

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)



Deteksi Penyakit Mata Pada Citra Menggunakan Metode *Convolutional Neural Network* Arsitektur Efficientnetb3

Eye Disease Detection in Images Using Convolutional Neural Network Method with EfficientNetB3 Architecture

Muhammad Pratar Lokananta^{1*}, Nanda Martyan Anggadimas², Muhammad Misdram³

^{1,2,3}Teknik Informatika, Universitas Merdeka Pasuruan, Indonesia

Jl. Ir. H. Juanda No. 68, Tapaan, Kecamatan Bugul Kidul, Kota Pasuruan 67129

Email: ¹pratarlokananta@student.unmerpas.ac.id, ²nandama@unmerpas.ac.id,
³misdram@unmerpas.ac.id,

**Corresponding Author*

A B S T R A K

Penyakit mata seperti katarak, glaukoma, retinopati diabetik, dan konjungtivitis dapat menyebabkan gangguan penglihatan atau bahkan kebutaan jika tidak terdeteksi lebih awal. Penelitian ini bertujuan untuk mengembangkan sistem deteksi otomatis untuk penyakit mata menggunakan data gambar dan *Convolutional Neural Network* (CNN) dengan arsitektur EfficientNetB3. Dataset terdiri dari gambar mata yang telah melalui pra-pemrosesan dan augmentasi untuk meningkatkan kinerja model. Sistem ini dirancang untuk mengklasifikasikan gambar ke dalam empat kategori penyakit dan telah menunjukkan tingkat akurasi yang relatif tinggi. Hasil penelitian menghasilkan akurasi yang cukup tinggi yaitu 98% di 4 jenis penyakit mata yang menandakan bahwa model yang digunakan pada penelitian sangat akurat untuk memprediksi 4 jenis penyakit mata dan arsitektur EfficientNetB3 efektif dalam mendeteksi penyakit mata dari gambar dan memiliki potensi untuk digunakan sebagai alat pendukung diagnostik dini di bidang oftalmologi.

Kata Kunci: *deteksi penyakit mata; convolutional neural network; efficientnetb3*.

A B S T R A C T

Eye diseases such as cataracts, glaucoma, diabetic retinopathy, and conjunctivitis can cause visual impairment or even blindness if not detected early. This study aims to develop an automatic detection system for eye diseases using image data and Convolutional Neural Networks (CNN) with the EfficientNetB3 architecture. The dataset consists of eye images that have undergone preprocessing and augmentation to improve model performance. This system is designed to classify images into four disease categories and has shown a relatively high accuracy rate. The study results achieved a fairly high accuracy of 98% across the four



types of eye diseases, indicating that the model used in the study is highly accurate in predicting these four eye diseases, and the EfficientNetB3 architecture is effective in detecting eye diseases from images and has the potential to be used as a tool to support early diagnosis in the field of ophthalmology.

Keywords: *eye disease detection; convolutional neural network; efficientnetb3.*

1. PENDAHULUAN

Mata merupakan salah satu organ indra yang memiliki peran krusial dalam kehidupan manusia[1][2], berfungsi sebagai alat utama untuk melihat dan memahami lingkungan sekitar. Kemampuan mata dalam menangkap cahaya dan memprosesnya menjadi penglihatan menjadikannya sangat penting untuk mendukung berbagai aktivitas sehari-hari. Akan tetapi, sejumlah faktor seperti pola hidup tidak sehat, lingkungan yang kurang mendukung, penuaan, dan faktor genetik dapat memicu munculnya gangguan atau penyakit pada mata seperti yang ada pada penelitian [2].

Penyakit mata saat ini bukan menjadi masalah kesehatan yang langka, saat ini penyakit mata menjadi umum di masyarakat dan dapat memberikan dampak signifikan terhadap kualitas hidup seseorang. Sayangnya tidak sedikit masyarakat yang menyepelekan dan bahkan menganggap bahwa penyakit mata bukan masalah yang serius. Selain mengganggu penglihatan, penyakit mata juga berpotensi menyebabkan kebutaan permanen apabila tidak ditangani dengan cepat dan tepat[3][4].

