

Penerapan Deep Learning Untuk Klasifikasi Penyakit Mata Menggunakan Metode Convolutional Neural Network

Alfarida Dewi Aprilia¹, Arius Satoni Kurniawansyah², Yupianti³

¹Mahasiswa Program Studi Informatika Fakultas Ilmu Komputer Universitas Dehasen Bengkulu,
e-mail: alfaridadewi5@gmail.com

^{2,3}Dosen Program Studi Informatika Fakultas Ilmu Komputer Universitas Dehasen Bengkulu
e-mail: ariussatonikurniawansyah@unived.ac.id, yupianti@unived.ac.id

Jl. Meranti Raya No. 32 Kota Bengkulu 38228 Telp. (0736) 22027, 26957 Fax. (0736) 341139

Received: Juni 2026, Revised: Agustus 2026, Accepiend: Oktober 2026)

Abstract—Eye diseases such as cataracts, diabetic retinopathy, and glaucoma are among the leading causes of visual impairment and can result in blindness if not detected at an early stage. The application of Deep Learning technology, particularly Convolutional Neural Networks (CNNs), provides an opportunity to support the automatic classification of eye diseases based on retinal fundus images. This study aims to develop an eye disease classification model using the EfficientNetB0 architecture with a transfer learning approach. The dataset used was the Eye Diseases Classification dataset from Kaggle, consisting of 4,217 retinal fundus images categorized into four classes: Cataract, Diabetic Retinopathy, Glaucoma, and Normal. Before the training process, the images underwent preprocessing, including image resizing, normalization, and data augmentation. The model was trained using the Tensor Flow/Keras framework in the Google Colab environment and evaluated using accuracy, precision, recall, F1-score, and confusion matrix metrics. The experimental results showed that the proposed model achieved an overall accuracy of 73.23%. The Cataract class demonstrated the best performance, with a precision of 0.78, a recall of 0.92, and an F1-score of 0.84. In contrast, the Glaucoma class obtained the lowest recall of 0.36, indicating that the model still encountered difficulties in correctly identifying a considerable number of glaucoma images. Overall, the results indicate that the EfficientNetB0 architecture is capable of classifying eye diseases from retinal fundus images with satisfactory performance. However, increasing the dataset size, optimizing preprocessing techniques, and applying more extensive fine-tuning are recommended to further improve the model's performance, particularly in glaucoma classification.

Keyword: Deep Learning, Convolutional Neural Network (CNN), EfficientNetB0, Transfer Learning, Eye Disease Classification, Retinal Fundus Images.

Intisari—Penyakit mata seperti katarak, diabetic retinopathy, dan glaukoma merupakan penyebab utama gangguan penglihatan yang dapat berujung pada kebutaan apabila tidak dideteksi sejak dini. Pemanfaatan teknologi Deep Learning, khususnya Convolutional Neural Network (CNN), memberikan peluang untuk membantu proses klasifikasi penyakit mata secara otomatis berdasarkan citra fundus retina. Penelitian ini bertujuan mengembangkan model klasifikasi penyakit mata menggunakan arsitektur EfficientNetB0 dengan pendekatan transfer learning. Dataset yang digunakan merupakan Eye Diseases Classification dari Kaggle yang terdiri atas 4.217 citra fundus retina dengan empat kelas, yaitu Katarak, Diabetic Retinopathy, Glaukoma, dan Normal. Sebelum proses pelatihan, citra melalui tahap preprocessing yang meliputi resize, normalisasi, dan data augmentation. Model dilatih menggunakan framework TensorFlow/Keras pada lingkungan Google Colab, kemudian dievaluasi menggunakan metrik accuracy, precision, recall, F1-score, dan confusion matrix. Hasil pengujian menunjukkan

bahwa model memperoleh akurasi sebesar 73,23%. Kelas Katarak memberikan performa terbaik dengan precision 0,78, recall 0,92, dan F1-score 0,84, sedangkan kelas Glaukoma memiliki recall terendah sebesar 0,36, yang menunjukkan bahwa model masih mengalami kesulitan dalam mengenali sebagian citra glaukoma. Secara keseluruhan, penelitian ini menunjukkan bahwa arsitektur EfficientNetB0 mampu digunakan untuk klasifikasi penyakit mata berbasis citra fundus retina dengan performa yang cukup baik. Peningkatan jumlah dataset, optimalisasi teknik preprocessing, dan proses fine-tuning diperlukan untuk meningkatkan kemampuan model, terutama pada klasifikasi glaukoma.

