

Disparitas Efektivitas CLAHE pada Berbagai Arsitektur Deep Learning untuk Klasifikasi Katarak Berbasis Citra Fundus

Frida Ramadhani^{1,*}, Cinantya Paramita^{1,2}, Egia Rosi Subhiyako^{1,2}

¹ Fakultas Ilmu Komputer, Informatics Engineering, Universitas Dian Nuswantoro, Semarang, Indonesia

² Dinus Research Group for AI in Medical Science (DREAMS), Universitas Dian Nuswantoro, Semarang, Indonesia

Email: ^{1,*}111202214842@mhs.dinus.ac.id, ²cinantya.paramita@dsn.dinus.ac.id, ³egia@dsn.dinus.ac.id

Correspondence Author Email: 111202214842@mhs.dinus.ac.id

Submitted: 17/11/2025; Accepted: 16/12/2025; Published: 16/12/2025

Abstrak—Penelitian ini bertujuan untuk menyoroti dan membandingkan kinerja tiga arsitektur pembelajaran mendalam, yakni CNN, VGG16, dan EfficientNet-B1 dalam mengklasifikasikan kondisi katarak berdasarkan citra fundus retina. Sebanyak 2600 citra fundus dari dua kelas (normal dan katarak) dikumpulkan dari sumber terbuka dan diproses dalam dua versi: citra asli dan citra dengan kontras yang ditingkatkan menggunakan Contrast Limited Adaptive Histogram Equalization (CLAHE). Setiap model diuji menggunakan kedua versi dataset, dengan evaluasi berdasarkan akurasi, presisi, recall, dan skor F1. Hasil percobaan ini menunjukkan bahwa penerapan CLAHE terbukti meningkatkan akurasi CNN dari 0,89 (89%) menjadi 0,97 (97%) serta, yang penting untuk diagnosis klinis, meningkatkan recall untuk kelas katarak dari 0,81 (81%) menjadi 0,97 (97%) dengan presisi 0,98 (98%), skor f1 0,97(97%) dan mengurangi jumlah False Negative(FN) dari 9 menjadi 6. Demikian pula, meningkatkan akurasi VGG16 dari 0,93 (93%) (dengan presisi 0,91 (91%), recall 0,96 (96%), skor f1 0,94 (94%)) menjadi 0,96 (96%) (presisi 0,94 (94%), recall 0,98 (98%), skor f1 0,96 (96%)), dan juga mengurangi jumlah FN dari 9 menjadi 6, sehingga meningkatkan reliabilitas klinis. Berbeda dengan model EfficientNet-B1, CLAHE tidak memberikan peningkatan yang signifikan, dengan akurasi 0,97 (97%), presisi 0,98 (98%), recall 0,98 (98%), dan skor f1 0,97 (97%) justru menurunkan performa akurasi menjadi 0,96 (96%) dan presisi menjadi 0,94 (94%). Hal ini menunjukkan bahwa efektivitas teknik pra-proses sangat bergantung pada arsitektur model yang digunakan. CLAHE telah terbukti efektif pada model konvensional seperti CNN dan VGG16, tetapi kurang optimal untuk model pra-latihan yang kompleks seperti EfficientNet-B1. Temuan ini berkontribusi pada pengembangan sistem klasifikasi citra medis yang adaptif dan efisien, khususnya dalam konteks skrining katarak otomatis di layanan kesehatan primer.

Kata Kunci: CNN; VGG16; EfficientNet-B1; CLAHE; Klasifikasi Katarak; Citra Fundus


Abstract—This study aims to highlight and compare the performance of three deep learning architectures, namely CNN, VGG16, and EfficientNet-B1, in classifying cataract conditions based on retinal fundus images. A total of 2600 fundus images of two classes (normal and cataract) were collected from open sources and processed in two versions: the original images and contrast-enhanced images using Contrast Limited Adaptive Histogram Equalization (CLAHE). Each model was tested using both versions of the dataset, with evaluation based on accuracy, precision, recall, and F1 score. The results of this experiment show that the application of CLAHE is proven to improve the accuracy of CNN from 0.89 (89%) to 0.97 (97%) and, importantly for clinical diagnosis, improve the recall for cataract class from 0.81 (81%) to 0.97 (97%) with precision 0.98 (98%), f1 score 0.97 (97%) and reduce the number of False Negatives (FN) from 9 to 6. Similarly, it improves the accuracy of VGG16 from 0.93 (93%) (with precision 0.91 (91%), recall 0.96 (96%), f1 score 0.94 (94%)) to 0.96 (96%) (precision 0.94 (94%), recall 0.98 (98%), f1 score 0.96 (96%)), and also reduces the number of FN from 9 to 6, thereby improving clinical reliability. In contrast to the EfficientNet-B1 Model, CLAHE does not provide significant improvement. significant. significant, with an accuracy of 0.97 (97%), precision of 0.98 (98%), recall of 0.98 (98%), and f1 score of 0.97 (97%), the accuracy performance actually decreased to 0.96 (96%) and precision to 0.94 (94%). This shows that the effectiveness of preprocessing techniques is highly dependent on the model architecture used. CLAHE has been shown to be effective on conventional models such as CNN and VGG16, but is less optimal for complex pretrained models such as EfficientNet-B1. These findings contribute to the development of adaptive and efficient medical image classification systems, particularly in the context of automated cataract screening in primary healthcare.

Keywords: CNN; VGG16; EfficientNet-B1; CLAHE; Cataract Classification; Fundus Image

1. PENDAHULUAN

Penyebab utama dari kebutaan salah satunya yakni penyakit katarak. Katarak terjadi ketika lensa mata yang awalnya terlihat bening dan jernih berubah menjadi kotor, sehingga menghalangi cahaya yang masuk ke dalam retina. Penyakit ini masih menjadi masalah kesehatan masyarakat yang serius di dunia termasuk negara-negara berkembang seperti Indonesia. Oleh karena itu, organisasi dunia di tingkat *World Health Organization* (WHO) mengumumkan pada tahun 2023 ada sekitar 51% kasus kebutaan di seluruh dunia disebabkan oleh katarak, jumlahnya sendiri ada lebih dari 20 juta orang [1]. Usia yang paling banyak diderita penderitanya secara spesifik ada di usia lanjut, biasanya yang memiliki usia diatas 50 tahun. Selain usia lanjut, penderita Diabetes juga bisa meningkatkan resiko terjangkit penyakit ini karena glukosa berlebihan dapat menarik air dan menyebabkan lensa mata bengkak yang mengakibatkan katarak. Di daerah yang memiliki sinar *ultraviolet* tinggi juga rentan memicu katarak dikarenakan hal tersebut dapat mempercepat penuaan alami dari lensa mata. Di Indonesia sendiri, katarak juga menjadi penyebab utama dari kebutaan, dengan kasus gangguan penglihatan beratnya ada sekitar 1,6% berdasarkan data Riset Kesehatan Dasar (Riskesdas) pada tahun 2018 [2]. Kondisi ini diprediksi akan terus meningkat akibat terbatasnya peralatan medis terutama poli mata di fasilitas-fasilitas layanan kesehatan, rendahnya pemahaman masyarakat terhadap kesehatan mata, dan juga pola hidup masyarakat yang tidak sehat.

