



PENERAPAN CNN DENGAN ARSITEKTUR EFFICIENTNET-B4 UNTUK DETEKSI PENYAKIT GLAUKOMA BERBASIS WEB

Rizal Rachman¹, Adi Karawinata Satyanegara²

¹ Sistem Informasi, Universitas Adhirajasa Reswara Sanjaya

² Teknik Informatika, Universitas Adhirajasa Reswara Sanjaya

Kiaracandong, Jawa Barat, Indonesia 40282

rizalrachman@ars.ac.id, adi.karawinata.s@gmail.com

Abstract

Glaucoma is a leading cause of irreversible blindness and frequently goes undetected in its early stages due to its slow and silent progression. Many individuals remain unaware of the disease until significant optic nerve damage has occurred. Early screening is limited by low public awareness, insufficient access to eye-care facilities, and the need for specialists to interpret retinal images. Automated detection is further complicated by inconsistent image quality, illumination variations, and the subtle differences between healthy and glaucomatous retinas. This study develops a web-based early detection system using the EfficientNet-B4 Convolutional Neural Network. A total of 9,540 retinal images from the EyePACS dataset were utilised, including 8,000 for training, 770 for validation, and 770 for testing. Classification was performed using two expert-annotated categories: normal and glaucomatous. The model was trained for 30 epochs through transfer learning and fine-tuning to achieve stable performance. The results show validation accuracy between 90% and 92%, with well-converging loss. The final model was integrated into an interactive web platform that allows users to upload retinal images and receive preliminary predictions accompanied by basic glaucoma information. This system offers potential as an accessible tool for early community-level screening.

Keywords: Convolutional Neural Network, Deep Learning, EfficientNet-B4, Glaucoma Detection, Retinal Fundus

Abstrak

Glaukoma menjadi salah satu penyebab kebutaan yang sering tidak terdeteksi pada tahap awal karena gejalanya berkembang perlahan dan tidak menimbulkan rasa nyeri. Banyak kasus baru diketahui setelah kerusakan saraf optik sudah berat. Pemeriksaan rutin masih rendah di masyarakat karena keterbatasan fasilitas, minimnya kesadaran, serta kebutuhan tenaga ahli untuk membaca citra retina. Proses identifikasi juga cukup menantang karena variasi kualitas citra, perbedaan kondisi pencahayaan, dan kemiripan visual antara mata normal dan glaukoma. Penelitian ini mengembangkan sistem deteksi dini glaukoma berbasis web dengan model *Convolutional Neural Network EfficientNet-B4*. Dataset EyePACS digunakan sebagai sumber citra retina dengan total 9.540 citra, terdiri dari 8.000 data latih, 770 data validasi, dan 770 data uji. Kriteria klasifikasi mencakup dua kategori, yakni mata normal dan glaukoma berdasarkan anotasi ahli pada *dataset*. Pelatihan dilakukan selama 30 *epoch* menggunakan strategi *transfer learning* dan *fine-tuning* untuk memperoleh stabilitas performa. Hasil evaluasi menunjukkan akurasi validasi berada pada kisaran 90–92% dengan nilai *loss* yang stabil. Model kemudian diintegrasikan ke sistem web yang memungkinkan pengguna mengunggah citra retina dan memperoleh prediksi awal beserta informasi dasar mengenai glaukoma. Sistem ini berpotensi meningkatkan skrining awal yang mudah dijangkau masyarakat.

Kata kunci: Convolutional Neural Network, Deep Learning, Deteksi Glaukoma, EfficientNet-B4, Fundus Retina

1. PENDAHULUAN

Glaukoma merupakan salah satu penyakit mata kronis yang ditandai oleh kerusakan progresif pada saraf optik dan peningkatan tekanan intraokular, yang apabila tidak terdeteksi serta ditangani sejak dini dapat menyebabkan kebutaan permanen [1], [2], [3]. Pemeriksaan glaukoma secara konvensional umumnya memerlukan kunjungan ke

klitik mata atau rumah sakit dengan peralatan diagnostik khusus, seperti tonometer dan pemeriksaan fundus [4]. Kondisi ini menjadi tantangan bagi masyarakat di wilayah terpencil dengan keterbatasan akses layanan kesehatan, sehingga diperlukan sistem skrining dini yang praktis, efektif, dan mudah diakses, misalnya melalui platform berbasis web [5].