Beberapa penyakit mata yang sering dijumpai antara lain katarak, glaukoma, kelainan refraksi (seperti rabun jauh, rabun dekat, dan astigmatisme), retinopati diabetik, serta konjunktivitis.[5] Katarak sering kali menyerang lansia, dan tidak menutup kemungkinan katarak terjadi terhadap anak-anak dan orang dewasa[6][7].Sementara kelainan refraksi kini semakin meningkat di kalangan anak-anak dan remaja akibat penggunaan perangkat elektronik secara berlebihan. Sementara itu, glaukoma, yang dikenal sebagai "pencuri penglihatan," sering kali tidak menunjukkan gejala pada tahap awal, namun jika tidak ditangani sesegera mungkin dapat menyebabkan kebutaan permanen[8].

Selain faktor-faktor tersebut, kondisi lingkungan yang buruk, paparan sinar *ultraviolet*, serta rendahnya kesadaran masyarakat untuk melakukan pemeriksaan kesehatan mata secara rutin turut berkontribusi terhadap meningkatnya prevalensi penyakit mata. Perkembangan teknologi dan gaya hidup modern juga memicu masalah kesehatan mata, seperti sindrom mata kering yang disebabkan oleh penggunaan *handphone* dalam waktu yang berlebihan[9].

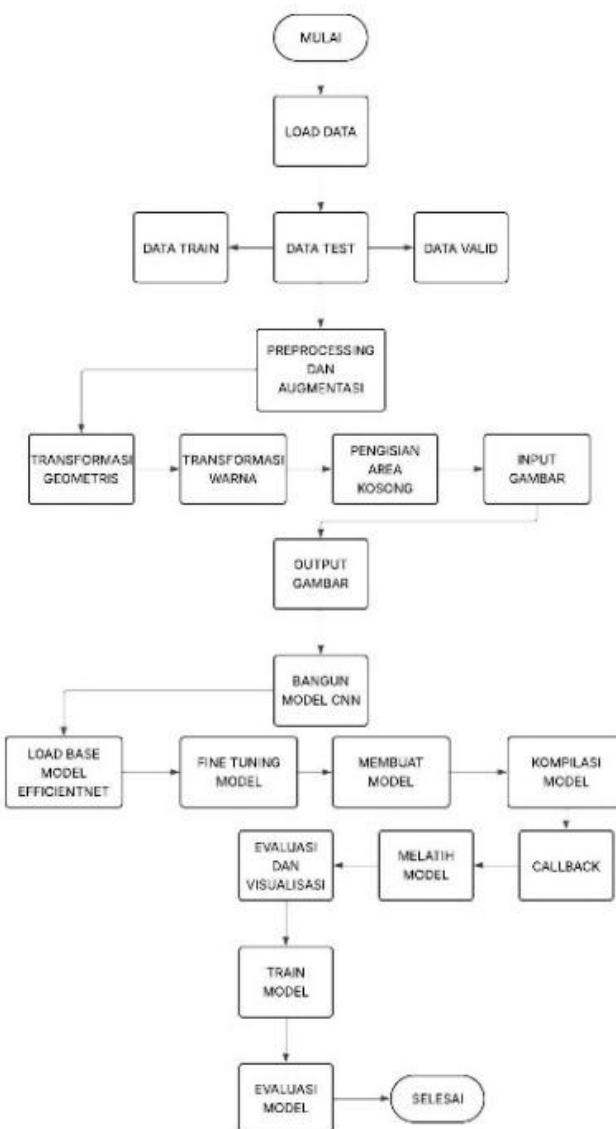
Beberapa penelitian tentang penyakit mata menggunakan metode *Convolutional Neural Network (CNN)* sudah pernah dilakukan di antaranya penelitian oleh [10] yang membahas Deteksi Penyakit Mata Katarak Menggunakan Metode *Covolutional Neural Network (CNN)* dan hasil penelitian ini dapat menghasilkan akurasi yang bagus sehingga dapat membantu dibidang kedokteran untuk mendiagnosa dini penyakit mata seperti katarak, glukoma, konjunktivitis, dan retina diabetic. Selanjutnya ada penelitian dari Hananta Firdaus[11] yang membahas tentang Klasifikasi Penyakit Katarak Pada Mata Menggunakan Metode CNN Berbasis Web pada penelitiannya menggunakan beberapa *epoch* untuk mencari model *training* terbaik dan hasil akurasi yang didapatkan sebesar 93,33%. Dan juga ada

penelitian milik Nurona Cahya [3] yang berjudul Klasifikasi Penyakit Mata Menggunakan *Convolutional Neural Network* hasil penelitian tersebut mencapai akurasi sebesar 98,37% dengan menggunakan 150 epoch.