Secara visual, citra fundus dari mata normal dan mata katarak menunjukkan perbedaan yang mencolok seperti pada Gambar 1. Citra fundus normal menampilkan struktur retina dengan sangat jelas, memperlihatkan detail seperti pembuluh darah, disk optik, dan makula secara utuh. Pantulan cahaya merah *red reflex* yang dihasilkan saat pemotretan tampak terang dan merata, yang menandakan bahwa lensa mata jernih. Oleh karena itu, kualitas gambar yang dihasilkan tinggi, dengan kontras optimal dan tanpa kabut[3]. Sebaliknya, kualitas gambar fundus pada penderita katarak berkurang akibat kekeruhan lensa mata opasitas lensa [4]. Kondisi ini menyebabkan gambar fundus menjadi kabur, kontras memudar, dan detail struktur retina menjadi kurang jelas. Refleksi lensa merah bahkan mungkin tidak terlihat sama sekali karena lensa yang kotor dan menyebarkan cahaya. Seringkali, citra retina tidak memberikan informasi yang diperlukan untuk diagnosis katarak parah [5]. Katarak terjadi karena protein lensa mata menggumpal dan strukturnya rusak, sehingga lensa yang tadinya bening dan jernih berubah menjadi keruh. Kerusakan ini secara efektif menghalangi cahaya untuk mencapai retina, yang pada akhirnya membuat kualitas penglihatan menurun drastis. Jika kekeruhan lensa terlalu tinggi, kualitas gambar yang dihasilkan oleh alat seperti funduskopi atau OCT dapat menurun drastis [6]. Namun, dokter dapat mengidentifikasi masalah menggunakan pola khas dari citra fundus tersebut.



Gambar 1. Perbandingan citra fundus (a) normal dan (b) katarak.

Dalam beberapa dekade terakhir ini, kemajuan dari teknologi telah membawa perubahan yang cukup berarti bagi dunia medis, terutama dalam diagnosis penyakit berdasarkan citra medis. Kemajuan ini didorong oleh Kecerdasan Buatan (AI), khususnya algoritma *Convolutional Neural Networks* (CNN). Model tersebut dilatih menggunakan ribuan citra mata, seperti citra fundus retina, OCT, dan CFF yang sudah disetujui oleh dokter mata ahli untuk dipelajari. Berkat pelatihan tersebut, AI dapat mendeteksi pola penyakit yang bahkan sulit dideteksi oleh mata manusia. CNN, algoritma paling umum digunakan dalam kemajuan ini dan telah menunjukkan hasil yang tinggi dibandingkan manusia [7]. Oleh karena itu, teknologi ini berperan penting dalam upaya global mencegah kebutaan akibat katarak

Penelitian sebelumnya menggunakan jaringan saraf tiruan konvolusional (CNN) untuk mengklasifikasikan gambar fundus ke dalam empat label dengan arsitektur EfficientNetB3 dan VGG16. Metode ini mencapai performa dengan akurasi 93% [4]. Penelitian berikutnya juga menggunakan CNN untuk dataset fundus, dengan akurasi 98.37% [8]. Penelitian-penelitian tersebut memberikan dasar yang kuat untuk membandingkan model-model baru dalam penelitian ini. Teknologi yang memberikan peningkatan citra seperti CLAHE masih belum banyak digunakan. Teknik pra-proses *Contrast Limited Adaptive Histogram Equalization* (CLAHE) merupakan teknik yang digunakan untuk membuat detail kecil pada gambar menjadi lebih jelas dan menonjol. CLAHE unggul dalam meningkatkan kontras gambar karena ia efektif mengatasi masalah peningkatan kontras yang berlebihan yang sering terjadi pada metode lain. Teknik ini bekerja dengan baik dengan mengatur nilai ambang batas klip pada histogram, sehingga kualitas gambar dapat ditingkatkan tanpa distorsi yang tidak wajar. CLAHE terbukti dapat meningkatkan hasil kualitas citra CCTV, seperti yang dilaporkan dalam penelitian dimana terdapat adanya peningkatan nilai PSNR pada citra setelah dilakukan CLAHE sebesar rata-rata 43.1497 lebih besar dibandingkan citra awal [8]. CLAHE diakui sebagai teknik yang baik untuk peningkatan citra digital, khususnya pada citra medis, karena menghasilkan kualitas yang lebih bagus dibandingkan hanya metode kontras dasar. Bahkan, teknik ini bekerja secara visual dan terukur dengan mempertajam tampilan pembuluh darah retina dengan menghilangkan noise atau batas gambar buatan yang mungkin muncul setelah pemrosesan [9]. Oleh karena itu, meskipun potensi CLAHE sebagai teknik pra-proses sudah terbukti, evaluasi sistematis mengenai efektivitasnya dalam meningkatkan kinerja klasifikasi katarak pada arsitektur *deep learning* yang beragam terutama antara model sederhana CNN dan model kompleks EfficientNet-B1 masih terbatas.

Pendekatan serupa menggunakan model deteksi objek modern seperti YOLOv8 juga telah dievaluasi dan menunjukkan kinerja yang kuat pada citra medis untuk kasus deteksi lesi kulit multi-kelas [10]. Penelitian ini mengevaluasi kinerja tiga arsitektur deep learning utama yakni CNN dasar, VGG16, dan EfficientNet-B1 pada citra fundus retina untuk klasifikasi katarak, dan dibandingkan secara kritis pada citra asli dan citra yang ditingkatkan dengan CLAHE, menggunakan metrik akurasi, presisi, recall, dan skor F1. Hasil dari penelitian ini memberikan panduan yang baik dalam pemilihan model yang paling optimal untuk diagnosis katarak berbasis kecerdasan buatan, yang secara langsung akan berguna terutama pada bidang medis dengan memungkinkan pengembangan proses skrining yang lebih akurat dan cepat, terutama di daerah tertinggal. Oleh karena itu, penemuan ini berkontribusi besar

dalam mendukung deteksi dini dan pengambilan keputusan klinis dalam waktu singkat namun bermakna, dan pada akhirnya akan memperluas akses terhadap perawatan mata dan membantu mendeteksi katarak untuk mencegah kebutaan yang dapat dihindari.

2. METODOLOGI PENELITIAN

2.1 Dataset

Penelitian ini menggunakan dataset utama yakni kumpulan citra fundus retina dari platform Kaggle dengan kelas citra normal dan katarak. Dataset *Eye Disease Recognition (ODIR-5K)* digunakan karena keanekaragaman pikselnya karena data yang dikumpulkan dari berbagai fasilitas medis menggunakan model kamera fundus yang berbeda, seperti Canon, Zeiss, dan Kowa. Dimensi gambar pada dataset ini terdiri dari ukuran 188 piksel sampai 5184 piksel dalam format file JPEG dengan ukuran berbeda beda. Untuk mengatasi masalah variasi resolusi diterapkan tahap prapemrosesan dimana setiap gambar diubah ukurannya menjadi dimensi persegi yang seragam 224x224 piksel dan 240x240 piksel, sebelum digunakan untuk melatih dan menguji sistem klasifikasi. Penelitian tahun 2025 memperkenalkan penerapan normalisadisi. Terinspirasi oleh cara kerja sistem visual biologis yang dirancang khusus untuk menormalkan variabilitas gambar sehingga terbukti meningkatkan kinerja dan ketahanan sistem klasifikasi secara keseluruhan [10].


Studi ini menggunakan sekitar 2.600 gambar dengan rasio 70:15:15, sesuai praktik umum dalam pembuatan model pembelajaran mesin, terutama untuk dataset berukuran kecil hingga menengah [4]. Sebagian besar data yakni sebesar 454 digunakan untuk melatih model. Sebagian data tambahan dengan jumlah 97 gambar digunakan untuk memastikan bahwa model telah diajarkan dengan benar dan bukan hanya menghafal. 99 data lain digunakan sebagai tes akhir untuk mengevaluasi kinerja model[11]. Proses pembagian dilakukan dengan hati-hati untuk memastikan setiap kelompok data latih, validasi, dan uji yang memiliki distribusi kelas yang seimbang.