Seiring pesatnya kemajuan metode *image processing* dan *machine learning*, pendekatan berbasis citra retina mulai diperkenalkan sebagai alat diagnosis alternatif [6]. *Convolutional Neural Network* (CNN) telah terbukti efektif untuk klasifikasi citra medis, seperti deteksi *diabetic retinopathy* dan glaukoma, dengan hasil akurasi yang tinggi dalam berbagai studi [7], [8], [9].


Keunggulan CNN terletak pada kemampuannya mengekstraksi fitur kompleks dari citra tanpa memerlukan pra-pemrosesan manual yang berlebihan [10], [11]. Dalam penelitian ini, digunakan arsitektur *EfficientNet-B4* sebagai model CNN utama untuk mendeteksi glaukoma berdasarkan citra retina. *EfficientNet-B4* dipilih karena mampu mencapai keseimbangan optimal antara akurasi dan efisiensi komputasi melalui teknik *compound scaling*, yang secara simultan menyesuaikan kedalaman, lebar, dan resolusi jaringan [12], [13], [14]. Model ini kemudian di-*fine-tune* menggunakan *dataset* citra retina glaukoma untuk meningkatkan kemampuan generalisasi terhadap variasi kondisi nyata [15].

Meskipun CNN telah banyak digunakan dalam klasifikasi citra medis, penelitian terdahulu umumnya berfokus pada tahap pengembangan model tanpa mengintegrasikannya ke dalam sistem berbasis web yang dapat diakses langsung oleh pengguna. Oleh karena itu, penelitian ini berfokus pada pengembangan sistem skrining dini glaukoma berbasis web yang memanfaatkan CNN *EfficientNet-B4* untuk analisis citra retina secara otomatis [16].

Tujuan penelitian ini adalah mengembangkan sistem konseling mata berbasis web yang memungkinkan pengguna melakukan *self-screening* dengan mengunggah foto retina untuk dianalisis menggunakan model CNN. Sistem ini diharapkan mampu memberikan estimasi probabilistik mengenai kemungkinan penyakit glaukoma secara non-invasif, cepat, dan mudah diakses, sehingga dapat membantu mempersempit kebutuhan pemeriksaan langsung di fasilitas kesehatan. Batasan penelitian mencakup penggunaan model CNN yang dilatih pada *dataset* citra retina terbatas, serta evaluasi performa yang difokuskan pada akurasi model dan efektivitas interaksi pengguna.

2. METODE PENELITIAN

Penelitian ini menggunakan desain penelitian kuantitatif dengan pendekatan *experimental research* karena bertujuan menguji efektivitas kombinasi metode *Convolutional Neural Network* (CNN) dalam mengklasifikasikan penyakit glaukoma berbasis aplikasi web. CNN digunakan untuk ekstraksi fitur dari citra retina yang diunggah oleh pengguna. Penelitian dilakukan secara *cross-sectional* dengan pengumpulan data pada satu periode waktu tertentu.



Gambar 1. Flowchart Penelitian


Alur tahapan penelitian ditunjukkan pada Gambar 1, yang menggambarkan proses penelitian mulai dari pengumpulan data, pemahaman dan persiapan data, hingga tahap pemodelan, evaluasi, dan penerapan (*deployment*). Setiap tahap memiliki keterkaitan yang sistematis untuk memastikan proses pengembangan sistem berlangsung terarah dan konsisten. Sebelum memasuki tahapan utama tersebut, penelitian diawali dengan kajian literatur terhadap berbagai studi relevan untuk membangun landasan teoretis dan metodologis yang kuat.

2.1 Data Collection

Tahapan ini mencakup proses pengumpulan data yang menjadi dasar penelitian, yaitu citra retina. Seluruh citra retina diperoleh dari *dataset* EyePACS, yang banyak digunakan dalam penelitian oftalmologi berbasis *deep learning* karena memiliki variasi citra yang luas dan telah teranotasi dengan baik.

