

## CESS

(Journal of Computer Engineering, System and Science)

Available online: <https://jurnal.unimed.ac.id/2012/index.php/cess>

ISSN: 2502-714x (Print) | ISSN: 2502-7131 (Online)



### Penerapan Arsitektur EfficientNetB0 pada Model Convolutional Neural Network untuk Deteksi Dini Mata Katarak

#### *Application of EfficientNetB0 on Convolutional Neural Network Model for Early Detection of Cataract*

Rico Apriliansyah<sup>1\*</sup>, Agung Handayanto<sup>2</sup>, Nugroho Dwi Saputro<sup>3</sup>

<sup>1,2,3</sup>Prodi Informatika, Fakultas Teknik dan Informatika, Universitas PGRI Semarang, Indonesia  
Jl. Sidodadi Timur Nomor 24 – Dr. Cipto Semarang - Indonesia

Email: <sup>1</sup>[ricoapriliansyah@gmail.com](mailto:ricoapriliansyah@gmail.com), <sup>2</sup>[agunghan@upgris.ac.id](mailto:agunghan@upgris.ac.id), <sup>3</sup>[nugrohods@upgris.ac.id](mailto:nugrohods@upgris.ac.id)

\*Corresponding Author

#### ABSTRAK

Katarak merupakan penyebab utama kebutaan di dunia, terutama pada lansia, dan dapat dicegah jika terdeteksi secara dini. Dengan kemajuan teknologi kecerdasan buatan, deteksi katarak kini dapat dilakukan melalui pengolahan citra mata secara otomatis. Penelitian ini mengusulkan penerapan arsitektur EfficientNetB0 sebagai model klasifikasi gambar mata untuk membedakan antara mata normal dan mata yang terindikasi katarak. Dataset yang digunakan terdiri dari 612 gambar yang diperoleh dari Kaggle, dengan dua kelas yaitu normal dan katarak. Model dikembangkan menggunakan teknik *transfer learning* dan dilatih selama 15 epoch. Evaluasi kinerja klasifikasi dilakukan dengan memanfaatkan *confusion matrix* dan *classification report* dengan menghitung metrik akurasi, presisi, recall, dan f1-score. Pada pengujian model yang telah dibuat mendapatkan hasil tingkat performa model yang tinggi, ditandai dengan akurasi 98% serta skor precision, recall, dan f1-score yang sama-sama mencapai 0,98 untuk kedua kelas. Untuk penerapan praktis, model diintegrasikan ke dalam aplikasi berbasis web menggunakan Streamlit agar dapat digunakan secara langsung oleh pengguna. Hasil penelitian ini menunjukkan bahwa EfficientNetB0 merupakan arsitektur yang efisien dan andal dalam mendeteksi katarak secara otomatis melalui citra mata.

**Kata Kunci:** *deteksi katarak; EfficientNetB0; CNN; deep learning; streamlit.*

#### ABSTRACT

Cataracts are a leading cause of blindness worldwide, particularly among the elderly, and can be prevented if detected early. With the advancement of artificial intelligence technologies, cataract detection can now be performed automatically through ocular image processing. This study proposes the implementation of the EfficientNetB0 architecture as a classification



model for eye images to distinguish between normal eyes and eyes with cataract indications. The dataset used consists of 612 images obtained from Kaggle, categorized into two classes: normal and cataract. The model was developed using transfer learning techniques and trained for 15 epochs. The classification performance was evaluated using a confusion matrix and a classification report by calculating metrics accuracy, precision, recall, and f1-score. The testing results demonstrated a high level of performance, indicated by an accuracy of 98% and precision, recall, and f1-score values all reaching 0.98 for both classes. For practical implementation, the model was integrated into a web-based application using Streamlit to allow users to utilize the system directly. The findings indicate that EfficientNetB0 is an efficient and reliable architecture for automatically detecting cataracts through ocular images.

**Keywords:** *cataract detection; EfficientNetB0; CNN; deep learning; streamlit.*

---

## 1. PENDAHULUAN

Katarak merupakan gangguan penglihatan yang paling umum dan menjadi penyebab utama kebutaan di dunia. Menurut laporan yang dirilis dari *World Health Organization (WHO)*, katarak menjadi penyebab utama kebutaan secara global, dengan kontribusi lebih dari 50% terhadap total kasus kehilangan penglihatan di dunia [1]. Di Indonesia, prevalensi katarak juga cukup tinggi, terutama pada kelompok usia lanjut. Merujuk pada temuan survei nasional *Rapid Assessment of Avoidable Blindness (RAAB)* yang telah dilaksanakan antara tahun 2014 hingga 2016 dari Kementerian Kesehatan, angka kebutaan di Indonesia mencapai 3% pada populasi usia 50 tahun ke atas dengan katarak sebagai penyebab tertinggi sebesar 81% [2]. Pada tahun 2017, dilaporkan bahwa dari total 8 juta individu dengan gangguan penglihatan, sekitar 1,6 juta mengalami kebutaan, sementara 6,2 juta sisanya menderita gangguan penglihatan tingkat sedang hingga berat, dengan katarak menjadi penyebab utama pada 81,2% kasus tersebut.