Tabel 1. Distribusi Dataset

Kelas	Train	Validation	Test	Total
Normal 224x224 piksel	454	97	99	650
Katarak 224x224 piksel	454	97	99	650
Normal 240x240 piksel	454	97	99	650
Katarak 240x240 piksel	454	97	99	650
Total	1816	388	396	2600

2.2 Contrast Limited Adaptive Histogram Equalization(CLAHE)

Sebelum kami mulai melatih model, dataset kami dipersiapkan dalam dua versi untuk perbandingan versi pertama adalah citra asli yang diambil langsung dari sumbernya, dan versi kedua adalah citra yang telah ditingkatkan kualitasnya melalui teknik preprocessing bernama *Contrast Limited Adaptive Histogram Equalization (CLAHE)*[12]. Dalam penelitian ini, CLAHE diterapkan dengan parameter krusial yakni *clip limit* diatur sebesar 2.0 dan *tile grid size* sebesar 8 x 8. Penelitian ini menggunakan CLAHE karena kemampuannya yang unggul dalam meningkatkan kontras lokal terutama area yang gelap atau kontrasnya buruk tanpa menghasilkan *noise* yang berlebihan [3]. Peningkatan ini sangat penting karena membantu memperjelas detail struktur fundus retina yang dibutuhkan model untuk mendeteksi fitur- fitur katarak sebelum diproses oleh model. Penggunaan CLAHE memang terbukti bagus dalam memperbaiki kualitas visual citra medis. Masing-masing sebelum dan sesudah prapemrosesan menggunakan CLAHE. Teknik ini meningkatkan kontras lokal sehingga membantu model dalam proses ekstraksi fitur.




Gambar 2. Citra fundus retina sebelum dan sesudah di proses CLAHE

CLAHE beroperasi dalam tiga langkah utama diantaranya, Pertama, citra dibagi menjadi blok-blok kecil (subdivisi lokal) untuk memfokuskan peningkatan kontras pada area tertentu. Kedua, pemerataan histogram lokal

dilakukan di setiap blok, menyesuaikan kontras dengan kebutuhan area tersebut. Terakhir, untuk mencegah efek samping umum seperti amplifikasi noise, CLAHE menerapkan batas pemotongan kontras, memotong nilai histogram di atas ambang batas yang ditentukan dan mendistribusikan kembali kelebihanannya secara merata di seluruh tingkat intensitas, memastikan detail halus tetap jelas tanpa kontras yang berlebihan. Pentingnya preprocessing yang tepat ini sejalan dengan temuan yang menegaskan bahwa strategi data preprocessing adalah kunci untuk merancang model CNN yang tangguh (robust) untuk klasifikasi citra medis [13]. Proses CLAHE bertujuan untuk menyeimbangkan tingkat kecerahan pada gambar dengan memperbaiki profil kecerahan setiap area kecil. Dengan menggunakan histogram untuk mencatat jumlah piksel tiap warna, CLAHE mengatasi masalah kontras buruk dengan menerapkan kliping, di mana batas maksimum ditetapkan untuk batang grafik yang terlalu tinggi dan piksel yang terpotong didistribusikan kembali. Setelah histogram seimbang, data diterjemahkan menjadi gambar baru menggunakan *Cumulative Distribution Function* (CDF), yang merupakan kurva sferis ($CDF(k) \times (L - 1)$) di mana *Cumulative* menunjukkan jumlah frekuensi piksel, *Distribution* menggambarkan intensitas setiap gelombang, dan *Function* bertindak sebagai transisi dari gelombang lama ke gelombang baru. Hasil CDF kemudian dianalisis menggunakan $(L-1)$ untuk mencocokkan kecerahan maksimum (255), sehingga menghasilkan citra yang lebih representatif. Proses ini mencakup penggabungan blok-blok secara mulus. Di sini, teknik penghalusan yang disebut interpolasi bilinear digunakan untuk memastikan tidak ada jahitan yang mengganggu atau batas kasar antar area. Kombinasi kontras lokal dan penghalusan ini merupakan kunci dari keunggulan CLAHE dalam pemrosesan citra medis, karena mampu menyoroti detail penting untuk diagnosis tanpa memperparah gangguan seperti noise dan juga sudah dikonfirmasi oleh penelitian [14].

2.3 Praproses dan Augmentasi

Struktur dataset diatur menjadi subset pelatihan, validasi, dan pengujian dengan rasio 70:15:15 sesuai penelitian [16]. Prapemrosesan yang dipakai menggunakan modul ImageDataGenerator dari pustaka Keras supaya model lebih umum dan mencegah overfitting. Selanjutnya semua gambar dinormalisasi dalam set pelatihan ke rentang nilai 0,1 dan penskalaan ulang sebesar 1/255. Augmentasi juga diterapkan dengan rotasi acak hingga 15 derajat, zoom acak 10%, dan pembalikan horizontal. Kombinasi transformasi digunakan untuk meningkatkan variasi data pelatihan secara artifisial, sehingga model menjadi lebih tangguh dan mampu mengenali variasi citra dunia nyata tanpa perlu augmentasi data manual [3].



Gambar 3. Diagram flowchart

2.4 Modeling Convolutional Neural Network

Model *Convolutional Neural Network* (CNN) yang digunakan terdiri dari lapisan konvolusional bertumpuk. Setiap lapisan menggunakan kernel 3x3 dan diaktifkan oleh fungsi ReLU. Untuk menurunkan kompleksitas, disisipkan lapisan Max Pooling berukuran 2x2 supaya mengurangi dimensi spasial (down-sampling) fitur yang telah diekstrak [15]. Output konvolusi kemudian diratakan *flatten* dan dihubungkan ke lapisan Dense yang terdiri dari 128 unit. Untuk meningkatkan kemampuan generalisasi model dan mencegah overfitting, disisipkan lapisan Dropout dengan rasio 0.5 tepat sebelum lapisan keluaran. Lapisan keluaran menggunakan fungsi aktivasi Softmax dengan dua neuron, yang sama dengan jumlah kelas yang akan diprediksi. Pendekatan serupa digunakan dengan pengoptimal RMSProp optimizer dan fungsi kerugian *Binary Cross Entropy*. Untuk memastikan replikasi dan efisiensi pelatihan, nilai hyperparameter yang digunakan yakni *learning rate* diatur sebesar 0,0001, *batch size* sebesar 32, dan jumlah epoch maksimum 50. Hasilnya menunjukkan akurasi sebesar 91,25%, yang menunjukkan efektivitas arsitektur CNN dalam mengenali pola visual pada citra fundus katarak [6]. Tinggi atau lebar dimensi spasial keluaran yang dihasilkan secara sistematis menggunakan rumus matematika $((W - F + 2P) / S) + 1$, dimana W yakni ukuran masukan, F yakni ukuran kernel, P nilai padding dan S adalah nilai stride. Rumus ini penting untuk menentukan ukuran fitur yang dihasilkan pada setiap lapisan.

2.5 VGG16

Arsitektur VGG16 diperkenalkan oleh Visual Geometry Group di Universitas Oxford pada tahun 2015[16]. Arsitektur ini dipakai karena penggunaan kernel konvolusi (3x3) yang tidak berubah-ubah dan pengaturan kedalaman jaringan yang teratur sesuai penelitian yang dipakai sebelumnya tentang gambar medis[17]. Arsitektur yang dipakai terdiri dari 13 lapisan konvolusional yang dibagi menjadi lima blok. Setiap blok diikuti oleh lapisan Max Pooling. Fase klasifikasi diakhiri dengan tiga lapisan *Fully Connected* (FC). Setiap lapisan konvolusional menggunakan fungsi aktivasi ReLU,

dan peningkatan bertahap di setiap blok konvolusional 64, 128, 256, 512, dan 512. Lapisan keluaran menggunakan fungsi Softmax dengan 1000 kelas dataset ImageNet pada model asli. Tiga lapisan *Fully Connected* (FC) disesuaikan dengan lapisan baru Flatten, Dense 256 unit, aktivasi ReLU, Dropout dengan rasio 0.5, Dense 2 unit dan aktivasi Softmax. Untuk memastikan replikasi pelatihan dan efisiensi, kami menggunakan pengoptimal Adam dan fungsi kerugian Binary Cross Entropy, dengan Learning Rate sebesar 0.0001, batch size 16, dan maximum epochs sebanyak 50. Model ini juga menggunakan bobot yang telah dilatih dari ImageNet untuk mempercepat penstabilan pelatihan.