2.2 Data Understanding

Pada tahap ini dilakukan analisis menyeluruh terhadap karakteristik dan kualitas data yang digunakan dalam penelitian deteksi glaukoma. Data citra retina diperoleh dari *dataset* EyePACS, yang terdiri atas 9.540 citra, mencakup 8.000 citra untuk data latih (*training set*), 770 citra untuk data validasi (*validation set*), dan 770 citra untuk data uji (*testing set*). Analisis statistik awal dilakukan untuk menilai distribusi label antara kelas normal dan glaukoma, serta mengidentifikasi potensi ketidakseimbangan kelas (*class imbalance*) yang dapat memengaruhi performa model. Pemeriksaan visual terhadap citra dilakukan untuk memastikan kualitas gambar, meliputi aspek pencahayaan, fokus, kejernihan struktur retina, serta keberadaan artefak yang dapat mengganggu proses pelatihan.



Gambar 2. Visualisasi Perbandingan Citra Retina (a) Glaukoma dan (b) Normal

Gambar 2 menampilkan contoh visual dari dua kelas utama pada *dataset*, yaitu (a) citra retina penderita glaukoma dan (b) citra retina normal. Pada citra glaukoma tampak pelebaran disk optik dengan batas tepi saraf yang kurang jelas, disertai perbedaan warna yang lebih pucat di area pusat. Sebaliknya, citra retina normal memperlihatkan struktur yang lebih simetris dengan batas disk optik yang tegas serta distribusi pembuluh darah yang teratur. Perbandingan ini menggambarkan perbedaan morfologis yang menjadi dasar bagi model dalam mengenali pola visual khas glaukoma.


Tahap pemahaman data ini bertujuan memastikan bahwa *dataset* yang digunakan layak dan representatif, sehingga model yang dibangun dapat menghasilkan prediksi glaukoma dengan validitas dan kemampuan generalisasi yang baik.

2.3 Data Preparation

Tahap ini bertujuan mempersiapkan data agar siap digunakan dalam proses pelatihan model. Untuk citra retina dari EyePACS, dilakukan serangkaian *preprocessing* meliputi *resizing* ke resolusi yang sesuai dengan arsitektur *EfficientNet-B4*, normalisasi piksel, peningkatan kontras, serta augmentasi data seperti rotasi dan *flip* guna memperkaya variasi citra. Proses ini membantu model mengenali pola yang lebih *robust* terhadap kondisi pencahayaan dan orientasi yang berbeda. Pembagian *dataset* menjadi *training*, *validation*, dan *testing set* dilakukan secara proporsional untuk menjaga keseimbangan label antar kelompok data.

2.4 Modeling

Tahapan ini merupakan inti dari penelitian, yaitu pengembangan model utama yakni *Convolutional Neural Network* (CNN) berbasis arsitektur *EfficientNet-B4*, yang dipilih karena efisiensinya dalam menyeimbangkan kedalaman, lebar dan resolusi jaringan sehingga mampu mengekstraksi fitur visual kompleks pada citra retina dengan performa tinggi dan parameter yang relatif ringan.



Gambar 3. Model Arsitektur *EfficientNet-B4*

Gambar 3 menampilkan struktur arsitektur *EfficientNet-B4*, yang tersusun atas beberapa blok *MBConv* dengan variasi ukuran kernel dan jumlah lapisan berbeda. Setiap blok bertugas mengekstraksi representasi visual secara bertahap, dari fitur dasar hingga fitur tingkat tinggi. Peningkatan jumlah lapisan pada setiap tahap jaringan memungkinkan model menangkap pola spasial yang semakin kompleks,

yang penting untuk membedakan karakteristik morfologis antara retina normal dan retina yang mengalami glaukoma.