Kata Kunci: Deep Learning, Convolutional Neural Network, EfficientNetB0, Klasifikasi Penyakit Mata, Citra Fundus Retina.

I. PENDAHULUAN

Penyakit mata merupakan salah satu masalah kesehatan yang dapat menyebabkan penurunan kualitas hidup hingga kebutaan apabila tidak ditangani secara tepat. Katarak, diabetic retinopathy, dan glaukoma termasuk penyakit mata yang sering ditemukan dan membutuhkan deteksi dini untuk mencegah komplikasi yang lebih serius.

Perkembangan kecerdasan buatan, khususnya deep learning, telah memberikan kontribusi besar dalam bidang kesehatan melalui kemampuan analisis citra medis secara otomatis. Salah satu metode yang banyak digunakan adalah Convolutional Neural Network (CNN) yang mampu mengekstraksi fitur citra secara efektif dan menghasilkan tingkat akurasi yang tinggi.

Penelitian ini bertujuan mengembangkan sistem klasifikasi penyakit mata berdasarkan citra fundus retina menggunakan arsitektur EfficientNetB0. Arsitektur ini dipilih karena mampu menghasilkan performa tinggi dengan jumlah parameter yang relatif lebih sedikit dibandingkan model CNN lainnya. Hasil penelitian diharapkan dapat mendukung proses skrining awal penyakit mata secara cepat dan akurat.

II. TINJAUAN PUSTAKA

A. Deep Learning

Deep Learning merupakan salah satu cabang dari *machine learning* yang berlandaskan pada penggunaan Jaringan Saraf Tiruan (JST) dan dapat dianggap sebagai pengembangan lebih lanjut dari metode JST konvensional. Dalam pendekatan ini, sistem komputer mampu mempelajari dan melakukan proses klasifikasi secara langsung dari data mentah, seperti citra maupun sinyal suara, tanpa memerlukan ekstraksi fitur secara manual (Pratiwi et al., 2021).

B. Convolutional Neural Network

Convolutional Neural Network (CNN) adalah jenis jaringan saraf tiruan yang dirancang khusus untuk memproses data berbentuk grid, seperti citra digital, dengan memanfaatkan operasi konvolusi untuk mengekstraksi fitur secara hierarkis dari representasi spasial data (Alzubaidi et al., 2021).

C. Transfer Learning

Transfer learning adalah paradigma pembelajaran mesin di mana pengetahuan yang diperoleh dari menyelesaikan satu tugas (source task) dimanfaatkan untuk meningkatkan performa dalam tugas lain yang berbeda namun berkaitan (target task). Dalam konteks deep learning untuk analisis citra medis, transfer learning mengacu pada penggunaan model CNN yang telah dilatih sebelumnya pada dataset besar seperti ImageNet sebagai titik awal, kemudian diadaptasikan untuk dataset dan tugas spesifik yang diinginkan. Pendekatan ini sangat bermanfaat ketika dataset target yang tersedia relatif terbatas, karena model sudah memiliki representasi fitur visual yang kaya dari proses pre-training


D. EfficientNet B0

EfficientNet merupakan salah satu arsitektur Convolutional Neural Network (CNN) yang dirancang untuk meningkatkan akurasi sekaligus efisiensi dalam pengolahan citra melalui pendekatan compound scaling, yaitu metode yang menyeimbangkan kedalaman (depth), lebar (width), dan resolusi input secara proporsional

sehingga menghasilkan model yang optimal. *EfficientNet-B0* merupakan varian dasar dari keluarga EfficientNet yang menjadi fondasi bagi pengembangan model selanjutnya.