2.6 EfficientNet-B1

Arsitektur CNN terus berevolusi hingga dirancang model EfficientNet, inovasi besar yang digunakan untuk mengoptimalkan akurasi dan efisiensi komputasi [18]. EfficientNet memiliki beberapa versi dari B0 hingga B7, yang masing-masing lebih besar, kompleks, dan lebih akurat daripada versi sebelumnya. EfficientNet-B1 digunakan karena memiliki keseimbangan baik antara kinerja dan jumlah parameter yang dibutuhkan. Arsitekturnya terdiri dari beberapa blok *Mobile Inverted Bottleneck Convolution* (MBCConv). EfficientNet-B1 juga menggunakan teknik squeeze-and-excitation untuk meningkatkan fitur-fitur relevan dan Swish sebagai fungsi aktivasi[3]. Dalam penelitian ini, bagian klasifikasi asli (lapisan atas) dihapus dan diganti lapisan baru Global Average Pooling untuk meringkas fitur, lapisan Dense sebanyak 256 unit menggunakan aktivasi ReLU, kemudian lapisan Dropout (0,5), dan lapisan Dense sebanyak 2 unit menggunakan aktivasi Softmax. Pengoptimalan yang kami gunakan yakni RMSProp dan learning rate sebesar 0.00001, batch size 16, dan epoch maksimal 50. Fine-tuning hanya dilakukan pada beberapa lapisan terakhir sehingga representasi fitur yang ada sesuai dengan distribusi data citra fundus retina.

2.7 Evaluasi

Performa model dievaluasi pada dua set data, antara lain gambar asli dan gambar CLAHE. Untuk setiap arsitektur, hasil prediksi pada data uji dibandingkan dengan kebenaran dasar menggunakan empat metrik utama yakni akurasi, yang mewakili proporsi total prediksi yang benar; presisi, yang mengukur presisi prediksi positif; recall, yang menilai sensitivitas model dalam menangkap semua kasus positif; dan skor F1, yang memberikan gambaran umum tentang keseimbangan antara presisi dan recall [13].

Akurasi didapatkan dari

$$Akurasi = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

Presisi didapatkan dari

$$Presisi = \frac{TP}{TP + FP} \quad (2)$$

Recall didapatkan dari

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

Skor F1 didapatkan dari

$$Skor F1 = 2 \times \frac{Presisi \times Recall}{Presisi + Recall} \quad (4)$$

Confusion Matrix yang dipakai seperti True Positive (TP) yakni jumlah kasus yang diprediksi positif dan memang positif; True Negative (TN) jumlah kasus yang diprediksi negatif dan memang negatif; False Positive (FP) jumlah kasus yang diprediksi positif padahal negatif; False Negative (FN) jumlah kasus negatif padahal positif juga digunakan untuk menunjukkan dengan jelas bagaimana klasifikasi dilakukan. Validasi model dilakukan pada 15% subset dari data validasi, dan selama pelatihan, teknik penghentian awal digunakan untuk mengurangi overfitting [13]. Perbandingan performa antara model yang menggunakan dua versi set data ini bertujuan untuk secara khusus mengukur dampak teknik CLAHE terhadap efektivitas setiap arsitektur pembelajaran mendalam.

3. HASIL DAN PEMBAHASAN

3.1 Hasil

Penelitian ini dilakukan menggunakan laptop yang dilengkapi prosesor AMD Ryzen 3 3250U, GPU AMD Radeon™ Graphics terintegrasi, dan RAM 8 GB. Kami menggunakan Kaggle dan Visual Studio Code untuk melatih dan menguji semua model CNN, VGG16, dan EfficientNet-B1. Eksperimen dijalankan pada dua versi dataset citra fundus, citra asli dan citra yang telah diproses sebelumnya dengan CLAHE. Sebelum pelatihan, semua citra distandarisasi menjadi 224×224 piksel dan dinormalisasi ke rentang [0,1]. Untuk meningkatkan kinerja model, augmentasi dilakukan pada data pelatihan. Augmentasi yang digunakan berupa rotasi hingga 15 derajat, flip horizontal, dan zoom hingga 10%. Pelatihan menggunakan epoch paling banyak 50 yang hasilnya tertera pada tabel 2, pengoptimal Adam dengan laju pembelajaran 0,0001 dan ukuran batch sebesar 32. Penelitian ini menggunakan penghentian awal dan dropout untuk mencegah overfitting. Evaluasi model akhir dilakukan pada data uji sebesar 15% dari seluruh dataset menggunakan metrik akurasi, presisi, recall, dan skor F1.

Tabel 2. Hasil Epoch 0,25,50 tiap Model

Model	Epoch	Akurasi Pelatihan	Loss Pelatihan
CNN	0	0.50	0.69
	25	0.85	0.30
	50	0.89	0.25
CNN dengan CLAHE	0	0.50	0.69
	25	0.90	0.15
	50	0.97	0.08
VGG16	0	0.70	0.50
	25	0.90	0.20
	50	0.93	0.15
VGG16 dengan CLAHE	0	0.80	0.40
	25	0.94	0.12
	50	0.96	0.10
EfficientNet-B1	0	0.85	0.30
	25	0.97	0.08
	50	0.97	0.07
EfficientNet-B1 dengan CLAHE	0	0.85	0.30
	25	0.96	0.10
	50	0.96	0.11

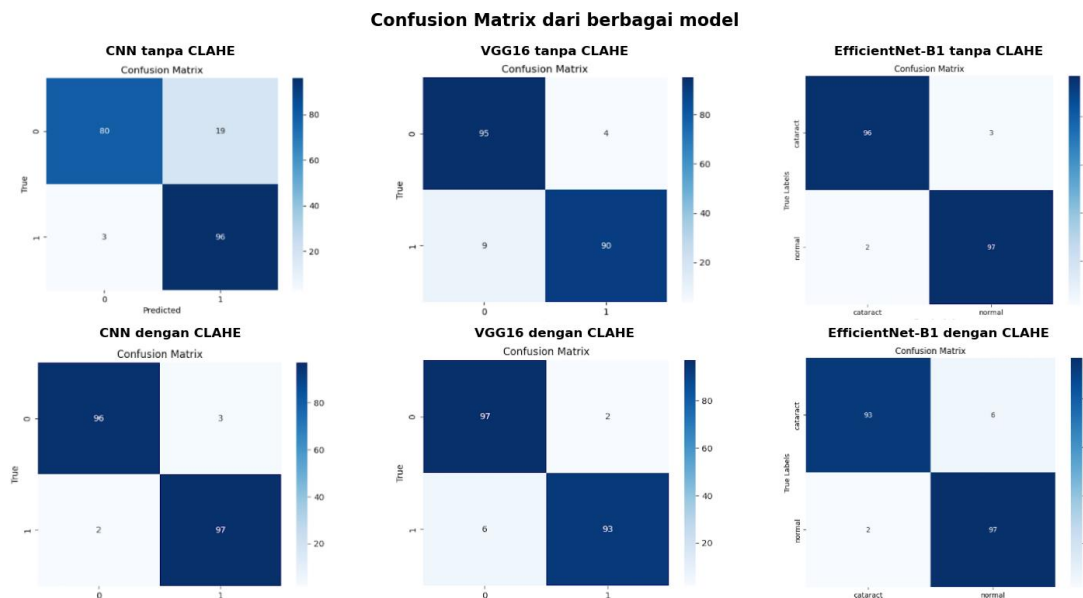
Tabel 3. Hasil Evaluasi Model pada Data Uji