2.5 Evaluation dan Modeling

Tahapan evaluasi dilakukan untuk mengukur performa model yang dikembangkan dan memastikan konsistensinya dalam mendeteksi penyakit glaukoma. Pengujian dilakukan pada *testing set* menggunakan metrik evaluasi seperti *accuracy* dan *loss*, *precision*, *recall*, *F1-score*, dan *Area Under Curve* (AUC). Model *EfficientNet-B4* diuji berdasarkan kemampuannya mengenali pola retina yang relevan.

2.6 Deployment


Tahap ini berfokus pada penerapan model terbaik ke dalam sistem yang siap digunakan dalam lingkup implementasi praktis, seperti aplikasi pendukung diagnosis dini penyakit glaukoma. Model *EfficientNet-B4* yang telah melalui tahap validasi diintegrasikan ke dalam antarmuka pengguna yang memungkinkan *input* citra retina untuk menghasilkan hasil prediksi otomatis. Proses *deployment* juga mencakup pemantauan performa model di lingkungan operasional serta mekanisme pembaruan (*model update pipeline*) apabila terdapat data baru yang lebih representatif. Selain itu, dilakukan validasi eksternal untuk memastikan bahwa sistem yang dikembangkan tetap relevan secara klinis dan dapat mendukung pengambilan keputusan oleh tenaga medis.

3. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil analisis performa model *EfficientNet-B4* untuk klasifikasi citra retina dalam deteksi glaukoma.


3.1 Hasil Penelitian

Pelatihan model *EfficientNet-B4* menggunakan metode *transfer learning* pada *dataset* citra retina glaukoma menunjukkan peningkatan kinerja yang konsisten sepanjang proses pelatihan. Data dibagi menjadi 80% untuk pelatihan, 10% untuk validasi, dan 10% untuk pengujian.




Gambar 4. Grafik Akurasi pada Data Latih dan Data Validasi Model *EfficientNet-B4*

Gambar 4 memperlihatkan perkembangan akurasi dan *loss* pada data latih serta data validasi selama 30 *epoch* menggunakan model *EfficientNet-B4* yang telah di-*fine-tune*. Akurasi data validasi meningkat cepat hingga mencapai kisaran 0,90 pada *epoch* ke-10 dan stabil hingga akhir pelatihan, sementara akurasi data latih terus naik secara bertahap hingga mendekati 0,85.




Gambar 5. Grafik *Loss* pada Data Latih dan Data Validasi Model *EfficientNet-B4*

Pada sisi lain, Gambar 5 menampilkan *loss* data latih dan validasi yang menunjukkan tren penurunan konsisten. *Training loss* turun dari sekitar 0,42 menjadi 0,10, dan *validation loss* mencapai nilai yang lebih rendah di kisaran 0,08. Pola ini menandakan proses pembelajaran yang stabil dan efisien tanpa gejala *overfitting* yang signifikan.




Gambar 6. Grafik *Precision* pada Data Latih dan Data Validasi Model *EfficientNet-B4*

Gambar 6 menampilkan grafik *precision* dari model *EfficientNet-B4* selama proses pelatihan selama 30 *epoch*. *Precision* pada data latih meningkat stabil dari sekitar 0,50 hingga mencapai sekitar 0,85 pada akhir *epoch*, menandakan bahwa model semakin mampu meminimalkan prediksi *false positive* seiring waktu. Sementara itu, *precision* pada data validasi naik dengan cepat hingga melampaui 0,90 pada *epoch* ke-10 dan kemudian stabil di kisaran 0,88–0,92 hingga akhir pelatihan. Hasil ini menunjukkan bahwa model memiliki kestabilan performa yang baik serta kemampuan dalam mempertahankan tingkat ketepatan prediksi meskipun data yang diuji berbeda dari data pelatihan.