Dari pemahaman tentang jenis-jenis penyakit mata, penyebab gejala dan langkah-langkah pencegahan dan pengobatannya sangat diperlukan untuk meningkatkan kesadaran masyarakat dalam menjaga kesehatan mata[12]. Dan dengan adanya alat bantu *machine learning* dapat mempermudah deteksi penyakit mata sehingga bisa mengantisipasi sedini mungkin[13].

2. METODE PENELITIAN

Penelitian ini mengadopsi sistem yang ada di metode *convolutional neural network*, yang bisa dilihat pada gambar 1.



Gambar 1. Desain Penelitian

2.1. Load Data

Tahap load data merupakan langkah awal yang sangat krusial dalam penelitian, dimana data yang akan dianalisis dikumpulkan dan disiapkan. Pada penelitian ini, data yang digunakan berupa gambar digital dari berbagai jenis penyakit mata, yang nantinya akan diolah menggunakan metode *Convolutional Neural Network (CNN)*, seperti yang digambarkan pada gambar 1.

2.2. Preprocessing dan Augmentasi

Bagian *preprocessing* dan augmentasi data memegang peranan penting dalam menyiapkan gambar sebelum digunakan dalam pelatihan model. Untuk data pelatihan, digunakan *ImageDataGenerator*, yang tidak hanya membantu memproses gambar, tetapi juga menerapkan berbagai teknik augmentasi guna memperkaya variasi data dan mengurangi risiko overfitting. Fungsi *preprocessing* yang dipakai adalah *tf.keras.applications.efficientnet.preprocess_input*, yang berfungsi menyesuaikan nilai piksel gambar agar sesuai dengan standar input model *EfficientNetB3* biasanya melalui proses normalisasi.

Teknik augmentasi yang digunakan mencakup rotasi hingga 30 derajat, pergeseran gambar ke arah horizontal dan vertikal masing-masing sebesar 10%, efek shear sebesar 20%, zoom hingga 20%, penyesuaian kecerahan antara 60% hingga 140%, serta pembalikan gambar secara horizontal. Semua transformasi ini diterapkan secara acak di setiap batch pelatihan, agar model terbiasa dengan berbagai kondisi gambar yang lebih beragam dan realistik.

2.3. Build Model

Bagian build model CNN dalam kode ini dimulai dengan memuat arsitektur *efficientnetB3* sebagai base model atau model dasar. Model ini digunakan tanpa bagian atasnya (*include_top=False*) agar dapat ditambahkan layer kustom sesuai kebutuhan klasifikasi yang diinginkan. Selain itu, bobot awal dari *efficientnetB3* dimuat dari pelatihan sebelumnya pada dataset *ImageNet* (*weights='imagenet'*), sehingga model sudah memiliki pemahaman awal terhadap fitur-fitur umum dalam gambar. Untuk proses *fine-tuning*, sebagian besar layer awal pada model dasar dikunci (*trainable=False*) agar tidak ikut dilatih, sementara 20 layer terakhir dibuka (*trainable=True*) untuk disesuaikan dengan karakteristik dataset baru. Strategi ini bertujuan untuk mempertahankan pengetahuan umum dari *pre-trained* model, sekaligus menyesuaikan sebagian fitur akhir dengan data spesifik yang sedang digunakan.

2.4. Pelatihan Model

Bagian *training* model dalam kode ini bertujuan untuk melatih model *Convolutional Neural Network (CNN)* yang telah dibangun menggunakan dataset pelatihan dan divalidasi dengan dataset validasi. Proses pelatihan dilakukan menggunakan fungsi *model.fit()*, dengan data yang diambil dari *train_generator* dan dievaluasi setiap *epoch* menggunakan *validation_generator*. Model dilatih selama maksimal 25 *epoch*, namun proses ini dapat berhenti lebih awal jika kriteria *early stopping* terpenuhi. Untuk itu, digunakan dua *callback* penting: *earlystopping* dan *modelcheckpoint*. *Callback early stopping* akan menghentikan pelatihan jika nilai loss pada data validasi tidak mengalami penurunan selama 8 *epoch* berturut-turut, serta akan mengembalikan bobot model ke kondisi terbaiknya selama

pelatihan. Sementara itu, *modelcheckpoint* secara otomatis menyimpan bobot model terbaik berdasarkan akurasi validasi tertinggi selama proses pelatihan, dengan nama file *best_model_efficientnetb3.keras*.