Model	Kelas	Akurasi	Presisi	Recall	Skor F1
CNN	Cataract	0.89	0.96	0.81	0.88
	Normal	0.89	0.83	0.97	0.90
CNN dengan CLAHE	Cataract	0.97	0.98	0.97	0.97
	Normal	0.97	0.97	0.98	0.97
VGG16	Cataract	0.93	0.91	0.96	0.94
	Normal	0.93	0.96	0.91	0.93
VGG16 dengan CLAHE	Cataract	0.96	0.94	0.98	0.96
	Normal	0.96	0.98	0.94	0.96
EfficientNet-B1	Cataract	0.97	0.98	0.97	0.97
	Normal	0.97	0.98	0.98	0.97
EfficientNet- B1 dengan CLAHE	Cataract	0.96	0.98	0.94	0.96
	Normal	0.96	0.94	0.98	0.96

Berdasarkan analisis komprehensif dari hasil pada Tabel 2, uji menunjukkan model dengan kinerja terbaik yaitu CNN dengan CLAHE yang mencapai akurasi tertinggi, yaitu 0,97, dengan skor F1 sebesar 0,97. Hal ini menjadikannya yang terbaik. Dampak CLAHE pada CNN terlihat yakni dengan akurasi 0,89 menjadi 0,97, skor F1 untuk Katarak dari 0,88 menjadi 0,97, dan skor F1 untuk Normal 0,90 menjadi 0,97. Peningkatan yang bagus ini, terutama pada Recall untuk kelas Cataract 0,81 ke 0,97, menunjukkan bahwa CLAHE dapat meningkatkan pencocokan gambar secara signifikan, memungkinkan model yang lebih ringan untuk bekerja dengan arsitektur yang lebih canggih. Hal ini menjadikannya pilihan yang unggul untuk strategi efisiensi. Selanjutnya model VGG16 dengan CLAHE mencapai peningkatan secara kolektif, dengan akurasi 0,96 dan skor F1 0,96, peningkatan yang signifikan dibandingkan model VGG16 dasar dengan Akurasi 0,93, skor F1 0,94 untuk Katarak. Hal ini menunjukkan bahwa CLAHE sangat cocok untuk arsitektur pembelajaran transfer klasik.

Model pembelajaran EfficientNet-B1 berkinerja sangat baik, dengan akurasi 0,97 tanpa CLAHE dan presisi serta recall masing-masing sebesar 0,98 dan 0,97. Oleh karena itu, modifikasi CLAHE pada model EfficientNet-B1 dengan CLAHE mengurangi akurasi menjadi 0,96 dan recall menjadi 0,94 untuk kelas Cataract (skor F1 sebesar 0,96). Hal ini menunjukkan bahwa prapemrosesan kontras tambahan tidak berdampak signifikan pada ekstraksi fitur EfficientNet-B1 yang sudah sangat baik, kemungkinan karena rendahnya jumlah noise.

Model VGG16 berada di peringkat selanjutnya dengan akurasi 0,93. Model ini memprediksi kelas normal dengan skor 0,96, tetapi memiliki daya ingat yang lebih baik untuk kelas normal dengan skor 0,91, yang menunjukkan lebih sedikit stres di tempat kerja. Hasil akhirnya adalah CNN tanpa CLAHE, yang memiliki skor F1 0,88 dan akurasi 0,89. Daya ingatnya untuk kelas Katarak hanya 0,81. Fakta bahwa CNN (0,89) dan CNN dengan CLAHE (0,97) memiliki perbedaan kinerja yang begitu besar menunjukkan bahwa CLAHE merupakan peningkatan yang signifikan, terutama untuk arsitektur ini.



Gambar 4. Confusion matrix dari 3 Model: CNN, VGG16, EfficientNet-B1 dengan dan tanpa CLAHE

Tabel 4. Hasil Confusion matrix pada Data Uji

Model	True Positive	True Negative	False Positive	False Negative
CNN	96	80	19	3
CNN dengan CLAHE	97	96	3	2
VGG16	90	95	4	9
VGG16 dengan CLAHE	93	97	2	6
EfficientNet-B1	97	96	3	2
EfficientNet-B1 dengan CLAHE	97	93	6	2

Dari perhitungan confusion matrix yang tertera pada Tabel 3, berikut analisis dan kesimpulan yang dapat diambil

3.1.1 Model CNN dasar

Dari hasil perhitungan menggunakan CNN tanpa CLAHE dapat disimpulkan sebagai berikut,

Akurasi (*Accuracy*) = $(TP + TN) / Total = (96 + 80) / 198 = 0.8889$
 Presisi (*Precision*) = $TP / (TP + FP) = 96 / (96 + 19) = 0.8348$
 Recall (*Sensitivitas*) = $TP / (TP + FN) = 96 / (96 + 3) = 0.9697$
F1-Score = $2 * (Precision * Recall) / (Precision + Recall)$
 = $2 * (0.8348 * 0.9697) / (0.8348 + 0.9697) \approx 0.8973$

Kinerja awal model CNN menunjukkan tingkat Recall yang tinggi 0.96. Namun, nilai Presisi relatif rendah 0.83 akibat tingginya False Positive (FP=19), menunjukkan model sering salah mengklasifikasikan citra non-katarak sebagai katarak.

3.1.2 Model CNN dengan CLAHE

Dari hasil perhitungan menggunakan CNN dengan CLAHE dapat disimpulkan sebagai berikut,

Akurasi = 0.9747
 Presisi = 0.9700
 Recall = 0.9798
 F1-Score = 0.9749

Penerapan CLAHE secara signifikan meningkatkan kinerja CNN. Semua metrik evaluasi naik tajam. Peningkatan terbesar adalah pada Presisi dan Spesifisitas (karena FP turun dari 19 menjadi 3), yang membuat model ini sangat andal dengan Akurasi 0.97

3.1.3 Model VGG16

Dari hasil perhitungan menggunakan VGG16 Tanpa CLAHE dapat disimpulkan sebagai berikut,

Akurasi = 0.9343
 Presisi = 0.9574
 Recall = 0.9091
 F1-Score = 0.9326

VGG16 menunjukkan Presisi yang baik 0.95 karena FP yang rendah. Namun, Recall 0.9 lebih rendah akibat False Negative (FN=9) yang cukup tinggi, menandakan model ini cenderung melewatkan beberapa kasus katarak (kasus positif).

3.1.4 Model VGG16 dengan CLAHE

Dari hasil perhitungan menggunakan VGG16 dengan CLAHE dapat disimpulkan sebagai berikut,

Akurasi	= 0.9596
Presisi	= 0.9789
Recall	= 0.9394
F1-Score	= 0.9587

CLAHE meningkatkan kinerja VGG16 secara keseluruhan, ditandai dengan peningkatan Akurasi menjadi 0.95. Hal yang paling krusial dalam diagnosis medis, FN berhasil diturunkan dari 9 menjadi 6, yang meningkatkan Recall dari 0.90 menjadi 0.93

3.1.5 Model EfficientNet-B1

Dari hasil perhitungan menggunakan EfficientNet-B1 Tanpa CLAHE dapat disimpulkan sebagai berikut,

Akurasi	= 0.9747
Presisi	= 0.9700
Recall (Sensitivitas)	= 0.9798
F1-Score:	= 0.9749

Model ini menunjukkan kinerja optimal tanpa CLAHE, dengan Akurasi tertinggi 0.97 dan kombinasi Presisi dan Recall yang sangat seimbang. Nilai False Negative (FN=2) sangat minimal, menunjukkan keandalan diagnostik yang unggul.