Gambar 7. Grafik *Recall* pada Data Latih dan Data Validasi Model *EfficientNet-B4*


Gambar 7 memvisualisasikan perkembangan *recall* model *EfficientNet-B4* selama pelatihan. Nilai *recall* pada data latih meningkat stabil dari sekitar 0,50 hingga mendekati 0,87 pada *epoch* ke-30, menunjukkan kemampuan model yang semakin baik dalam menangkap seluruh kasus glaukoma pada data latih. Pelatihan dibatasi hingga 30 *epoch* karena pada percobaan awal terlihat bahwa kenaikan performa mulai melambat setelah *epoch* ke-25, sementara indikasi *overfitting* mulai muncul jika pelatihan diperpanjang. Batas 30 *epoch* dipilih sebagai titik optimal untuk menjaga keseimbangan antara akurasi, stabilitas *loss*, dan efisiensi komputasi tanpa mengorbankan kemampuan generalisasi model. Pada data validasi, *recall* mengalami fluktuasi di awal *epoch* namun kemudian stabil di kisaran 0,88–0,93 setelah *epoch* ke-10. Stabilitas nilai *recall* yang tinggi ini menandakan bahwa model memiliki sensitivitas yang baik dalam mengenali citra retina yang mengandung indikasi glaukoma, sekaligus mampu mempertahankan performa yang konsisten terhadap data baru yang belum pernah dilihat sebelumnya.



Gambar 8. Grafik *AUC* pada Data Latih dan Data Validasi Model *EfficientNet-B4*


Gambar 8 menampilkan grafik *AUC* (*Area Under Curve*) dari model *EfficientNet-B4* selama proses pelatihan sebanyak 30 *epoch*. Nilai *AUC* pada data latih meningkat stabil dari sekitar 0,50 pada awal pelatihan hingga mencapai sekitar 0,93 pada *epoch* ke-30, menunjukkan peningkatan kemampuan model dalam membedakan antara citra retina normal dan yang mengandung glaukoma. Sementara itu,

AUC pada data validasi meningkat tajam hingga melewati 0,90 pada *epoch* ke-8 dan kemudian stabil di kisaran 0,94–0,96 hingga akhir pelatihan. Stabilitas nilai AUC yang tinggi ini menandakan bahwa model memiliki kemampuan diskriminatif yang sangat baik dalam mengenali kasus positif maupun negatif glaukoma, serta mampu mempertahankan performa yang konsisten terhadap data yang belum pernah dilihat sebelumnya.



Gambar 9. Grafik *F1-score* pada Data Latih dan Data Validasi Model *EfficientNet-B4*

Gambar 9 memperlihatkan perkembangan *F1-score* model *EfficientNet-B4* selama proses pelatihan selama 30 *epoch*. Nilai *F1-score* pada data latih menunjukkan peningkatan stabil dari sekitar 0,50 pada awal pelatihan hingga mencapai kisaran 0,86 pada *epoch* ke-30, menandakan keseimbangan yang baik antara *precision* dan *recall* dalam mengenali citra retina dengan indikasi glaukoma. Sementara itu, *F1-score* pada data validasi meningkat tajam hingga melampaui 0,90 pada *epoch* ke-8 dan kemudian stabil di rentang 0,88–0,92 hingga akhir pelatihan. Model ini menunjukkan performa yang tinggi pada data pelatihan sekaligus mempertahankan hasil yang stabil pada data validasi. Konsistensi tersebut mengindikasikan bahwa model mampu mengenali pola secara efektif tanpa mengalami *overfitting*, serta memiliki kemampuan generalisasi yang baik terhadap data baru yang belum pernah dipelajari sebelumnya.




Gambar 10. *Confusion Matrix*

Confusion matrix pada Gambar 10 menunjukkan performa model dalam membedakan citra retina normal (NRG) dan

citra retina dengan glaukoma (RG). Model berhasil mengklasifikasikan 219 citra normal secara benar, dan salah memprediksi 166 citra normal sebagai glaukoma. Untuk kelas glaukoma, model mengidentifikasi 199 citra secara tepat, sedangkan 186 citra glaukoma salah diklasifikasikan sebagai normal.


Kesalahan prediksi terbanyak terjadi ketika citra glaukoma diprediksi sebagai normal. Kondisi ini umum terjadi pada *dataset* glaukoma karena sebagian pasien memiliki tanda struktural yang sangat halus, terutama pada tahap awal, seperti peningkatan *cup-to-disc ratio* yang minimal. Model cenderung kesulitan mengenali pola ini sehingga sebagian besar *misclassifications* jatuh pada kategori tersebut.