Deteksi dini katarak sangat penting karena penyakit ini dapat diatasi melalui tindakan medis seperti operasi penggantian lensa. Dengan kemajuan teknologi pengolahan citra dan kecerdasan buatan sekarang ini, deteksi dini mata katarak kini dapat dilakukan secara otomatis dengan tingkat akurasi yang tinggi. Penerapan metode CNN pada deteksi dini mata katarak telah diterapkan pada penelitian terdahulu [3]. Dari studi penelitian sebelumnya yang telah dilakukan oleh Fanny Ramadhani et al. berhasil menerapkan CNN untuk mendeteksi dini mata katarak dengan memperoleh tingkat akurasi sebesar 92,5% [4]. Dalam studi penelitian yang dilakukan oleh Widyawati et al. juga menggunakan model CNN dengan arsitektur VGG-16 yang mendapatkan hasil akurasi sebesar 96,4% [5]. Hasil ini menunjukkan potensi besar penggunaan deep learning dalam bidang Kesehatan [6].

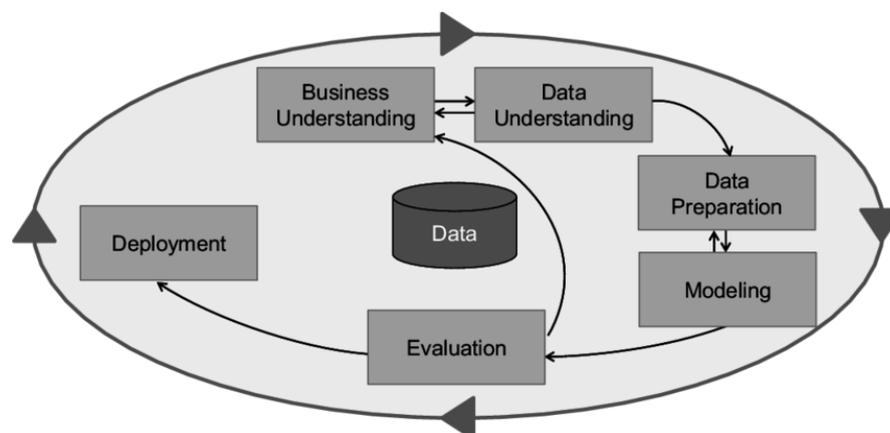
Dari penelitian penelitian sebelumnya CNN konvensional sering kali memiliki jumlah parameter yang besar dan membutuhkan sumber daya komputasi tinggi. Oleh karena itu, dibutuhkan pendekatan yang lebih efisien namun tetap mempertahankan atau bahkan meningkatkan akurasi prediksi. Salah satu arsitektur yang menonjol adalah EfficientNet, yang diperkenalkan oleh Google AI. EfficientNet menggunakan teknik compound scaling untuk secara proporsional menyeimbangkan kedalaman (*depth*), lebar (*width*), dan resolusi input dari model, yang membuatnya jauh lebih efisien dibandingkan CNN konvensional seperti VGG atau ResNet [7]. Perlu diketahui kalau arsitektur EfficientNet ini juga masih termasuk bagian dari model CNN. Dalam penelitian ini, digunakan EfficientNetB0, versi dasar dari keluarga EfficientNet, yang sudah di-pretrained pada ImageNet dan memiliki keunggulan dalam hal

ukuran model yang ringan namun tetap mempertahankan akurasi tinggi. Dibandingkan dengan CNN standar, EfficientNetB0 memiliki struktur yang lebih ringan, efisien, dan terbukti mampu mencapai akurasi tingkat tinggi dengan jumlah parameter yang lebih kecil [8]. EfficientNetB0 juga dipilih karena merupakan varian paling ringan dalam keluarga EfficientNet, sehingga lebih sesuai untuk implementasi dalam aplikasi deteksi dini berbasis web atau Streamlit [9]. Dengan demikian, penggunaan EfficientNetB0 pada CNN untuk deteksi dini katarak menjadi langkah strategis untuk menciptakan sistem deteksi secara efisien dan akurat.

Untuk itu, penelitian ini mengembangkan metode deteksi dini katarak berbasis arsitektur EfficientNetB0 pada model CNN. Arsitektur ini dipilih sebagai alternatif dari CNN konvensional untuk meningkatkan efisiensi sekaligus meningkatkan performa akurasi. Penelitian ini bertujuan untuk mengevaluasi kemampuan EfficientNetB0 dalam mendeteksi dini mata katarak secara otomatis dan membandingkannya dengan hasil penelitian sebelumnya, serta menerapkannya ke dalam bentuk aplikasi sederhana berbasis *web app* menggunakan Streamlit. Selain itu, akses terhadap fasilitas pemeriksaan mata masih terbatas di banyak wilayah, terutama di daerah pelosok. Hal ini menyebabkan banyak kasus katarak yang tidak terdiagnosis secara dini. Dengan dibuatnya sistem deteksi dini mata katarak ini, pemeriksaan awal dapat dilakukan secara cepat, efisien, dan mandiri menggunakan citra mata yang diambil dari kamera smartphone atau kamera fundus sederhana.

## 2. METODE PENELITIAN

Penelitian ini menerapkan metode *CRISP-DM (Cross Industry Standard Process for Data Mining)* sebagai kerangka utama metodologis dalam merancang sistem deteksi dini katarak. *CRISP-DM (Cross-Industry Standard Process for Data Mining)* dikembangkan sebagai pendekatan terstruktur untuk memandu proses analisis data lintas industri secara efisien. Metodologi ini dirancang sebagai kerangka kerja standar yang bertujuan mendukung pemecahan permasalahan maupun penelitian berbasis data secara sistematis dan efisien. CRISP-DM menguraikan enam tahapan utama yang saling berkesinambungan, meliputi tahap *Business Understanding, Data Understanding, Data Preparation, Modeling, Evaluation*, serta *Deployment* [10]. Proses tahapan yang disebutkan tadi digambarkan pada Gambar 1. dibawah ini:



Gambar 1. CRISP-DM

### 2.1. Bussines Understanding

Fase ini bertujuan untuk memahami tujuan utama dari penelitian. Masalah yang diangkat adalah tingginya angka kebutaan akibat penyakit katarak, terutama pada populasi usia lanjut [11]. Oleh karena itu, dibutuhkan sistem deteksi dini yang efisien dan akurat supaya penanganan dapat dilakukan dengan cepat. Penelitian ini memiliki tujuan untuk mengembangkan model deteksi dini katarak secara otomatis dengan memanfaatkan CNN yang berbasis arsitektur EfficientNetB0, yang kemudian diimplementasikan dalam bentuk aplikasi web berbasis streamlit untuk memudahkan penggunaannya oleh praktisi medis atau masyarakat umum.