3.1.6 Model EfficientNet-B1 dengan CLAHE

Dari hasil perhitungan menggunakan EfficientNet-B1 dengan CLAHE dapat disimpulkan sebagai berikut,

Akurasi	= 0.9596
Presisi	≈ 0.9417
Recall	≈ 0.9798
F1-Score	≈ 0.9604

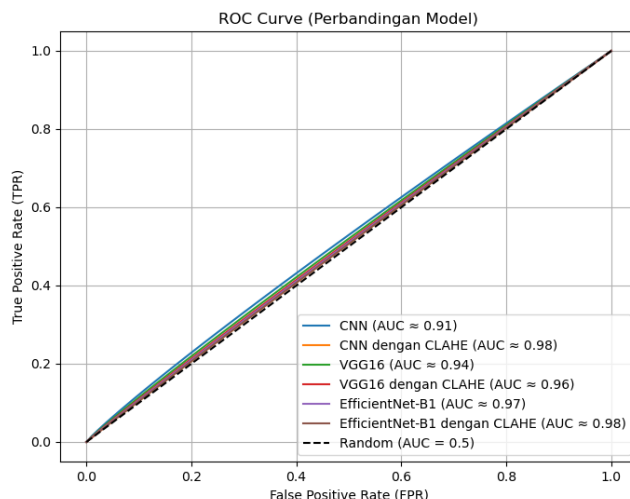
Penerapan CLAHE pada EfficientNet-B1 menurunkan Akurasi (dari 0.97 menjadi 0.95) dan Presisi (dari 0.97 menjadi 0.94) karena peningkatan False Positive (FP) dari 3 menjadi 6. Hal ini menegaskan bahwa arsitektur yang sudah kuat ini tidak memerlukan pre-processing tambahan, dan bahkan dapat terganggu olehnya.

Analisis komparatif kinerja model klasifikasi menunjukkan bahwa konsisten meningkatkan kemampuan diskriminatif pada arsitektur yang kurang kompleks; model CNN mengalami peningkatan terbesar, di mana Akurasi melonjak dari 0.8889 menjadi 0.9747 dan Presisi dari 0.8348 menjadi 0.9700 akibat penurunan tajam False Positive (FP) dari 19 menjadi 3. Demikian pula, CLAHE pada VGG16 meningkatkan Akurasi dari 0.9343 menjadi 0.9596 dengan mengurangi False Negative (FN) secara kritis dari 9 menjadi 6, yang krusial untuk meningkatkan Sensitivitas (Recall) dari 0.9091 menjadi 0.9394 dan mencerminkan reliabilitas klinis yang lebih baik. Sebaliknya, arsitektur deep learning yang kuat, EfficientNet-B1, telah mencapai kinerja optimalnya tanpa pre-processing tambahan (Akurasi 0.9747, Recall 0.9798 dengan FN=2); penambahan CLAHE justru menurunkan Akurasi dan Presisi karena peningkatan FP, menegaskan bahwa model yang sudah terlatih memiliki ketahanan inheren terhadap variasi pencahayaan. Kesimpulannya, untuk mencapai tujuan penelitian yakni optimalisasi Recall yang tinggi (meminimalkan FN), model CNN dengan CLAHE dan EfficientNet-B1 tanpa CLAHE menunjukkan hasil terbaik dengan nilai Recall sangat tinggi yaitu 0.9798.


Secara keseluruhan, hasil confusion matrix menunjukkan bahwa CLAHE paling efektif diterapkan pada arsitektur konvolusional sederhana seperti CNN dan VGG16. Kedua model memperoleh peningkatan simultan pada Sensitivitas (Recall) dan Spesifisitas, yang menandakan peningkatan reliabilitas sistem klasifikasi dalam konteks diagnosis medis. Nilai FN yang rendah sangat krusial karena menggambarkan minimnya kasus positif yang tidak terdeteksi. Sementara itu, EfficientNet-B1 mempertahankan performa terbaik tanpa CLAHE, dengan kombinasi sensitivitas dan spesifisitas tinggi yang menunjukkan stabilitas diagnostik dan validitas klinis unggul untuk penerapan praktis.

Kurva ROC (Receiver Operating Characteristic) digunakan terlihat pada Gambar 5 untuk mengevaluasi kemampuan model dalam membedakan dua kelas, yaitu citra normal dan katarak. ROC Curve menampilkan hubungan antara True Positive Rate (TPR) dan False Positive Rate (FPR), sedangkan luas area di bawah kurva (AUC) menunjukkan tingkat akurasi klasifikasi secara menyeluruh. Model EfficientNet-B1 dengan CLAHE memiliki nilai AUC tertinggi yaitu 0.98, yang menunjukkan kemampuan diskriminatif paling baik dalam mengenali citra katarak dan normal. Penerapan CLAHE secara konsisten meningkatkan area di bawah kurva (AUC) pada setiap arsitektur, dibandingkan dengan model tanpa CLAHE. Model CNN tanpa CLAHE memiliki AUC terendah (0.91), sedangkan EfficientNetB1 dengan CLAHE menunjukkan peningkatan performa signifikan dengan AUC mendekati sempurna.

Hal ini membuktikan bahwa proses peningkatan kontras melalui CLAHE mampu memperkuat fitur penting yang relevan dengan deteksi katarak pada citra fundus retina.




Gambar 5. Kurva ROC perbandingan model CNN, VGG16, dan EfficientNet-B1 dengan dan tanpa CLAHE



Gambar 6. Perbandingan Akurasi Tiap Model dengan dan tanpa CLAHE

Perbandingan akurasi pada Gambar 6 menunjukkan bahwa model CLAHE sangat berbeda dari model kinerja. Akurasi model CNN Sederhana meningkat paling tinggi, dari sekitar 0,89 menjadi sekitar 0,97. Hal ini menunjukkan bahwa CLAHE bekerja dengan baik untuk meningkatkan kesesuaian model dengan arsitektur yang lebih sederhana. Di sisi lain, VGG16 dengan CLAHE menunjukkan bahwa akurasi meningkat dari sekitar 0,93 menjadi 0,96. Tanpa CLAHE, model EffNet EfficientNet-B1 memiliki kinerja keseluruhan terbaik, dengan akurasi sekitar 0,97. Jadi, penambahan CLAHE pada EffNet hanya membuat akurasi turun menjadi 0,96. Prapemrosesan CLAHE umumnya efektif dalam meningkatkan kapabilitas model yang lebih robust, yang memungkinkan CNN Sederhana dengan CLAHE mempertahankan kinerja konsisten yang sebanding dengan model pembelajaran mendalam yang lebih kompleks, khususnya EffNet tanpa CLAHE.



Gambar 7. Perbandingan Precision, Recall, dan F1-Score Tiap Model

Analisis komparatif metrik kinerja presisi, recall, dan skor f1 pada Gambar 7 menunjukkan bahwa EfficientNet-B1 tanpa CLAHE menghasilkan keluaran kerja terbaik dan paling konsisten, mencapai skor tertinggi berkisar antara 0,97 hingga 0,98 di semua metrik, dengan demikian menunjukkan keunggulan algoritma pembelajaran mendalam yang kuat. Di sisi lain, CLAHE bekerja sangat baik untuk model yang lebih sederhana. CNN dengan CLAHE memiliki efek besar pada kinerja terendah 0,89 sampai 0,90 dan tetap stabil di 0,97. Hal ini menjadikannya

pilihan yang sangat baik dan efektif dibandingkan dengan strategi komputer trade-off. Kinerja VGG16 dengan CLAHE juga naik banyak, menjadi sebesar 0,96. Dengan begitu, menambahkan CLAHE ke EfficientNet-B1 dapat menurunkan skor menjadi 0,96, yang berarti bahwa prapemrosesan ini tidak selalu diperlukan atau bahkan dapat mempersulit untuk mendapatkan fitur dari model yang sudah sangat kuat.


3.2 Pembahasan

Berdasarkan hasil eksperimen, terevaluasi bahwa penggunaan CLAHE secara signifikan meningkatkan kinerja klasifikasi pada model CNN dasar dan VGG16. Model CNN menunjukkan peningkatan yang nyata dengan akurasi 0.97 dan skor F1 sebesar 0.97 setelah kontras lokal citra fundus ditingkatkan melalui CLAHE. Peningkatan signifikan dibanding tanpa CLAHE hanya memperoleh akurasi 0.89 dan skor F1 0.88. Model VGG16 dengan CLAHE juga menunjukkan peningkatan dengan akurasi 0.96 dan skor F1 sebesar 0.96 dari akurasi 0.97 dan skor F1 0.94. Peningkatan sejalan dengan karakteristik citra medis, di mana fitur-fitur penting seperti kekeruhan lensa akibat katarak menjadi lebih mudah terdeteksi ketika kontras lokal diperjelas, sehingga membantu kedua model dalam mengenali pola patologis secara lebih akurat. Efek positif CLAHE ini paling terlihat pada model CNN yang dilatih dari awal tanpa pretrained weights, dan juga memberikan manfaat bagi model VGG16 yang memiliki kapasitas representasi menengah [14].