III. METODOLOGI PENELITIAN

Metode penelitian yang digunakan adalah metode rekayasa perangkat lunak (*software engineering research method*) dengan model pengembangan waterfall. Model waterfall dipilih karena tahapan penelitian ini bersifat sekuensial dan linier, di mana setiap fase harus diselesaikan sebelum melanjutkan ke fase berikutnya, sehingga memudahkan pengendalian dan pemantauan kemajuan penelitian.



Gambar 1. Metode Waterfall

Keterangan :

1. Requirements Analysis

Tahap ini dilakukan untuk mengidentifikasi kebutuhan penelitian melalui studi literatur, analisis dataset, serta penentuan kebutuhan sistem. Studi literatur dilakukan dengan mengkaji jurnal, buku, dan penelitian terdahulu mengenai klasifikasi penyakit mata menggunakan metode Deep Learning, khususnya arsitektur Convolutional Neural Network (CNN) dan EfficientNetB0. Dataset yang digunakan adalah Eye Diseases Classification yang diperoleh dari Kaggle dan terdiri atas empat kelas, yaitu Cataract, Diabetic Retinopathy, Glaucoma, dan Normal. Berdasarkan hasil analisis, dipilih arsitektur EfficientNetB0 karena memiliki performa klasifikasi yang baik dengan jumlah parameter yang relatif efisien.

2. System Design

Pada tahap ini dilakukan perancangan arsitektur model dan alur pengolahan data. Citra fundus retina diproses melalui tahap resize menjadi 224×224 piksel, normalisasi, dan data augmentation, kemudian dataset dibagi menjadi data training (70%), validation (15%), dan testing (15%). Model dibangun menggunakan EfficientNetB0 dengan pendekatan transfer learning, di mana lapisan klasifikasi bawaan diganti dengan lapisan Global Average Pooling, Dense, Dropout, dan Softmax untuk menghasilkan empat kelas keluaran.

3. Implementation

Tahap implementasi dilakukan menggunakan Google Colab dengan framework TensorFlow/Keras. Proses implementasi meliputi pemuatan dataset, prapemrosesan citra, pembangunan model EfficientNetB0, proses kompilasi menggunakan optimizer Adam dan fungsi kehilangan Categorical Crossentropy, serta pelatihan model. Model yang telah dilatih kemudian disimpan dalam format .h5 untuk digunakan pada proses prediksi tanpa perlu melakukan pelatihan ulang.

4. Testing

Evaluasi model dilakukan menggunakan data testing dengan metrik accuracy, precision, recall, F1-score, dan confusion matrix. Selain itu, dilakukan analisis terhadap hasil klasifikasi untuk mengetahui performa model pada setiap kelas serta mengidentifikasi kemungkinan terjadinya overfitting atau underfitting. Model juga diuji menggunakan citra uji untuk memastikan proses prediksi berjalan dengan baik dan menghasilkan keluaran sesuai dengan kelas yang diprediksi.

5. Maintenance

Tahap pemeliharaan dilakukan dengan menyimpan model pada Google Drive agar dapat digunakan kembali tanpa proses pelatihan ulang. Selain itu, dilakukan dokumentasi terhadap parameter pelatihan dan hasil evaluasi sebagai dasar pengembangan penelitian selanjutnya, seperti penambahan dataset maupun optimalisasi model untuk meningkatkan akurasi klasifikasi. Ini menggunakan metode eksperimen dengan pendekatan kuantitatif. Dataset yang digunakan adalah Eye Diseases Classification dari Kaggle yang terdiri dari

4.217 citra fundus retina dengan empat kategori penyakit.

A. Dataset

Dataset yang digunakan pada penelitian ini adalah Eye Diseases Classification yang diperoleh dari Kaggle. Dataset terdiri atas 4.217 citra fundus retina yang dikelompokkan ke dalam empat kelas, yaitu Cataract, Diabetic Retinopathy, Glaucoma, dan Normal. Seluruh citra diproses melalui tahap preprocessing berupa resize menjadi ukuran 224×224 piksel, normalisasi nilai piksel ke rentang 0–1, serta data augmentation untuk meningkatkan variasi data pelatihan. Dataset kemudian dibagi menjadi data training (70%), validation (15%), dan testing (15%) sehingga diperoleh data uji sebanyak 637 citra.