### 2.2. Data Understanding

Dataset dalam penelitian ini diambil dari platform Kaggle, yang menyediakan sumber data terbuka dengan koleksi dataset yang relevan untuk kebutuhan penelitian ini [4]. Dataset yang digunakan berjudul *Cataract Image Dataset* dan diperoleh melalui tautan <https://www.kaggle.com/datasets/nandanp6/cataract-image-dataset>. Dataset ini berisi dari 612 file gambar mata yang terdiri dari dua kelas yaitu normal dan cataract. Struktur data terbagi dalam folder *train* yang berisi 491 data gambar dan *test* yang berisi 121 data gambar, yang di dalamnya berisi subfolder untuk masing masing kelas. Dataset langsung diambil dari Kaggle langsung menggunakan kagglehub. Gambar 2. dan Gambar 3. di bawah ini adalah contoh gambar dari masing-masing kelas dalam dataset:



Gambar 2. Mata Katarak



Gambar 3. Mata Normal

### 2.3. Data Preparation (Pre-Processing)

Pada tahap ini, dilakukan serangkaian proses preprocessing untuk menyiapkan data sebelum dimasukkan ke dalam model. Proses ini mencakup mengubah ukuran citra (resize), normalisasi piksel, augmentasi citra, serta pembagian data latih dan validasi. Langkah-langkah tersebut dilaksanakan agar data yang diperoleh memiliki format dan distribusi yang konsisten agar model dapat belajar secara optimal. Dalam penelitian ini dilakukan proses resize yaitu mengubah ukuran semua gambar menjadi resolusi seragam agar sesuai dengan input model, normalisasi dengan cara membagi nilai piksel agar berada pada skala yang sama [12], [13]. Karena dataset tidak menyediakan data validasi secara terpisah, maka data latih (*train*) secara otomatis dibagi menjadi 80% yang akan digunakan untuk pelatihan model (*training*) dan 20% digunakan untuk proses validasi (*validation*) [14]. Selain itu, diterapkan juga augmentasi citra pada data pelatihan sebagai strategi untuk memperluas keragaman data secara artifisial tanpa perlu menambah jumlah data manual. Teknik augmentasi yang digunakan meliputi rotasi acak, flipping horizontal, serta *zoom-in* dan *zoom-out* [15].

### 2.4. Modelling

Dalam penelitian ini, pemodelan dilakukan dengan mengadopsi EfficientNetB0, yang pada dasarnya merupakan salah satu varian arsitektur dari CNN modern [9]. EfficientNetB0 tetap menggunakan prinsip dasar CNN, yaitu proses ekstraksi fitur citra melalui lapisan

konvolusi (convolutional layers), pooling, dan aktivasi non-linear, sehingga seluruh proses pembelajaran citra tetap mengandalkan operasi konvolusional yang sudah terbukti efektif dalam domain klasifikasi gambar [8]. Fitur-fitur CNN klasik tetap dipertahankan di dalam blok-blok dasar EfficientNetB0, termasuk *convolutional layers* untuk *feature extraction*, *batch normalization*, dan *activation function swish* yang digunakan menggantikan ReLU pada beberapa bagian untuk meningkatkan akurasi [7]. Dengan demikian, pemanfaatan EfficientNetB0 pada penelitian ini dapat dipahami sebagai penerapan CNN yang dioptimalkan secara arsitektural, bukan sebagai pendekatan yang sepenuhnya berbeda.

Pada tahap modeling, dilakukan beberapa langkah utama, yaitu memuat *base model* EfficientNetB0 tanpa *top layer*, menerapkan *transfer learning* dengan bobot pra-latih dari *ImageNet*, menambahkan *custom classifier* untuk klasifikasi dua kelas (Normal dan Katarak), serta menyusun konfigurasi pelatihan yang mencakup penggunaan *loss function categorical crossentropy*, *optimizer Adam*, dan skema *early stopping*. Proses pelatihan dilakukan selama maksimal 15 epoch, dengan pemantauan akurasi validasi secara bertahap untuk memastikan model dapat melakukan generalisasi terhadap data baru secara efektif.