2.5. Evaluasi Model

Bagian evaluasi model berfungsi untuk menilai seberapa baik performa model setelah proses pelatihan selesai, baik terhadap data validasi maupun data uji. Pertama-tama, model dievaluasi pada data validasi menggunakan *model.evaluate()* yang menghasilkan dua metrik utama, yaitu *loss* dan *accuracy*. Ini memberikan gambaran mengenai kemampuan model dalam mengenali pola dari data yang belum digunakan selama pelatihan, namun masih berasal dari distribusi yang serupa. Evaluasi yang sama juga dilakukan pada data uji (*test_generator*) yang dianggap mewakili data nyata, untuk mengetahui seberapa baik model dapat bekerja dalam situasi yang lebih umum atau belum pernah dilihat sebelumnya. Hasil evaluasi ini kemudian ditampilkan sebagai nilai akurasi dan kerugian (*loss*) untuk memberikan tolok ukur performa model secara keseluruhan.

Selain evaluasi numerik, dilakukan juga analisis performa klasifikasi melalui *classification report* dan *confusion matrix*. Prediksi terhadap data uji diperoleh dengan memanfaatkan *model.predict()*, lalu nilai tertinggi dari hasil prediksi (*softmax*) digunakan untuk menentukan label kelas yang diprediksi. Hasil prediksi ini dibandingkan dengan label asli untuk menghasilkan laporan klasifikasi yang berisi metrik seperti *precision*, *recall*, *f1-score*, dan *support* untuk masing-masing kelas. Untuk memberikan gambaran visual, dibuatlah *confusion matrix* dalam bentuk diagram *heatmap* menggunakan *Seaborn*, yang memperlihatkan jumlah prediksi benar dan salah untuk tiap kategori. Dengan cara ini, pengguna dapat dengan mudah mengidentifikasi pola kesalahan, seperti kelas mana yang sering diklasifikasikan secara keliru. Evaluasi semacam ini sangat penting untuk memastikan bahwa model tidak hanya memiliki akurasi tinggi, tetapi juga mampu mengenali semua kelas secara adil dan akurat dalam penerapan di dunia nyata.

Setelah proses pelatihan selesai, dilakukan evaluasi terhadap model menggunakan data uji. Evaluasi ini dilakukan dengan fungsi *model.evaluate()*, yang akan mengembalikan nilai *loss* dan akurasi akhir dari model terhadap data uji. Nilai akurasi yang tinggi menunjukkan bahwa model mampu mengklasifikasikan gambar penyakit mata dengan tingkat ketepatan yang baik.

3. HASIL DAN PEMBAHASAN

Penelitian ini menggunakan arsitektur EfficientNetB3 untuk mendeteksi empat jenis penyakit mata, yaitu: katarak, glaukoma, retinopati diabetik, dan konjungtivitis. Model dilatih menggunakan dataset gambar fundus mata yang telah melalui *preprocessing* dan augmentasi.

3.1. Contoh Data Set Penyakit Mata

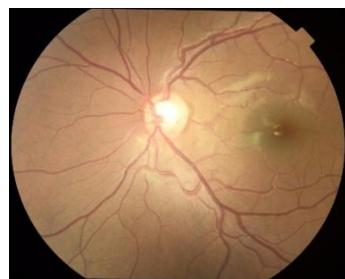
Dalam penelitian ini mengambil dataset dari website terbuka seperti Kaggle, Mendeley *Data Search*, Dan setiap penyakit mata memiliki 1000 data dan dibagi menjadi 3 bagian yaitu data *train*, *test*, *valid*. Berikut Adalah contoh data set yang digunakan dalam penelitian ini.