Gambar 2. Contoh Dataset Tiap Kelas

IV. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil evaluasi model Convolutional Neural Network (CNN) dalam mengklasifikasikan penyakit mata berdasarkan citra fundus retina. Pengujian dilakukan menggunakan data uji untuk menilai kemampuan model dalam mengidentifikasi setiap kategori penyakit secara akurat. Kinerja model dianalisis melalui confusion matrix dan metrik evaluasi pada masing-masing kelas untuk mengidentifikasi tingkat keberhasilan klasifikasi serta pola kesalahan prediksi. Selain itu, ditampilkan hasil pelatihan model dan visualisasi prediksi yang dijalankan melalui Google Colab sebagai bentuk implementasi model dalam mengklasifikasikan citra penyakit mata.

A. Hasil Pengujian

Untuk mengetahui performa klasifikasi maka dilakukan evaluasi terhadap confusion matrix sebagaimana dapat dilihat pada gambar 3.



Gambar 3. Confusion Matrix

Gambar 3. menunjukkan kemampuan klasifikasi yang baik pada kelas cataract dan normal, dengan masing-masing 957 dan 984 citra berhasil diprediksi secara benar. Sebaliknya, performa pada kelas diabetic retinopathy dan glaucoma masih belum optimal. Kesalahan prediksi terbesar terjadi pada kelas glaucoma, yang sering diklasifikasikan sebagai normal (324 citra) dan cataract (256 citra). Selain itu, sebanyak 302 citra diabetic retinopathy juga diprediksi sebagai normal. Hasil tersebut mengindikasikan bahwa karakteristik visual pada kelas glaucoma dan diabetic retinopathy memiliki kemiripan dengan kelas lain sehingga lebih sulit dibedakan oleh model. Secara keseluruhan, confusion matrix menunjukkan bahwa model telah mampu mengenali pola penyakit mata dengan baik, namun masih memerlukan peningkatan kemampuan klasifikasi pada kelas glaucoma dan diabetic retinopathy untuk meningkatkan akurasi prediksi.

B. Hasil platihan model (kurva training-validation)

Kurva training dan validation digunakan untuk menganalisis proses pembelajaran model selama pelatihan. Grafik ini menunjukkan perkembangan nilai accuracy dan loss pada data pelatihan (training) serta data validasi (validation) di setiap epoch. Melalui kurva tersebut dapat diamati tingkat konvergensi model, kemampuan generalisasi, serta indikasi terjadinya overfitting atau underfitting.



Gambar 4. Kurva Loss dan Akurasi Training

Gambar menunjukkan kurva pelatihan, akurasi training meningkat secara bertahap dari sekitar 72% menjadi 89%, sedangkan training loss terus menurun hingga mencapai sekitar 0,40. Hasil tersebut menunjukkan bahwa model mampu mempelajari pola pada data pelatihan dengan baik. Di sisi lain, validation accuracy mengalami fluktuasi dan berakhir pada kisaran 77%, sementara validation loss juga berfluktuasi dan cenderung meningkat pada epoch akhir.

Kondisi ini mengindikasikan bahwa meskipun performa model pada data pelatihan terus meningkat, kemampuan generalisasi terhadap data validasi belum sepenuhnya stabil serta terdapat indikasi overfitting pada akhir proses pelatihan.

B. Evaluasi Per Kelas

Hasil evaluasi model ditunjukkan pada Tabel 1.