Secara keseluruhan, hasil ini menunjukkan bahwa model mampu melakukan pemisahan kelas dengan stabil, namun masih memerlukan peningkatan sensitivitas terhadap ciri glaukoma dengan keparahan ringan. Peningkatan dapat dilakukan melalui penambahan variasi citra glaukoma tahap awal, *fine-tuning* pada *region of interest* (khususnya *optic disc-cup area*), atau penguatan strategi augmentasi yang mempertahankan struktur anatomis penting.




Gambar 11. Halaman Beranda *Website*

Gambar 11 menampilkan halaman beranda yang berfungsi sebagai titik awal interaksi pengguna dengan sistem skrining glaukoma. Pada bagian atas disediakan fitur unggah citra retina (fundus) yang menjadi *input* utama bagi proses analisis berbasis *Convolutional Neural Network* (CNN) menggunakan arsitektur *EfficientNet-B4*. Elemen desain berwarna lembut dan tata letak yang responsif dirancang untuk meningkatkan kenyamanan serta mengurangi ketegangan visual pengguna. Selain itu, beranda juga menampilkan informasi edukatif mengenai penyebab, gejala, dan langkah pencegahan glaukoma yang bertujuan memperkuat aspek literasi kesehatan pengguna sebelum melakukan skrining awal.



Gambar 12. Halaman Hasil Prediksi Positif (Diduga Glaukoma)

Gambar 12 menampilkan hasil keluaran sistem yang menunjukkan deteksi positif, yaitu ketika model mengenali pola pada citra retina yang menyerupai indikasi glaukoma. Informasi hasil ditampilkan bersama tingkat kepercayaan model (*confidence*) untuk memberikan hasil objektif terhadap akurasi prediksi. Bagian ini dilengkapi rekomendasi tindak lanjut seperti pemeriksaan tekanan intraokular, *Optical Coherence Tomography* (OCT), serta anjuran konsultasi ke dokter spesialis mata. Seluruh konten hasil disertai penegasan bahwa prediksi bersifat skrining awal dan bukan diagnosis klinis, sesuai dengan prinsip kehati-hatian dalam pemanfaatan teknologi kecerdasan buatan di bidang medis.



Gambar 13. Halaman Hasil Prediksi Negatif (Tidak Terindikasi Glaukoma)

Gambar 13 yakni halaman hasil negatif menampilkan kondisi di mana sistem tidak mendeteksi adanya pola yang mengindikasikan glaukoma pada citra retina. Meskipun hasil menunjukkan kondisi normal, halaman ini tetap menyertakan himbauan untuk melakukan pemeriksaan mata berkala dan kewaspadaan terhadap faktor risiko genetik maupun gejala yang muncul di kemudian hari. Penekanan utama pada bagian ini ialah bahwa sistem hanya

memberikan asesmen awal berbasis *machine learning*, sehingga keputusan medis akhir tetap harus dilakukan oleh tenaga kesehatan profesional.

3.2 Pembahasan

Hasil yang diperoleh menunjukkan bahwa arsitektur *EfficientNet-B4* memberikan performa yang sangat baik dalam klasifikasi citra retina untuk deteksi dini glaukoma. Model mencapai akurasi validasi stabil pada kisaran 90–92%, dengan *loss* yang menurun secara konsisten hingga mendekati nilai 0,20 pada akhir pelatihan. Nilai akurasi yang tinggi dan perbedaan minimal antara akurasi data latih dan validasi menunjukkan bahwa model mampu melakukan generalisasi dengan baik tanpa mengalami *overfitting* yang signifikan. Hal ini mengindikasikan bahwa proses *fine-tuning* dan strategi *data augmentation* yang diterapkan berjalan optimal dalam membantu model mengenali fitur-fitur visual khas pada citra retina penderita glaukoma.