1. Katarak



Gambar 2. Penyakit Mata Katarak

2. Glukoma



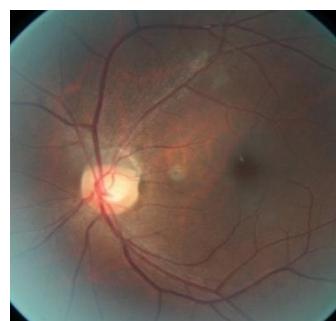
Gambar 3. Penyakit Mata Glukoma

3. Konjungtivitis



Gambar 4. Penyakit Mata Konjungtivitis

4. Retina Diabetik



Gambar 5. Penyakit Mata Retina Diabetik

3.2. Hasil Penelitian Model CNN

Pelatihan dilakukan sebanyak tiga kali dengan jumlah *epoch* berbeda, yaitu 10, 25, dan 50 *epoch*, guna mengetahui pengaruh jumlah *epoch* terhadap performa model. Parameter lain yang digunakan tetap konstan, seperti:

1. *Optimizer*: Adam
2. *Learning rate*: 0.001
3. *Batch size*: 32
4. *Loss function*: *categorical crossentropy*
5. Rasio data latih, test dan validasi: 70, 15, 15

Dari hasil pelatihan di setiap *epoch* didapatkan hasil seperti tabel dibawah ini.

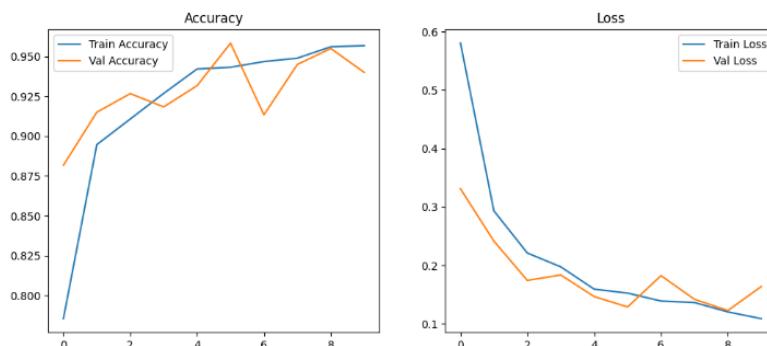
Tabel 1. Keandalan Konsistensi Internal Tes Biologi

Jumlah Epoch	Akurasi	Loss
10	0,9612	0,0992
25	0,9766	0,0621
50	0,9852	0,0446

3.3. Grafik Akurasi dan Loss

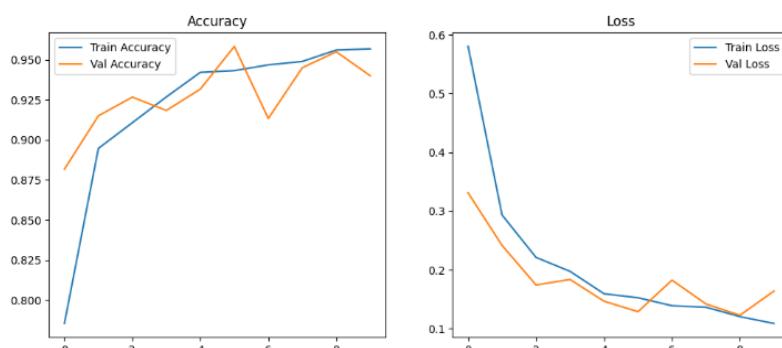
Berikut adalah grafik akurasi dan *loss* di masing-masing *epoch* yang bisa dilihat pada gambar 2, 3 dan 4.