Sebaliknya, model EfficientNet-B1 menunjukkan performa yang relatif stabil tanpa penerapan CLAHE dengan akurasi 0.97 dan skor F1 0.97 sejalan dengan penelitian sebelumnya [12]. Sebagai model pretrained yang telah dilatih pada jutaan citra dengan beragam kondisi pencahayaan dan tingkat kontras, EfficientNet-B1 memiliki kemampuan generalisasi yang kuat terhadap variasi karakteristik visual. Oleh karena itu, penerapan CLAHE tidak memberikan peningkatan performa yang signifikan, dan dalam beberapa kasus justru sedikit menurunkan akurasi. Fenomena ini kemungkinan disebabkan oleh munculnya artefak visual atau hilangnya detail halus akibat peningkatan kontras yang terlalu agresif, yang dapat mengganggu proses ekstraksi fitur oleh EfficientNet-B1 [12].

Pemilihan teknik CLAHE harus disesuaikan dengan karakteristik arsitektur model yang digunakan [3]. CLAHE telah menunjukkan kemajuan, terutama dengan model lama seperti CNN dan VGG16. Kedua model tersebut memerlukan bantuan dengan prapemrosesan untuk mengoreksi variasi kontras dengan CLAHE, fitur-fitur penting seperti kekeruhan lensa karena katarak menjadi lebih jelas, yang memungkinkan model untuk mengenali pola patologis dengan lebih akurat [15]. Di sisi lain, efek CLAHE tidak secara konsisten meningkatkan kinerja model yang telah dilatih sebelumnya seperti model dari arsitektur EfficientNet-B1. Penerapan teknik ygCLAHE perlu diseleksi pada setiap model karena kontras gambar bisa terlalu tajam dan bisa menghilangkan detail penting yang diperlukan untuk ekstraksi fitur [14]. CLAHE sebaiknya tidak diterapkan pada model EfficientNet-B1, karena model sendiri sudah efektif mengenali pola dari beragam pencahayaan. Dengan begitu efek CLAHE dipengaruhi oleh karakteristik arsitektur model. CLAHE meningkatkan kontras lokal dan menjelaskan pola-pola penting dalam model konvensional. Dalam model pelatihan seperti EfficientNet-B1, teknik ini harus digunakan secara selektif untuk mencegah rusaknya struktur yang dipelajari. Temuan-temuan ini dapat berfungsi sebagai referensi penting untuk mengembangkan sistem klasifikasi gambar medis berbasis pembelajaran mendalam yang tepat dan kuat dalam berbagai kondisi pencahayaan [14].

Untuk memahami area citra yang menjadi fokus model terbaik dalam proses klasifikasi, dilakukan visualisasi menggunakan *Gradient-weighted Class Activation Mapping* (Grad-CAM) yang meningkatkan interpretabilitas dan visualisasi fokus model dalam citra medis pada model VGG16 dengan CLAHE[19][20]. Metode ini menampilkan area yang paling berkontribusi terhadap keputusan model, dengan warna merah menunjukkan tingkat aktivasi tinggi dan warna biru menunjukkan tingkat aktivasi rendah. Berdasarkan hasil visualisasi pada Gambar 8, pada citra fundus penderita katarak, area aktivasi tampak lebih luas dengan dominasi warna biru. Warna biru pada peta Grad-CAM menunjukkan tingkat aktivasi yang rendah, yang berarti model memiliki kontribusi fitur yang tersebar dan kurang terfokus pada area spesifik untuk membuat keputusan. Kondisi ini menunjukkan bahwa model mengalami kesulitan mengenali fitur-fitur spesifik akibat tingkat kekeruhan lensa mata yang tinggi, yang menyebabkan detail struktur retina menjadi buram. Sementara itu, pada citra mata normal, Grad-CAM memperlihatkan area aktivasi yang lebih terfokus dan berwarna merah di sekitar disk optik dan pola pembuluh darah. Hal ini menandakan bahwa model dapat dengan mudah mengenali pola struktur yang jelas dan utuh pada citra normal.



Gambar 8. Visualisasi Grad-CAM pada Model VGG16 CLAHE

Meskipun kombinasi VGG16 dengan CLAHE menunjukkan hasil yang superior, beberapa temuan penting masih belum terselesaikan. Kondisi citra katarak yang sangat parah (buram ekstrem atau noise berlebihan) dapat membatasi kemampuan komparatif CLAHE dan generalisasi model. Model yang digunakan bisa menjadi tidak efektif dalam mengatasi variasi kualitas gambar yang signifikan dalam kasus ekstrem tersebut. Lebih lanjut, penelitian ini belum membahas secara mendalam masalah interpretabilitas model untuk merepresentasikan proses diagnostik secara visual, sebuah tantangan signifikan dalam adopsi klinis pembelajaran mendalam. Hal ini menggarisbawahi perlunya penelitian tambahan yang bertujuan untuk memajukan metodologi *denoising* dan *deblurring* yang meningkatkan pengurangan kesalahan dengan kualitas superior [21][22]. Penerapan explainable AI juga dapat dijelaskan untuk meningkatkan transparansi dan memperkuat kepercayaan linis terhadap sistem deteksi katarak berbasis pembelajaran mendalam[23].

4. KESIMPULAN

Penelitian ini sukses mengevaluasi efektivitas dari tiga arsitektur deep learning seperti CNN sederhana, VGG16, dan EfficientNet-B1 dalam mengklasifikasikan katarak pada citra fundus retina. Kinerja setiap model dibandingkan pada dua versi dataset yakni citra asli dan citra yang telah diproses dengan CLAHE. Dampak preprocessing terhadap akurasi didapatkan pada penelitian ini dengan hasil eksperimen yang menunjukkan bahwa CLAHE meningkatkan performa klasifikasi pada model CNN, terlihat dari akurasi dan skor f1 yang meningkat jadi 0.97. Demikian juga dengan VGG16, CLAHE berhasil meningkatkan akurasi dan skor f1 menjadi 0,96 karena lebih jelasnya struktur jaringan dan kekeruhan lensa yang identik untuk diagnosis katarak, sehingga performa lebih tinggi pada kedua model tersebut. Sebaliknya, model EfficientNet-B1 menampilkan performa yang kuat tanpa CLAHE. Model pretrained ini sudah memiliki kapabilitas generalisasi tinggi yang dapat mengatasi beragam kontras citra tanpa bantuan CLAHE dengan akurasi dan skor F1 0.97, bahkan penambahan CLAHE tidak memberikan peningkatan dan menimbulkan distorsi kecil. Temuan ini secara keseluruhan menegaskan bahwa pemilihan preprocessing harus disesuaikan dengan arsitektur model. CLAHE sangat efektif untuk meningkatkan kinerja model konvensional seperti CNN dan VGG16. Di sisi lain, model pretrained modern seperti EfficientNet perlu dipertimbangan lagi untuk penerapan preprocessing CLAHE supaya hasilnya tidak mengganggu fitur-fitur yang sudah dipelajari model sebelumnya. Hasil dari penelitian ini dapat dijadikan acuan penting dalam mengembangkan sistem deteksi katarak berbasis deep learning yang lebih akurat terhadap beragam kualitas citra medis. Keterbatasan utama yang disoroti yakni bahwa teknik CLAHE tidaklah universal, sehingga memerlukan penyesuaian pada arsitektur model. Oleh karena itu, penelitian masa depan dapat dikembangkan dengan mengeksplorasi teknik praproses alternatif selain CLAHE dan melakukan validasi eksternal terhadap model unggul ini pada kumpulan data citra medis yang beragam untuk menguji generalisasi.[24].