Jika dibandingkan dengan penelitian oleh [2], yang mengembangkan arsitektur CNN khusus dengan empat lapisan konvolusional dan dua lapisan *fully connected* serta mencapai nilai AUC sebesar 0,831 dan 0,887 pada *dataset* ORIGA dan SCES, pendekatan *transfer learning* dengan *EfficientNet-B4* pada penelitian ini menunjukkan peningkatan yang berarti dari sisi kestabilan hasil dan efisiensi pelatihan. Arsitektur *EfficientNet-B4*, dengan keunggulan pada efisiensi parameter dan kedalaman jaringan yang teroptimasi secara *compound scaling*, mampu mempelajari representasi visual yang lebih kompleks dengan jumlah parameter yang relatif lebih sedikit dibandingkan CNN konvensional.

Selain peningkatan performa model, kontribusi penting dari penelitian ini terletak pada implementasi praktisnya melalui integrasi model klasifikasi ke dalam sistem berbasis web. Penelitian ini menerapkan model yang telah dilatih ke dalam platform interaktif yang dapat diakses pengguna secara daring. Melalui sistem ini, pengguna dapat mengunggah citra retina untuk memperoleh hasil prediksi awal disertai informasi edukatif terkait glaukoma, termasuk gejala umum, faktor risiko, dan langkah pencegahan. Pendekatan ini memperluas jangkauan manfaat model AI bagi masyarakat di wilayah dengan keterbatasan akses terhadap layanan kesehatan mata. Dengan demikian, sistem ini berperan sebagai sarana peningkatan kesadaran masyarakat terhadap pentingnya pemeriksaan glaukoma secara rutin.

4. KESIMPULAN

Penelitian ini berhasil mengembangkan sistem deteksi dini glaukoma berbasis web dengan memanfaatkan arsitektur *Convolutional Neural Network* (CNN) *EfficientNet-B4*. Model yang dilatih menggunakan *dataset* citra retina dengan total 9.540 citra, mencakup 8.000 data latih, 770 data validasi, dan 770 data uji menunjukkan performa yang baik, ditandai dengan akurasi validasi stabil pada kisaran 90–92% serta nilai *loss* yang menurun konsisten hingga mencapai konvergensi optimal. Hasil tersebut menunjukkan

bahwa model mampu mengenali pola visual khas glaukoma dengan tingkat generalisasi yang baik. Penggunaan *EfficientNet-B4* sendiri memberikan keuntungan tambahan karena arsitekturnya menerapkan pendekatan *compound scaling* yang menyeimbangkan kedalaman, lebar, dan resolusi secara proporsional. Mekanisme ini membuat jaringan mampu menangkap detail halus pada struktur retina, termasuk variasi kontur disk optik dan *rasio cup-to-disc* yang sering menjadi indikator awal glaukoma. Kapasitas fitur yang lebih besar namun tetap efisien secara komputasi membuat *EfficientNet-B4* mampu membedakan perbedaan visual yang subtil antara mata normal dan glaukoma tanpa menghasilkan *overfitting*, sehingga model lebih stabil dan reliabel saat diuji pada data baru. Meskipun performanya stabil, kasus glaukoma dengan tanda struktural yang sangat halus tetap menjadi tantangan umum, sehingga diperlukan evaluasi lebih mendalam pada citra dengan tingkat keparahan ringan.

Implementasi model ke dalam sistem berbasis web memungkinkan proses skrining awal dilakukan secara praktis dan mudah diakses oleh pengguna. Fitur unggah citra retina dan penyajian hasil prediksi yang dilengkapi edukasi mengenai glaukoma membuat sistem ini berfungsi ganda, sebagai alat bantu diagnosis awal sekaligus media edukatif untuk meningkatkan kesadaran masyarakat akan pentingnya pemeriksaan mata secara rutin.

Untuk penelitian selanjutnya, pengembangan dapat diarahkan pada perluasan *dataset* agar mencakup variasi citra dari berbagai perangkat dan kondisi pencahayaan, serta integrasi model dengan data klinis tambahan seperti tekanan intraokular dan riwayat medis pasien. Pendekatan multimodal ini diharapkan mampu meningkatkan akurasi diagnosis sekaligus mendekatkan sistem ke arah penggunaan klinis yang lebih baik.