## 2.5. Evaluation

Evaluasi model yang telah dibuat dilakukan pengujian dengan menggunakan data *testing* yang telah disiapkan untuk mengukur kinerjanya. Pengujian dilakukan dengan fokus pada dua metrik utama, yaitu *loss* yang menunjukkan tingkat kesalahan prediksi, dan akurasi yang merepresentasikan proporsi prediksi tepat terhadap keseluruhan data uji. Nilai akurasi validasi ditampilkan dalam bentuk persentase sebagai keluaran akhir, sehingga memberikan gambaran kemampuan model dalam mengklasifikasikan data baru. [4]

Selain itu, evaluasi juga disertai dengan *classification report* yang menyajikan nilai *precision*, *recall*, *F1-score*, serta jumlah sampel (*support*) untuk setiap kelas. *Precision* menunjukkan ketepatan prediksi positif, sedangkan *recall* menggambarkan kemampuan model dalam mengidentifikasi seluruh sampel positif secara tepat. *F1-score* merupakan metrik yang dihitung sebagai rata-rata harmonik antara *precision* dan *recall* untuk menilai sejauh mana model mencapai keseimbangan performa [8]. Lalu, dilakukan juga evaluasi menggunakan *confusion matrix* untuk memvisualisasikan distribusi prediksi yang tepat yaitu *true positive* dan *true negative*, serta prediksi yang keliru yaitu *false positive* dan *false negative*, sehingga membantu mengidentifikasi pola kesalahan dan potensi bias prediksi model terhadap kelas tertentu. Berikut merupakan rumus dalam menghitung metrik evaluasi, yaitu akurasi, *precision*, *recall*, dan *f1-score*:

$$\text{Akurasi} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \times 100 \quad [6]$$

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad [6]$$

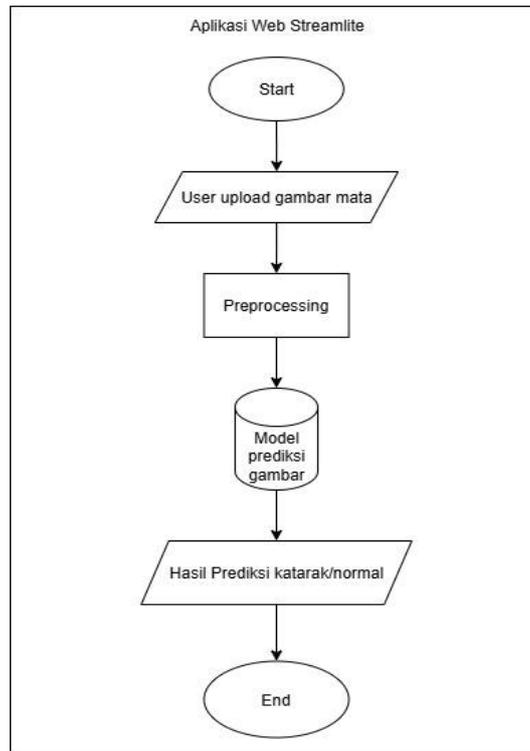
$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad [6]$$

$$\text{F1 - Score} = \frac{2 \times \text{Recall} \times \text{Precision}}{\text{Recall} + \text{Precision}} \times 100 \quad [6]$$

## 2.6. Deployment

Tahap deployment direncanakan dalam bentuk aplikasi berbasis web menggunakan Streamlit, yang memungkinkan prediksi kondisi mata secara real-time berdasarkan input

gambar dari pengguna [15]. Model hasil pelatihan akan disimpan dan diintegrasikan ke dalam antarmuka aplikasi, sehingga dapat dipanggil ulang secara otomatis saat prediksi dilakukan. Untuk mendukung pengembangan aplikasi ini, desain sistem dibuat menggunakan *flowchart* yang menggambarkan alur kerja secara menyeluruh, mulai dari proses unggah gambar, preprocessing gambar yang diunggah, pemrosesan prediksi data gambar oleh model, hingga penampilan hasil prediksi kepada pengguna. Pendekatan ini menjadikan desain lebih terstruktur, mudah dipahami, dan dapat menjadi acuan yang jelas dalam tahap implementasi dan pengujian aplikasi. Gambar 7. Dibawah ini merupakan *flowchart* aplikasi web streamlitnya:



Gambar 7. *Flowchart* Aplikasi Streamlit

### 3. HASIL DAN PEMBAHASAN

Berdasarkan rangkaian tahapan metodologis yang telah dilaksanakan, model deteksi katarak menggunakan arsitektur EfficientNetB0 telah berhasil diimplementasikan dan diuji. Tahapan yang telah dilakukan disajikan pada penjelasan berikut:

#### 3.1. Preprocessing

Sebelum proses pelatihan model dilakukan, seluruh citra terlebih dahulu melalui tahap preprocessing agar format dan karakteristik datanya sesuai dengan kebutuhan arsitektur EfficientNetB0. Data yang telah dikumpulkan kemudian diproses dalam beberapa tahapan berikut:

- *Resize Image*: Semua gambar diubah ukurannya menjadi 224x224 piksel untuk disesuaikan dengan input EfficientNetB0. Ukuran ini dipilih agar fitur spasial pada citra dapat diproses secara optimal oleh jaringan konvolusional.
- *Normalisasi*: Setiap piksel pada gambar dilakukan normalisasi ke dalam rentang [0,1] dengan membagi nilai intensitas RGB masing-masing piksel dengan 255 agar model dapat belajar secara optimal.

- Augmentasi: Augmentasi citra diterapkan pada data latih untuk meningkatkan variasi data dan mencegah *overfitting*. Teknik augmentasi mencakup rotasi, *flipping horizontal*, dan *zoom*. Teknik ini bertujuan meningkatkan keragaman data secara artifisial sehingga model menjadi lebih robust terhadap variasi orientasi, pencahayaan, dan skala objek.
- *Split Dataset*: Dikarenakan belum ada data *validation*, maka dilakukan pembagian data *train* yang dibagi menjadi 80% yang akan digunakan untuk pelatihan model (*training*) dan 20% digunakan untuk proses validasi (*validation*). Dimana yang awalnya dataset *train* sebesar 491 data, dibagi menjadi 393 data untuk pelatihan (*train*) dan 98 data untuk validasi (*validation*), sedangkan untuk data *testing* tetap sebesar 121. Pembagian ini digunakan untuk memantau performa model secara independen selama pelatihan.