Tabel 1. Hasil Evaluasi Precision, Recall, dan F1-score per Kelas


Kelas	Precision	Recall	F1-Score	Support
Katarak	0,78	0,92	0,84	157
Diabetic Retinopathy	0,87	0,71	0,78	166
Glaukoma	0,89	0,36	0,52	152
Normal	0,59	0,92	0,72	162
Akurasi Keseluruhan	—	—	73.23%	637

Pembahasan pada Tabel 1 menunjukkan hasil evaluasi model menggunakan metrik precision, recall, F1-score, dan support pada setiap kelas. Kelas Glaukoma memiliki nilai precision tertinggi sebesar 0,89, yang menunjukkan bahwa sebagian besar prediksi glaukoma yang dihasilkan model adalah benar. Namun, nilai recall pada kelas ini hanya 0,36, sehingga masih banyak citra glaukoma yang tidak berhasil teridentifikasi. Kelas Katarak menunjukkan performa yang paling seimbang dengan precision sebesar 0,78, recall sebesar 0,92, dan F1-score tertinggi yaitu 0,84, yang mengindikasikan kemampuan model yang baik dalam mengenali citra katarak. Pada kelas Diabetic Retinopathy, model memperoleh precision sebesar 0,87, recall sebesar 0,71, dan F1-score sebesar 0,78, sehingga performanya tergolong baik meskipun masih terdapat beberapa kesalahan klasifikasi. Sementara itu, kelas Normal memiliki recall yang tinggi sebesar 0,92, tetapi precision yang relatif rendah sebesar 0,59, menunjukkan bahwa

model mampu mengenali sebagian besar citra normal, namun masih menghasilkan prediksi normal yang berasal dari kelas penyakit lain. Secara keseluruhan, model memperoleh akurasi sebesar 73,23% pada 637 data uji, yang menunjukkan bahwa model mampu mengklasifikasikan penyakit mata dengan performa yang cukup baik, meskipun masih memerlukan peningkatan terutama dalam mendeteksi kelas Glaukoma.

II. VISUALISASI HASIL

Model yang telah dilatih kemudian diimplementasikan pada lingkungan Google Colab untuk melakukan pengujian prediksi terhadap citra fundus retina. Proses implementasi dilakukan dengan memasukkan citra uji ke dalam model yang telah dilatih, kemudian sistem menghasilkan prediksi kelas penyakit beserta nilai probabilitas untuk setiap kelas. Hasil prediksi ditampilkan secara langsung dalam bentuk visualisasi di Google Colab sebagai media analisis terhadap kemampuan model dalam mengklasifikasikan penyakit mata. Implementasi ini menunjukkan bahwa model dapat digunakan untuk melakukan prediksi secara otomatis dan memberikan hasil yang mudah diinterpretasikan tanpa memerlukan aplikasi berbasis web.



Gambar 5. Output Tampilan Hasil Prediksi

Gambar 5 menunjukkan hasil implementasi model Convolutional Neural Network (CNN) pada lingkungan Google Colab dalam melakukan prediksi terhadap citra

fundus retina. Pada contoh pengujian ini, citra cataract_097.png diproses oleh model untuk mengklasifikasikan penyakit mata ke dalam empat kategori, yaitu Cataract, Diabetic Retinopathy, Glaucoma, dan Normal. Hasil prediksi menunjukkan bahwa citra tersebut diklasifikasikan sebagai Cataract (Katarak) dengan tingkat kepercayaan (confidence) sebesar 99,53%. Sementara itu, probabilitas untuk kelas Diabetic Retinopathy, Glaucoma, dan Normal masing-masing hanya sebesar 0,02%, 0,39%, dan 0,06%. Nilai probabilitas yang sangat tinggi pada kelas Cataract menunjukkan bahwa model memiliki tingkat keyakinan yang tinggi terhadap hasil klasifikasi, sedangkan probabilitas yang sangat rendah pada kelas lainnya mengindikasikan bahwa kemungkinan citra termasuk ke dalam kategori tersebut sangat kecil. Hasil ini menunjukkan bahwa model CNN mampu melakukan prediksi secara akurat terhadap citra uji serta membantu proses skrining awal penyakit mata sebagai sistem pendukung keputusan bagi tenaga medis.