REFERENCES

- [1] World Health Organization, "Blindness and vision impairment," World Health Organization. Accessed: Nov. 09, 2025. [Online]. Available: <https://www.who.int/news-room/fact-sheets/detail/blindness-and-visual-impairment>
- [2] Badan Penelitian dan Pengembangan Kesehatan, "Hasil Utama Riskesdas 2018," Jakarta, 2018. Accessed: Nov. 09, 2025. [Online]. Available: <https://www.litbang.kemkes.go.id/laporan-riiset-kesehatan-dasar-riskesdas-2018/>
- [3] R. RAHMADWATI, A. Z. IMRAN, M. ASWIN, and K. FERDIANA, "Identifikasi Penyakit Katarak berdasarkan Citra Fundus menggunakan Siamese Convolutional Neural Network," *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, vol. 12, no. 4, p. 838, Dec. 2024, doi: 10.26760/elkomika.v12i4.838.
- [4] C. Paramita, S. Rakasiwi, P. N. Andono, G. F. Shidik, Shier Nee Saw, and M. I. Rafsanjani, "Deep Learning-Based Eye Disorder Classification: A K-Fold Evaluation of EfficientNetB and VGG16 Models," *Scientific Journal of Informatics*, vol. 12, no. 3, pp. 441–452, Sep. 2025, doi: 10.15294/sji.v12i3.26257.
- [5] C. A. Putri and S. Rakasiwi, "Diagnosis Dini Penyakit Mata: Klasifikasi Citra Fundus Retina dengan Convolutional Neural Network VGG-16," *Edumatic: Jurnal Pendidikan Informatika*, vol. 9, no. 1, pp. 208–216, Apr. 2025, doi: 10.29408/edumatic.v9i1.29571.
- [6] A. Azmiardi *et al.*, "Evaluating the effectiveness of the Indonesian diabetes self-management questionnaire in managing type 2 diabetes in primary care," *Jurnal Kedokteran dan Kesehatan*, vol. 16, no. 1, pp. 28–34, 2025, doi: 10.30659/sainsmed.v16i1.39770.
- [7] T. Abraham, Todd A., D. A. Orringer, and R. Levenson, "Applications of artificial intelligence for image enhancement in pathology," S. Cohen, Ed., Elsevier, 2021, pp. 119–148.
- [8] Noor F., Dinur Syahputra D., Muhathir M., and Fadlisyah F., "Analysis of Combined Contrast Limited Adaptive Histogram Equalization (CLAHE) and Median Filter Methods for Enhancement of CCTV Screenshot Image Quality," *Jurnal Ilmiah Teknik Elektro Komputer dan Informatika*, vol. 8, no. 2, 2025, doi: 10.31289/jite.v8i2.14016.
- [9] M. J. Alwazzan, M. A. Ismael, and A. N. Ahmed, "A Hybrid Algorithm to Enhance Colour Retinal Fundus Images Using a Wiener Filter and CLAHE," *J Digit Imaging*, vol. 34, no. 3, pp. 750–759, Jun. 2021, doi: 10.1007/s10278-021-00447-0.
- [10] P. Hernández-Cámara, J. Vila-Tomás, P. Dauden-Oliver, N. Alabau-Bosque, V. Laparra, and J. Malo, "Why Divisive Normalization works in image segmentation?," *Neurocomputing*, vol. 649, p. 130569, Oct. 2025, doi: 10.1016/j.neucom.2025.130569.
- [11] H. Tarwani, S. Patel, and P. Goel, "Deep learning approach for weather classification using pre-trained convolutional neural networks," *Procedia Comput Sci*, vol. 252, pp. 136–145, 2025, doi: 10.1016/j.procs.2024.12.015.
- [12] J. Deepa and P. Madhavan, "An advanced skin lesion segmentation and classification framework using deep learning strategies," *Sci Rep*, vol. 15, no. 1, p. 33926, Sep. 2025, doi: 10.1038/s41598-025-08255-0.



- [13] F. A. Mohammed, K. K. Tune, B. G. Assefa, M. Jett, and S. Muhie, “Medical Image Classifications Using Convolutional Neural Networks: A Survey of Current Methods and Statistical Modeling of the Literature,” *Mach Learn Knowl Extr*, vol. 6, no. 1, pp. 699–736, Mar. 2024, doi: 10.3390/make6010033.
- [14] M. Opoku, B. A. Weyori, A. F. Adekoya, and K. Adu, “CLAHE-CapsNet: Efficient retina optical coherence tomography classification using capsule networks with contrast limited adaptive histogram equalization,” *PLoS One*, vol. 18, no. 11, p. e0288663, Nov. 2023, doi: 10.1371/journal.pone.0288663.
- [15] L. Schneider, A. Krasowski, V. Pitchika, L. Bombeck, F. Schwendicke, and M. Büttner, “Assessment of CNNs, transformers, and hybrid architectures in dental image segmentation,” *J Dent*, vol. 156, p. 105668, May 2025, doi: 10.1016/j.jdent.2025.105668.
- [16] K. Simonyan and A. Zisserman, “Very Deep Convolutional Networks for Large-Scale Image Recognition,” Apr. 2015.
- [17] A. Arora, S. Gupta, S. Singh, and J. Dubey, “Eye Disease Detection Using Transfer Learning on VGG16,” 2023, pp. 527–536. doi: 10.1007/978-981-19-1142-2_42.
- [18] S. Nigam, R. Jain, V. K. Singh, S. Marwaha, A. Arora, and S. Jain, “EfficientNet architecture and attention mechanism-based wheat disease identification model,” *Procedia Comput Sci*, vol. 235, pp. 383–393, 2024, doi: 10.1016/j.procs.2024.04.038.
- [19] Mohamed Musthafa M, Mahesh T. R, Vinoth Kumar V, and Suresh Guluwadi, “Enhancing brain tumor detection in MRI images through explainable AI using Grad-CAM with Resnet 50,” *BMC Med Imaging*, vol. 24, no. 1, p. 107, May 2024, doi: 10.1186/s12880-024-01292-7.
- [20] L. R. M. Lanzafame *et al.*, “Deep Learning Denoising Algorithm for Improved Assessment of Coronary Arteries in Transcatheter Aortic Valve Implantation CT Imaging,” *Acad Radiol*, Nov. 2025, doi: 10.1016/j.acra.2025.10.030.
- [21] A. Sharma, A. Dogra, B. Goyal, A. Saini, and V. Kukreja, “From Spatial Domain to Patch-Based Models: A Comprehensive Review and Comparison of Multimodal Medical Image Denoising Algorithms,” 2025, *Tech Science Press*. doi: 10.32604/cmc.2025.066481.
- [22] D. Li and S. Li, “An artificial intelligence deep learning platform achieves high diagnostic accuracy for Covid-19 pneumonia by reading chest X-ray images,” *iScience*, vol. 25, no. 4, Apr. 2022, doi: 10.1016/j.isci.2022.104031.
- [23] M. A. Widyananda, C. Paramita, C. Supriyanto, A. W. Wibowo, D. W. Utomo, and S. T. Widyaatmadja, “YOLOVX Method for Cataract Early Detection,” in *2025 International Conference on Smart Computing, IoT and Machine Learning, SIML 2025*, Institute of Electrical and Electronics Engineers Inc., 2025. doi: 10.1109/SIML65326.2025.11080840.
- [24] C. Paramita, C. Supriyanto, P. Šolić, C. Wada, and A. A. Dzaky, “Performance Evaluation of YOLOv8 Models for Multi-Class Skin Lesion Detection from Dermoscopic Images,” in *2025 International Conference on Smart Computing, IoT and Machine Learning, SIML 2025*, Institute of Electrical and Electronics Engineers Inc., 2025. doi: 10.1109/SIML65326.2025.11080819.