1. Epoch 10



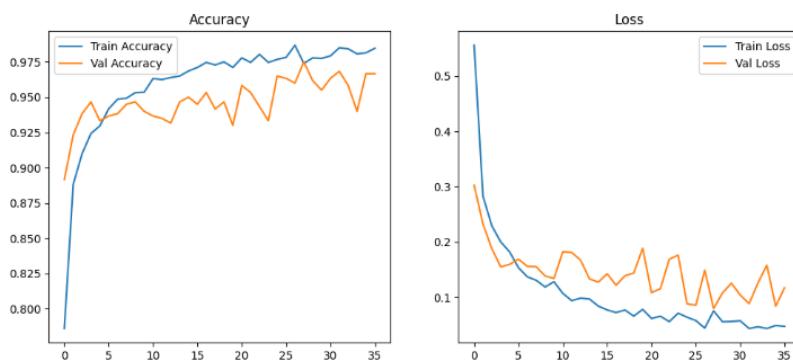
Gambar 6. Akurasi dan loss epoch 10

2. Epoch 25



Gambar 7. Akurasi dan loss epoch 25

3. Epoch 50



Gambar 8. Akurasi dan loss epoch 50

3.4. Evaluasi Kinerja Model

Model diuji menggunakan data uji (*test set*). Berikut perbandingan hasil dari setiap kelas dengan 50 *epoch*, meskipun pengujian maksimal 50 *epoch* tetapi prosesnya hanya berhenti di *epoch* ke 36 untuk karena *early stopping*. Karena tidak terjadi penurunan pada *val_loss* selama 8 *epoch* berturut turut. Oleh karena itu hasil evaluasi data uji merupakan hasil dari model terbaik pada *epoch* ke 36, dengan akurasi sebesar 96%, *precision* dan *recall* sebesar 0.96 Dan F1-Score sebesar 0.96.

Tabel 2. Klasifikasi Report

Nama Penyakit	Precision	Recall	F1 Score	Support
Katarak	0.88	0.97	0.92	150
Glukoma	0.98	0.95	0.96	150
Konjungtivitis	1	1	1	150
Retina Diabetik	0.99	0.93	0.96	150

Tabel 2 menunjukkan hasil evaluasi performa model *CNN EfficientNetB3* dalam mendeteksi empat jenis penyakit mata, yaitu Katarak, Glaukoma, Retina Diabetik, dan Konjungtivitis. Evaluasi dilakukan menggunakan metrik *precision*, *recall*, *F1-score*, serta *support* yang masing-masing menunjukkan kualitas prediksi model terhadap setiap kelas.

Model memperoleh *precision* tertinggi sebesar 1.00 pada kelas Retina Diabetik, yang berarti seluruh prediksi terhadap kelas tersebut benar. *Recall*-nya juga mencapai 1.00, menandakan bahwa seluruh citra Retina Diabetik berhasil dikenali tanpa ada yang terlewat, sehingga *F1-score*-nya pun sempurna di angka 1.00. Hasil ini mengindikasikan bahwa model sangat efektif dalam mendeteksi penyakit Retina Diabetik. Untuk kelas Konjungtivitis, model memiliki *precision* sebesar 0.99 dan *recall* 0.93, menghasilkan *F1-score* sebesar 0.96. Ini menunjukkan bahwa model sangat akurat dalam memprediksi kelas ini, meskipun ada sedikit kesalahan dalam mengenali semua data yang seharusnya diklasifikasikan sebagai konjungtivitis.

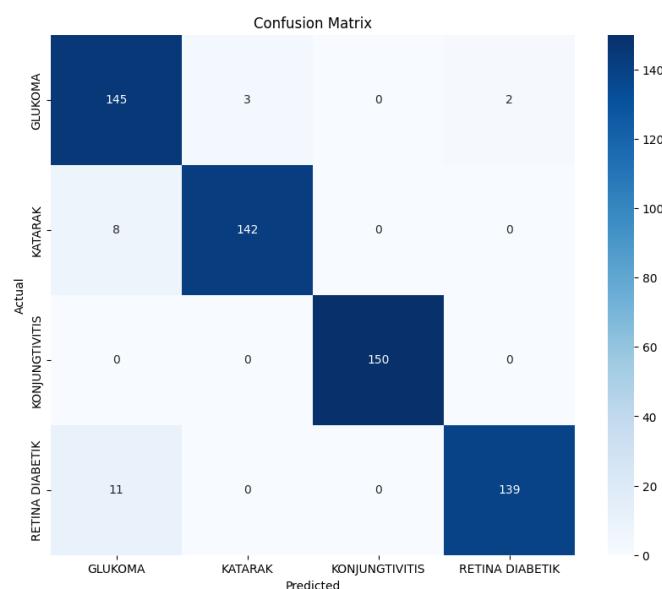
Pada kelas Glaukoma, *precision* dan *recall* masing-masing mencapai 0.98 dan 0.95, dengan *F1-score* 0.96. Hal ini menunjukkan bahwa model cukup seimbang dalam mengenali dan memprediksi citra glaukoma. Sementara itu, performa model pada kelas Katarak

menunjukkan *precision* terendah yaitu 0.88, meskipun *recall*-nya tinggi yaitu 0.97, menghasilkan *F1-score* 0.92. Nilai *recall* yang tinggi menandakan bahwa sebagian besar kasus Katarak berhasil dideteksi, namun *precision* yang rendah menunjukkan bahwa terdapat beberapa prediksi positif palsu (*false positive*) terhadap kelas ini.