DAFTAR PUSTAKA

- [1] D. M. S. Barros, J. C. C. Moura, C. R. Freire, A. C. Taleb, R. A. M. Valentim, and P. S. G. Morais, "Machine learning applied to retinal image processing for glaucoma detection: review and perspective," *Biomed Eng Online*, vol. 19, no. 1, p. 20, 2020.
- [2] X. Chen, Y. Xu, D. W. K. Wong, T. Y. Wong, and J. Liu, "Glaucoma detection based on deep convolutional neural network," in *2015 37th annual international conference of the IEEE engineering in medicine and biology society (EMBC)*, IEEE, pp. 715–718, 2015.
- [3] A. Serener and S. Serte, "Transfer learning for early and advanced glaucoma detection with convolutional neural networks," in *2019 Medical technologies congress (TIPTEKNO)*, IEEE, pp. 1–4, 2019.
- [4] A. Sarhan, J. Rokne, and R. Alhajj, "Glaucoma detection using image processing techniques: A literature review," *Computerized Medical Imaging and Graphics*, vol. 78, p. 101657, 2019.
- [5] M. Kim, O. Janssens, H. Park, J. Zuallaert, S. Van Hoecke, and W. De Neve, "Web applicable computer-aided diagnosis of glaucoma using deep learning," *arXiv preprint arXiv:1812.02405*, 2018.
- [6] D. M. S. Barros, J. C. C. Moura, C. R. Freire, A. C. Taleb, R. A. M. Valentim, and P. S. G. Morais, "Machine learning applied to retinal image processing for glaucoma detection: review and perspective," *Biomed Eng Online*, vol. 19, no. 1, p. 20, 2020.
- [7] L. Li *et al.*, "A large-scale database and a CNN model for attention-based glaucoma detection," *IEEE Trans Med Imaging*, vol. 39, no. 2, pp. 413–424, 2019.
- [8] K. Duvvuri, S. Chethana, S. S. Charan, V. Srihitha, T. K. Ramesh, and K. S. Srikanth, "Grad-cam for visualizing diabetic retinopathy," in *2022 3rd International Conference for Emerging Technology (INCET)*, IEEE, pp. 1–4, 2022.
- [9] T. N. Poly, M. M. Islam, B. A. Walther, M. C. Lin, and Y.-C. J. Li, "Artificial intelligence in diabetic retinopathy: Bibliometric analysis," *Comput Methods Programs Biomed*, vol. 231, p. 107358, 2023.
- [10] Z. S. Lie *et al.*, "Automatic Cataract and Cholesterol Detection System Based on Recurrent Neural Network (RNN): A Comparison with Convolutional Neural Network (CNN) and Siamese Neural Network (SNN)," in *The International Conference on Intelligent Unmanned Systems*, Springer, pp. 233–242, 2023.
- [11] L. A. Hark *et al.*, "Philadelphia telemedicine glaucoma detection and follow-up study: methods and screening results," *Am J Ophthalmol*, vol. 181, pp. 114–124, 2017.
- [12] S. Zhu *et al.*, "Screening of common retinal diseases using six-category models based on EfficientNet," *Front Med (Lausanne)*, vol. 9, p. 808402, 2022.
- [13] L. K. Singh, Pooja, H. Garg, and M. Khanna, "Performance evaluation of various deep learning based models for effective glaucoma evaluation using optical coherence tomography images," *Multimed Tools Appl*, vol. 81, no. 19, pp. 27737–27781, 2022.
- [14] A. Geetha and N. B. Prakash, "Classification of Glaucoma in Retinal Images Using EfficientnetB4

- Deep Learning Model.,” *Computer Systems Science & Engineering*, vol. 43, no. 3, 2022.
- [15] S. A. Haja and V. Mahadevappa, “Advancing glaucoma detection with convolutional neural networks: a paradigm shift in ophthalmology,” *Rom J Ophthalmol*, vol. 67, no. 3, p. 222, 2023.
- [16] M. Ashtari-Majlan, M. M. Dehshibi, and D. Masip, “Deep learning and computer vision for glaucoma detection: A review,” *arXiv preprint arXiv:2307.16528*, 2023.