V. KESIMPULAN DAN SARAN

A. Kesimpulan

1. Penelitian ini berhasil mengembangkan model klasifikasi penyakit mata berbasis citra fundus retina menggunakan metode Convolutional Neural Network (CNN) dengan arsitektur EfficientNetB0 dan pendekatan Transfer Learning.
2. Model dilatih menggunakan dataset Eye Diseases Classification yang terdiri dari 4.217 citra fundus retina dengan empat kelas, yaitu Cataract, Diabetic Retinopathy, Glaucoma, dan Normal.
3. Hasil pengujian menunjukkan bahwa model memperoleh akurasi sebesar 73,23% pada 637 data uji.
4. Kelas Katarak memberikan performa terbaik dengan nilai Precision 0,78, Recall 0,92, dan F1-Score 0,84, sedangkan kelas Glaukoma memiliki Recall terendah sebesar 0,36, sehingga masih memerlukan peningkatan kemampuan klasifikasi.
5. Secara keseluruhan, arsitektur EfficientNetB0 mampu digunakan sebagai model klasifikasi penyakit mata berbasis citra fundus retina dan berpotensi menjadi sistem pendukung skrining awal penyakit mata.

B. Saran

1. Menambah jumlah dan variasi dataset agar kemampuan generalisasi model semakin baik.
2. Mengoptimalkan tahap preprocessing dan data augmentation untuk meningkatkan kualitas fitur citra.
3. Melakukan fine-tuning yang lebih mendalam atau membandingkan EfficientNetB0 dengan arsitektur

lain seperti EfficientNetB3, DenseNet121, atau ResNet50.

4. Mengembangkan model menjadi aplikasi berbasis web atau perangkat bergerak agar dapat digunakan secara lebih praktis dalam proses skrining penyakit mata.
5. Melakukan validasi menggunakan dataset dari rumah sakit atau institusi kesehatan sehingga model memiliki tingkat keandalan yang lebih tinggi pada data nyata.

DAFTAR PUSTAKA

- [1] Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M. A., Al-Amidie, M., & Farhan, L. (2021). Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. In *Journal of Big Data* (Vol. 8, Issue 1). Springer International Publishing. <https://doi.org/10.1186/s40537-021-00444-8>
- [2] Apriliansyah, R., Handayanto, A., & Saputro, N. D. (2025). Penerapan Arsitektur EfficientNetB0 pada Model Convolutional Neural Network untuk Deteksi Dini Mata Katarak Application. *Journal of Computer Engineering, System and Science*, 10(1), 435–446.
- [3] Goodfellow, I., Bengio, Y., & Courville, and A. (2022). Book: Deep Learning. In *Prmu*. www.deeplearningbook.org
- [4] Imandayanti, N. E., Wahanani, H. E., & Rizki, A. M. (2024). Klasifikasi Jenis Wayang menggunakan Convolutional Neural Network (CNN) dan Optimasi Adaptive Moment Estimation (ADAM). *KERNEL: Jurnal Riset Inovasi Bidang Informatika Dan Pendidikan Informatika*, 5(2), 64–71. <https://doi.org/10.31284/j.kernel.2024.v5i2.6862>
- [5] Khairunnisa, P., Putra, W. E., Yitong, W., Jufrizal, A., & Makmum, M. N. A. (2025). Convolutional Neural Networks Using EfficientNetB0 Architecture and Hyperparameters on Skin Disease Classification. *Public Research Journal of Engineering, Data Technology and Computer Science*, 2(2), 127–137. <https://doi.org/10.57152/predatecs.v2i2.1569>
- [6] Le Gorrec, L., Mouysset, S., & Ruiz, D. (2022). Doubly stochastic scaling unifies community detection. *Neurocomputing*, 504, 141–162. <https://doi.org/10.1016/j.neucom.2022.06.090>
- [7] Marcela, D., Yohannes, & Devella, S. (2022). Klasifikasi Penyakit Mata Menggunakan Convolutional Neural Network Dengan Arsitektur VGG-19. *Jurnal Algoritme*, 3(1), 60–70. <https://doi.org/10.35957/algoritme.v3i1.3331>
- [8] Wilyani, F., Arif, Q. N., & Aslimar, F. (2024). *Pengenalan Dasar Pemrograman Python Dengan Google Colaboratory Basic*. 1, 8–14. <https://doi.org/https://doi.org/10.55606/jppmi.v3i1.1087>