Untuk hasil pembagian dataset sebagaimana ditampilkan pada Gambar 4. di bawah ini:

```
Found 393 images belonging to 2 classes.  
Found 98 images belonging to 2 classes.  
Found 121 images belonging to 2 classes.
```

Gambar 4. Hasil *Split Data Train*

Keseluruhan tahapan preprocessing ini bertujuan untuk memastikan citra yang diolah memiliki format yang konsisten, bersih, dan bervariasi sehingga mendukung proses pembelajaran yang efektif.

### 3.2. Modelling

Pada fase ini, dilakukan pemodelan menggunakan arsitektur EfficientNetB0, yang merupakan bagian dari keluarga EfficientNet dan termasuk dalam kategori Convolutional Neural Network (CNN) modern. Model di-fine-tune menggunakan transfer learning dari bobot pra-latih pada dataset ImageNet. Konfigurasi model meliputi:

- Base Model: EfficientNetB0 tanpa top layer (*include\_top=False*), berfungsi sebagai pengekstraksi fitur citra retina secara efisien. Bobot awal ImageNet dimanfaatkan agar model memiliki pengetahuan dasar pola visual.
- Custom Classifier: Satu lapisan Dense dengan dua neuron sesuai jumlah kelas (normal dan katarak) menggunakan aktivasi softmax untuk menghasilkan distribusi probabilitas klasifikasi.
- Loss Function: Categorical Crossentropy, digunakan untuk mengukur selisih distribusi prediksi terhadap label asli dalam tugas klasifikasi dua kelas.
- Optimizer: Adam optimizer dengan learning rate awal 0.0001, dipilih karena stabil dan cepat dalam proses konvergensi.

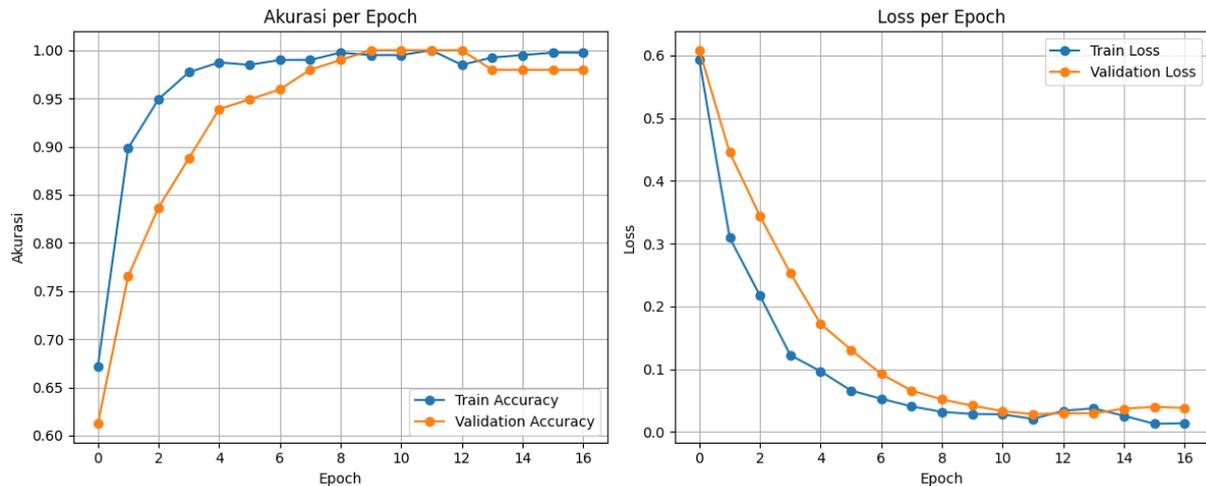
Pelatihan dilakukan hingga maksimal 15 epoch dengan callback EarlyStopping untuk menghentikan training jika akurasi validasi tidak membaik. Seluruh konfigurasi ini dirancang agar model akurat, efisien, dan mampu melakukan generalisasi terhadap data baru.

### 3.3. Hasil Pelatihan Model dan Evaluasi

Model yang sudah dibuat dilatih menggunakan data training gambar mata dengan dua kelas (cataract dan normal) sebanyak 15 epoch dengan menggunakan early stopping dari monitoring *val\_loss*. Dari proses pelatihan selama 15 epoch tersebut diperoleh akurasi validasi tertinggi sebesar 98,08% dengan nilai loss yang terus menurun secara stabil. Hal ini menunjukkan konvergensi yang baik. Nilai akurasi yang mencapai 98% menunjukkan kinerja

yang sangat tinggi, namun tidak mutlak sempurna. Setelah mendapatkan akurasi yang tinggi dilakukan evaluasi dengan memanfaatkan confusion matrix pada data pengujian (*train*). untuk mengecek performa model yang ternyata baik dimana dari 121 gambar hanya 3 gambar yang mengalami kesalahan klasifikasi.

Apabila dilakukan perbandingan dengan penelitian terdahulu yang dibuat oleh Widyawati et al. mendapatkan hasil 96,4% [5]. model yang dibuat ini sudah membuktikan peningkatannya bahwa dengan menggunakan arsitektur EfficientNetB0 hasil yang diperoleh bisa lebih maksimal lagi dan tidak membutuhkan komputasi yang besar dikarenakan modelnya sangat ringan sekali.