Secara keseluruhan, model menunjukkan performa klasifikasi yang sangat baik dengan nilai F1-score yang tinggi pada seluruh kelas, terutama pada Retina Diabetik. Hal ini mencerminkan kemampuan generalisasi model yang kuat terhadap data uji.

3.5. Convolution Matrix

Berdasarkan *confusion matrix* yang ditunjukkan pada gambar 5, model CNN memperlihatkan kinerja yang sangat baik dalam mengklasifikasikan empat jenis penyakit mata, yaitu Glaukoma, Katarak, Konjungtivitis, dan Retina Diabetik. Sebagian besar data berhasil diprediksi dengan tepat oleh model. Pada kelas Glaukoma, terdapat 145 data yang terklasifikasi dengan benar, meskipun masih terjadi kesalahan prediksi sebanyak 3 data ke kelas Katarak dan 2 data ke kelas Retina Diabetik. Untuk kategori Katarak, model mampu mengklasifikasikan 142 data secara akurat, sedangkan 8 data lainnya salah terklasifikasi sebagai Glaukoma. Kelas Konjungtivitis menunjukkan hasil yang paling sempurna, dengan seluruh 150 data berhasil diklasifikasikan dengan benar tanpa adanya kesalahan. Pada kelas Retina Diabetik, sebanyak 139 data diprediksi secara akurat, namun 11 data lainnya keliru diklasifikasikan sebagai Glaukoma. Secara umum, hasil *confusion matrix* ini mengindikasikan bahwa model memiliki tingkat akurasi yang tinggi pada semua kelas, terutama dalam mendeteksi Konjungtivitis. Meskipun begitu, masih terdapat sedikit kekeliruan dalam membedakan antara Glaukoma dan Retina Diabetik, yang kemungkinan disebabkan oleh kemiripan ciri-ciri visual pada citra kedua penyakit tersebut.



Gambar 9. Confusion Matrix

4. KESIMPULAN

Penelitian ini berhasil mengimplementasikan arsitektur *Convolutional Neural Network (CNN) EfficientNetB3* dalam mengklasifikasikan empat kategori penyakit mata berdasarkan citra berwarna RGB. Pelatihan model dilakukan melalui pendekatan *transfer learning*, dengan mempertahankan sebagian besar lapisan dari model *pretrained* EfficientNetB3 dan hanya menyesuaikan serta melatih ulang beberapa lapisan akhir untuk meningkatkan performa terhadap dataset yang digunakan. Untuk mengurangi risiko overfitting dan meningkatkan kemampuan generalisasi model, dilakukan teknik augmentasi data pada gambar pelatihan, termasuk rotasi, zoom, pergeseran posisi, penyesuaian tingkat kecerahan, dan pencerminan horizontal. Selain itu, proses pelatihan disertai dengan mekanisme *early stopping* untuk menghentikan pelatihan saat validasi tidak menunjukkan peningkatan, serta model *checkpoint* untuk menyimpan bobot terbaik dari model.

Evaluasi terhadap model menunjukkan performa yang baik, dengan nilai akurasi tinggi pada data validasi dan pengujian. Laporan klasifikasi dan matriks kebingungan (*confusion matrix*) mengonfirmasi bahwa model mampu mengenali setiap kelas dengan akurat. Grafik akurasi dan loss juga menunjukkan bahwa proses pelatihan berlangsung dengan baik dan mencapai konvergensi. Secara keseluruhan, penggunaan arsitektur EfficientNetB3 pada CNN dalam penelitian ini terbukti efisien dan akurat dalam mendeteksi penyakit mata melalui citra, serta memiliki potensi besar sebagai alat bantu deteksi dini yang dapat mempercepat penanganan dan meningkatkan kesadaran masyarakat terhadap kesehatan mata.

