pencitraan di dunia nyata. Ketiga, penerapan teknik interpretabilitas model seperti Grad-CAM akan meningkatkan transparansi prediksi yang sangat dibutuhkan dalam konteks aplikasi medis.

UCAPAN TERIMAKASIH

Penulis mengucapkan terima kasih kepada pihak-pihak terkait yang telah memberi dukungan terhadap penelitian ini.

REFERENSI

- [1] World Health Organization, *World Report on Vision*. Geneva: WHO, 2019.
- [2] Rokom, "Katarak Penyebab Terbanyak Gangguan Penglihatan di Indonesia," *Sehat Negeriku*, Okt. 2021.
- [3] T. Li et al., "Applications of deep learning in fundus images: A review," *Medical Image Analysis*, vol. 69, 2021.
- [4] R. Sarki, K. Ahmed, H. Wang, dan Y. Zhang, "Automatic detection of diabetic eye disease through deep learning using fundus images: A survey," *IEEE Access*, vol. 8, 2020.
- [5] M. M. Taye, "Theoretical understanding of convolutional neural network: Concepts, architectures, applications, future directions," *Computation*, vol. 11, no. 3, 2023.
- [6] I. Kandel dan M. Castelli, "Transfer learning with convolutional neural networks for diabetic retinopathy image classification: A review," *Applied Sciences*, vol. 10, no. 6, 2020.
- [7] S. Das et al., "Deep learning architecture based on segmented fundus image features for classification of diabetic retinopathy," *Biomedical Signal Processing and Control*, vol. 68, 2021.
- [8] Y. N. Fuadah et al., "Glaucoma classification based on fundus images processing with convolutional neural network," *Jurnal Teknik Informatika (JUTIF)*, vol. 3, no. 3, 2022.
- [9] G. Arslan dan C. B. Erdas, "Detection of cataract, diabetic retinopathy and glaucoma eye diseases with deep learning approach," *Intelligent Methods in Engineering Sciences*, 2023.
- [10] R. Yasashvini et al., "Diabetic retinopathy classification using CNN and hybrid deep convolutional neural networks," *Symmetry*, vol. 14, no. 9, 2022.
- [11] M. F. Novriandy, B. Rahmat, dan A. Junaidi, "Klasifikasi Citra Penyakit Kanker Mulut Menggunakan Arsitektur Resnet50 Optimasi Adam Dan SGD," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 12, no. 3, pp. 2284-2294, 2024, doi: 10.23960/jitet.v12i3.4732.
- [12] D. Passos dan P. Mishra, "A tutorial on automatic hyperparameter tuning of deep spectral modelling for regression and classification tasks," *Chemometrics and Intelligent Laboratory Systems*, vol. 223, 2022.
- [13] G. Kalyani et al., "Diabetic retinopathy detection and classification using capsule networks," *Complex and Intelligent Systems*, vol. 9, no. 3, 2023.
- [14] Encord, "Pre Trained Model," *encord.com*, 2025.
- [15] M. Tan dan Q. V. Le, "EfficientNetV2: Smaller models and faster training," *arXiv preprint*, arXiv:2104.00298, 2021.
- [16] A. C. Milano, A. Yasid, dan R. T. Wahyuningrum, "Klasifikasi Penyakit Daun Padi Menggunakan Model Deep Learning EfficientNet-B6," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 12, no. 1, 2024, doi: 10.23960/jitet.v12i1.3855.
- [17] Z. Liu et al., "A ConvNet for the 2020s," *arXiv preprint*, arXiv:2201.03545, 2022.
- [18] D. Bergmann, "What is fine-tuning?," *IBM Think*, Mar. 2024.
- [19] Keras, "Keras 3 API documentation: Callbacks," *keras.io*, 2025.

- [20] S. Wang et al., "Advances in data preprocessing for bio-medical data fusion," *Information Fusion*, vol. 76, 2021.
- [21] M. Lin, Q. Chen, dan S. Yan, "Network in network," *arXiv preprint*, arXiv:1312.4400, 2014.
- [22] O. Harris dan M. Andrews, "Effects and results of dropout layer in reducing overfitting with convolutional neural networks," *World Journal of Advanced Engineering Technology and Sciences*, vol. 13, no. 2, 2024.
- [23] D. A. N. Wulandari et al., "Prototyping model in information system development of Al-Ruhamaa Bogor Yatim Center Foundation," *Jurnal Pilar Nusa Mandiri*, vol. 17, no. 2, 2021.
- [24] G. V. Doddi, "eye_diseases_classification," *Kaggle*, 2023. [Online]. Tersedia: <https://www.kaggle.com/datasets/gunavenkdo/ddi/eye-diseases-classification>
- [25] R. Thanki, "A deep neural network and machine learning approach for retinal fundus image classification," *Healthcare Analytics*, vol. 3, 2023.