Gambar 8. Akurasi dan Loss

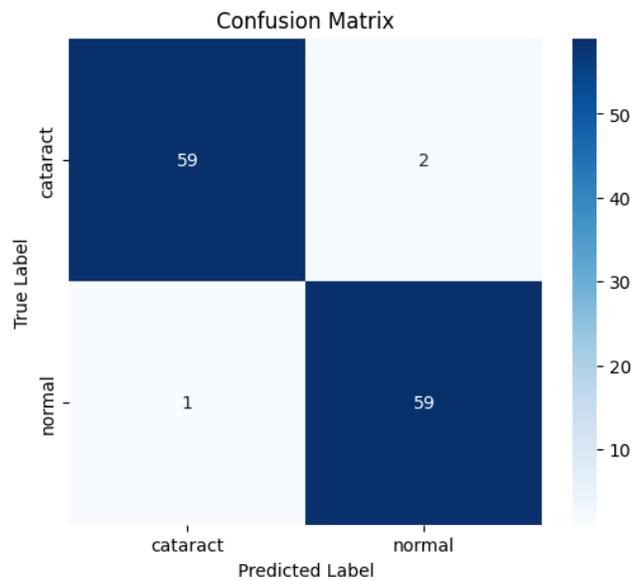
Dari grafik pada Gambar 8. diatas didapatkan hasil bahwa tingkat akurasi pada data pelatihan (*training*) sebesar 0,97 dan *loss* sebesar 0,0198, adapun akurasi yang diperoleh pada data validasi adalah 0,98 dan *loss* sebesar 0,0228. Hal ini menunjukkan bahwa model mengalami peningkatan performa secara bertahap tanpa tanda *overfitting* yang signifikan. Ini menandakan model berhasil belajar fitur penting dari citra dengan baik. Hasil ini menunjukkan bahwa arsitektur EfficientNetB0 mampu mengenali pola visual yang relevan dalam citra fundus secara efektif dan efisien.

Tabel 1. Classification Report

Classification Report:				
	precision	recall	f1-score	support
cataract	0.98	0.97	0.98	61
normal	0.97	0.98	0.98	60
accuracy			0.98	121
macro avg	0.98	0.98	0.98	121
weighted avg	0.98	0.98	0.98	121

Dilihat dari Tabel 1. Clasification Report diatas model memiliki nilai precision sebesar 0,98, recall 0,98, dan f1-score 0,98 yang seimbang untuk kedua kelas, dengan rata rata akurasi keseluruhan sebesar 98%. Hal ini menunjukkan model tidak bias terhadap salah satu kelas, dan memiliki generalisasi yang baik terhadap data baru.

Model dievaluasi menggunakan data *test* untuk mengevaluasi kemampuan klasifikasi dengan *confusion matrix*. Hasil *confusion matrix* dapat dilihat pada Gambar 9. di bawah ini:



Gambar 9. *Confusion Matrix*

Berikut ini adalah rincian nilai yang diperoleh dari *confusion matrix* hasil pengujian model pada Gambar 9. diatas:

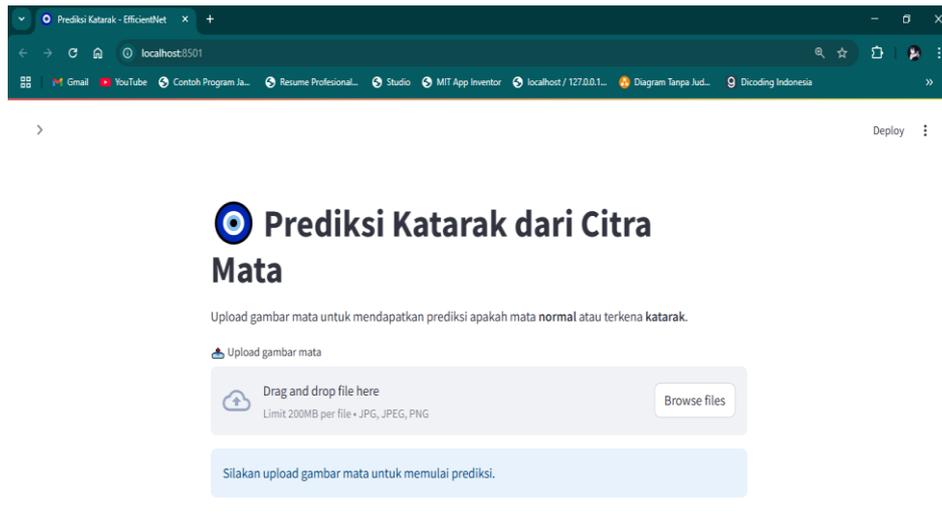
- *True Positive* (TP) sebanyak 59, yaitu kasus yang secara tepat teridentifikasi sebagai Katarak.
- *True Negative* (TN) berjumlah 59, yang menunjukkan prediksi benar terhadap kondisi Normal.
- *False Positive* (FP) tercatat sebanyak 1, yakni kasus yang keliru diklasifikasikan sebagai Katarak padahal sebenarnya Normal.
- *False Negative* (FN) sebanyak 2, yaitu kondisi ketika model salah memprediksi citra Katarak sebagai Normal.

Dari hasil gambar diatas menunjukkan model hanya melakukan 3 kesalahan klasifikasi dari total 121 gambar uji, dengan performa sangat baik pada kedua kelas. Tingginya nilai *True Positive* dan *True Negative* mengindikasikan bahwa model dapat diandalkan untuk untuk aplikasi nyata.