DAFTAR PUSTAKA

- [1] I. Dewa, A. Pradnya, P. Tentriajaya, G. Ngurah, and L. Wijayakusuma, “Eye Disease Classification Using EfficientNet-B0 Based on Transfer Learning,” 2025. [Online]. Available: <http://jurnal.polibatam.ac.id/index.php/JAIC>
- [2] D. Marcella, Y. Yohannes, and S. Devella, “Klasifikasi Penyakit Mata Menggunakan Convolutional Neural Network Dengan Arsitektur VGG-19,” *Jurnal Algoritme*, vol. 3, no. 1, pp. 60–70, Oct. 2022, doi: 10.35957/algoritme.v3i1.3331.
- [3] F. Nurona Cahya *et al.*, “SISTEMASI: Jurnal Sistem Informasi Klasifikasi Penyakit Mata Menggunakan Convolutional Neural Network (CNN).” [Online]. Available: <http://sistemas.ftik.unisi.ac.id>
- [4] An Nisa U Nur Hamidah, Putri Aulia Kusuma Ningrum, Sri Wahyuni, Zahra Amelia, and Liss Dyah Dewi A, “Pengaruh Diabetes Melitus Terhadap Ketajaman Penglihatan Penyakit Katarak,” *Intellektika : Jurnal Ilmiah Mahasiswa*, vol. 2, no. 3, pp. 49–60, May 2024, doi: 10.59841/intellektika.v2i3.1248.
- [5] R. Putri Dewi, P. Ristyaning Ayu Sangging, R. Himayani, M. Klinis, and dan Tatalaksana, “Konjungtivitis: Etiologi, Klasifikasi, Manifestasi Klinis, Komplikasi, dan Tatalaksana.”
- [6] K. A. Saputra *et al.*, “Multi-Disease Retinal Classification Using EfficientNet-B3 and Targeted Albumentations: A Benchmark on Kaggle Retinal Fundus Images Dataset,” *sinkron*, vol. 10, no. 1, pp. 232–241, Jan. 2026, doi: 10.33395/sinkron.v10i1.15530.
- [7] T. Medika Jurnal Kedokteran *et al.*, “Angka Kejadian dan Karakteristik Pasien Katarak di Poliklinik Mata RSUD Waled Kabupaten Cirebon 2022.” [Online]. Available: <http://journal.ugj.ac.id/index.php/tumed>

- [8] R. Indraswari, W. Herulambang, and R. Rokhana, "Deteksi Penyakit Mata Pada Citra Fundus Menggunakan *Convolutional Neural Network* (CNN) Ocular Disease Detection on Fundus Images Using *Convolutional Neural Network* (CNN)." [Online]. Available: <https://www.kaggle.com/datasets/jr2nbg/cataractdataset>
- [9] Y. Mahadika, A. Fadhillah, M. Agustina, and M. Hafiz, "Klasifikasi Penyakit Mata Dengan Model Machine Learning Berbasis SVM," *JRIIN : Jurnal Riset Informatika dan Inovasi*, vol. 2, no. 7, 2024, [Online]. Available: <https://jurnalmahasiswa.com/index.php/jriin>
- [10] A. Vania, P. Ardana, D. P. Rini, M. Kom, and M. N. Rachmatullah, "Sistem Deteksi Penyakit Mata Katarak Dengan Menggunakan Convolutional Neural Network (CNN)."
- [11] D. Hananta Firdaus, B. Imran, L. Darmawan Bakti, and E. Suryadi, "Klasifikasi Penyakit Katarak Pada Mata Menggunakan Metode Convolutional Neural Network (CNN) Berbasis Web," 2022.
- [12] P. Purwanita *et al.*, "Upaya meningkatkan kesadaran masyarakat dalam menjaga kesehatan mata di masa pandemi Covid-19," vol. 2, no. 2, 2021, doi: 10.32539/Hummed.V2I2.58.
- [13] F. Ramadhani, A. Satria, and S. Salamah, "Implementasi Algoritma *Convolutional Neural Network* dalam Mengidentifikasi Dini Penyakit pada Mata Katarak," *sudo Jurnal Teknik Informatika*, vol. 2, no. 4, pp. 167–175, Dec. 2023, doi: 10.56211/sudo.v2i4.408.