### 3.4. Implementasi Streamlit

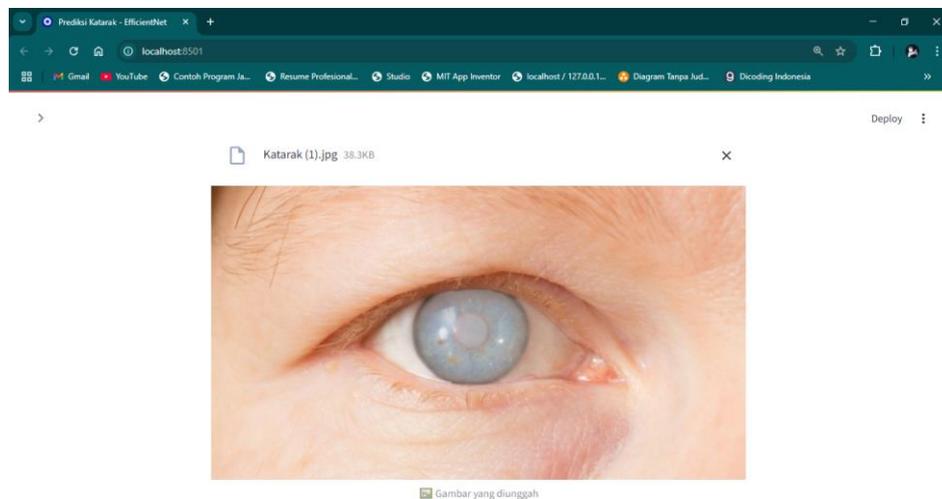
Sebagai hasil akhir, model yang telah dilatih diimplementasikan ke dalam aplikasi streamlit sebagai bentuk penerapan nyata dari penelitian ini. Untuk mengintegrasikannya model disimpan terlebih dahulu dengan format file .h5, lalu dilakukan *load data* pada kode aplikasinya yaitu app.py. Setelah itu file app.py di *run* di terminal *VS Code* yang menghasilkan output link website dengan menggunakan server lokal. Aplikasi ini memungkinkan pengguna untuk mengunggah gambar matadan menerima prediksi instan mengenai status mata yaitu normal atau terindikasi katarak. Tampilan antarmuka dibuat sederhana dan mudah digunakan oleh tenaga medis ataupun masyarakat awam. Adapun fitur yang ditampilkan pada streamlitnya sebagai berikut:

- Upload gambar mata, langkah pertama yang dilakukan user adalah upload gambar mata yang akan diprediksi seperti Gambar 10.



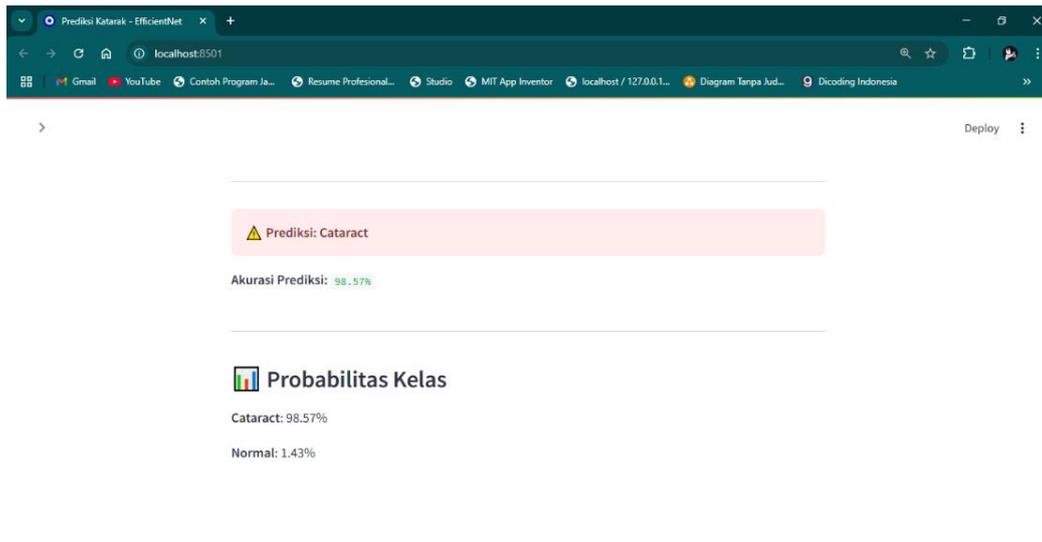
Gambar 10. Tampilan Awal

- Visualisasi gambar input, sistem menampilkan gambar yang diunggah seperti Gambar 11.



Gambar 11. Tampilan gambar yang diupload

- Akurasi prediksi gambar tersebut, sistem menampilkan akurasi prediksi seperti Gambar 12.
- Output hasil klasifikasi (normal/katarak), sistem menampilkan hasil prediksi seperti Gambar 12.



Gambar 12. Tampilan setelah dilakukan prediksi

#### 4. KESIMPULAN

Penelitian ini bertujuan mengatasi permasalahan tingginya angka kebutaan akibat katarak dengan mengembangkan sistem deteksi dini menggunakan arsitektur EfficientNetB0. Seperti yang dijelaskan pada bagian pendahuluan, dibutuhkan metode yang efisien dan akurat untuk mendeteksi katarak secara otomatis. Hasil yang diperoleh pada penelitian ini yaitu model EfficientNetB0 berhasil mencapai akurasi sebesar 98%, dengan nilai *precision*, *recall*, dan *F1-score* masing-masing sebesar 0,98. Hasil tersebut membuktikan kalau model yang dibuat telah berhasil memenuhi ekspektasi awal, yakni menciptakan sistem prediksi yang ringan namun akurat. Selain itu, integrasi model ke dalam aplikasi berbasis streamlit semakin memperkuat potensi penggunaannya dalam dunia nyata, baik oleh tenaga medis maupun masyarakat umum.

Meskipun demikian, penelitian kali ini masih mempunyai sejumlah keterbatasan, seperti jumlah data yang tergolong terbatas serta variasi kondisi citra yang masih homogen. Model juga belum diuji pada data citra fundus dengan resolusi sangat rendah atau noise tinggi yang sering dijumpai pada praktik pemeriksaan lapangan. Ke depannya, penelitian ini dapat dikembangkan lebih lanjut dengan mengeksplorasi varian arsitektur EfficientNet lainnya seperti B1 dan B3, serta menguji model terhadap dataset yang lebih besar, luas, dan beragam guna meningkatkan kemampuan generalisasi sistem. Penerapan lebih luas juga dapat mencakup integrasi dengan perangkat mobile atau sistem kesehatan digital guna mendukung pemeriksaan mata secara mandiri dan cepat di berbagai wilayah.

#### DAFTAR PUSTAKA

- [1] F. N. Cahya, N. Hardi, D. Riana, dan S. Hadiyanti, "Klasifikasi Penyakit Mata Menggunakan Convolutional Neural Network (CNN)," *SISTEMASI*, vol. 10, no. 3, hlm. 618, Sep 2021, doi: 10.32520/stmsi.v10i3.1248.
- [2] A. Wulandari, R. R. M. Putri, dan A. S. Budi, "Implementasi Algoritma Xception pada Sistem Deteksi Katarak Menggunakan Raspberry Pi Berbasis Citra Mata".

- [3] R. E. Mulyani, M. R. Erfiyanto, F. R. P. Pratama, T. Dimas, dan M. F. Hidayattullah, "Penerapan Algoritma Convolutional Neural Network (CNN) Deteksi Kesehatan Mata".
- [4] F. Ramadhani, A. Satria, dan S. Salamah, "Implementasi Algoritma Convolutional Neural Network dalam Mengidentifikasi Dini Penyakit pada Mata Katarak," *Sudo J. Tek. Inform.*, vol. 2, no. 4, hlm. 167–175, Des 2023, doi: 10.56211/sudo.v2i4.408.
- [5] R. Sidik, E. Nuryani, dan P. H. Winasis, "Rancang Bangun Sistem Deteksi Katarak Menggunakan Metode Convolutional Neural Network," vol. 7, no. 1, 2025.
- [6] Z. Arif, R. Y. Nur Fu'adah, S. Rizal, dan D. Ilhamdi, "Classification of eye diseases in fundus images using Convolutional Neural Network (CNN) method with EfficientNet architecture," *JRTI J. Ris. Tindakan Indones.*, vol. 8, no. 1, hlm. 125, Jul 2023, doi: 10.29210/30032835000.
- [7] E. C. Yaurentius, T. R. D. Saputri, E. Tanuwijaya, dan R. E. Sutanto, "Comparative Study of CNN-Based Architectures on Eye Diseases Classification Using Fundus Images to Aid Ophthalmologist," *J. Tek. Inform. Jutif*, vol. 6, no. 1, hlm. 249–257, Feb 2025, doi: 10.52436/1.jutif.2025.6.1.3699.
- [8] W. R. Perdani, R. Magdalena, dan N. K. Caecar Pratiwi, "Deep Learning untuk Klasifikasi Glaukoma dengan menggunakan Arsitektur EfficientNet," *ELKOMIKA J. Tek. Energi Elektr. Tek. Telekomun. Tek. Elektron.*, vol. 10, no. 2, hlm. 322, Apr 2022, doi: 10.26760/elkomika.v10i2.322.
- [9] P. Eko Niti Taruno, G. Satya Nugraha, R. Dwiyanaputra, dan F. Bimantoro, "Monkeypox Classification based on Skin Images using CNN: EfficientNet-B0," *E3S Web Conf.*, vol. 465, hlm. 02031, 2023, doi: 10.1051/e3sconf/202346502031.
- [10] D. Saputra dan T. Y. Hadiwandra, "Classification Of Letters And Numbers In Bisindo Using The Convolutional Neural Network Method," 2024.
- [11] C. A. Putri dan S. Rakasiwi, "Diagnosis Dini Penyakit Mata: Klasifikasi Citra Fundus Retina dengan Convolutional Neural Network VGG-16," *Edumatic J. Pendidik. Inform.*, vol. 9, no. 1, hlm. 208–216, Apr 2025, doi: 10.29408/edumatic.v9i1.29571.
- [12] C. R. Mulyasari, A. I. Hadiana, dan A. Komarudin, "Deteksi Penyakit Diabetes, Katarak dan Glaukoma Pada Citra Fundus Retina Mata Manusia Menggunakan CNN Dengan Arsitektur Alexnet".
- [13] A. Rusdy Prasetyo, Sussi, dan B. Aditya, "Analisis Perbandingan Algoritma Support Vector Machine (SVM) Dan Convolutional Neural Network (CNN) Untuk Sistem Deteksi Katarak," *J. Ilm. Tek. Mesin Elektro Dan Komput.*, vol. 3, no. 1, hlm. 1–10, Mar 2023, doi: 10.51903/juritek.v3i1.604.
- [14] I. Santoso, A. M. Manurung, dan E. R. Subhiyakto, "Comparison of ResNet-50, EfficientNet-B1, and VGG-16 Algorithms for Cataract Eye Image Classification," vol. 9, no. 2.
- [15] A. A. Pratama dan F. Utaminingrum, "Sistem Pendeteksi Tingkat Keparahan Katarak Berdasarkan Citra Digital Menggunakan Metode U-Net dan CNN".