

# Impact of Contrast Limited Adaptive Histogram Equalization and Image Upscaling on Cataract Classification Using Deep Learning Models: Inception-ResNetV2, EfficientNetB0, and ResNet-50

Ismi Dwi Junianti<sup>1</sup>, Ulva Nuha Muvidah<sup>2</sup>, Christian Sri Kusuma Aditya<sup>\*3</sup>

<sup>1,2,3</sup>Informatics, Universitas Muhammadiyah Malang, Indonesia

Email: <sup>3</sup>christianskaditya@umm.ac.id

Received : Jan 30, 2026; Revised : Feb 8, 2026; Accepted : Feb 8, 2026; Published : Jun 15, 2026

## Abstract

Cataract is one of the leading causes of visual impairment worldwide, and its detection using retinal images remains a critical challenge in medical image analysis due to variations in image quality and subjectivity in clinical assessment. This study aims to evaluate the impact of image preprocessing techniques, namely Contrast Limited Adaptive Histogram Equalization (CLAHE) and image upscaling, on the performance and interpretability of deep learning-based cataract classification models. Three convolutional neural network architectures—Inception-ResNetV2, EfficientNetB0, and ResNet-50—were assessed using a balanced dataset of 2,000 retinal images under two experimental settings: raw images and enhanced images. The models were evaluated using accuracy, precision, recall, and F1-score, while Gradient-weighted Class Activation Mapping (Grad-CAM) was employed to analyze model interpretability. Experimental results show that EfficientNetB0 achieved the highest accuracy on raw images (96%), followed by ResNet-50 (94%) and Inception-ResNetV2 (92%). After applying CLAHE and upscaling, ResNet-50 exhibited improved performance, reaching 95% accuracy, whereas EfficientNetB0 and InceptionResNetV2 experienced a decrease in accuracy to 83%. Grad-CAM visualizations indicate that all models consistently focused on clinically relevant regions associated with cataract characteristics. These findings demonstrate that image enhancement techniques do not universally improve classification performance and that their effectiveness is highly dependent on the underlying CNN architecture. The study provides practical insights for selecting appropriate preprocessing-model combinations to develop accurate, interpretable, and robust deep learning-based cataract classification systems for medical decision-support applications.

**Keywords :** *Cataract Classification, CLAHE, Deep Learning, EfficientNetB0, Grad-CAM, Inception-ResNetV2, ResNet-50, Upscaling.*

This work is an open access article and licensed under a Creative Commons Attribution-Non Commercial 4.0 International License



## 1. PENDAHULUAN

Katarak merupakan salah satu penyebab utama gangguan penglihatan dan kebutaan yang berdampak signifikan terhadap kualitas hidup penderitanya serta menjadi masalah kesehatan global [1]. Penyakit ini ditandai dengan kekeruhan lensa mata yang menyebabkan penurunan ketajaman visual secara bertahap, bahkan dapat berujung pada kebutaan permanen apabila tidak ditangani secara tepat [2]. Pada kelompok tertentu, seperti penderita diabetes, risiko terjadinya katarak meningkat akibat mekanisme patofisiologis yang kompleks, termasuk akumulasi sorbitol, stres oksidatif, dan glikasi protein lensa, yang mempercepat degradasi struktur lensa mata [3].

Seiring meningkatnya prevalensi katarak dan penyakit mata lainnya, kebutuhan akan metode deteksi dini yang akurat, cepat, dan konsisten menjadi semakin penting. Metode diagnosis konvensional yang bergantung pada pemeriksaan klinis manual memiliki keterbatasan, seperti subjektivitas antar pemeriksa, ketergantungan pada pengalaman klinisi, serta keterbatasan sumber daya di fasilitas kesehatan tertentu. Oleh karena itu, pendekatan berbasis teknologi, khususnya pemrosesan citra medis, menjadi alternatif yang menjanjikan dalam mendukung sistem diagnosis modern [4], [5], [6].

Perkembangan Artificial Intelligence (AI), khususnya deep learning, telah membawa kemajuan signifikan dalam analisis citra medis. Model Convolutional Neural Networks (CNN) terbukti mampu mengekstraksi fitur visual kompleks secara otomatis dan memberikan performa tinggi dalam berbagai tugas klasifikasi citra medis, seperti deteksi kanker kulit [7], [8], katarak [9], [10], retinopati diabetik [11], [12], penyakit pernapasan berbasis citra radiografi dada [13], serta klasifikasi tumor otak berbasis MRI [14], [15], [16], [17].

Berbagai arsitektur CNN telah dikembangkan dan dievaluasi untuk meningkatkan akurasi dan efisiensi diagnosis. Model berbasis ResNet memanfaatkan koneksi residual untuk mengatasi permasalahan vanishing gradient pada jaringan dalam [6], sementara Inception dan Inception-ResNet menggabungkan ekstraksi fitur multi-skala dengan koneksi residual untuk meningkatkan kemampuan representasi fitur [18]. Selain itu, EfficientNet menggunakan mekanisme penskalaan terintegrasi yang mempertimbangkan struktur jaringan dan ukuran citra masukan secara bersamaan, dengan tujuan memperoleh akurasi tinggi melalui penggunaan sumber daya komputasi yang lebih efisien [8]. Pendekatan hibrid dan fusi fitur dari beberapa arsitektur juga menunjukkan peningkatan kinerja yang signifikan dalam klasifikasi citra medis [19], [8], [10]. Meskipun model CNN mampu mengekstraksi fitur visual kompleks secara otomatis, kualitas citra masukan tetap memegang peranan penting dalam menentukan performa akhir model, khususnya pada citra medis yang sering mengalami permasalahan kontras rendah, pencahayaan tidak merata, serta keberadaan noise. Kondisi ini umum ditemukan pada citra medis seperti MRI, fundus retina, dan radiografi dada, yang dapat menyulitkan model dalam membedakan batas jaringan normal dan patologis [20].

Dalam konteks peningkatan kualitas citra, tahap pra-pemrosesan memegang peranan penting dalam sistem klasifikasi berbasis deep learning [21]. Teknik seperti Contrast Limited Adaptive Histogram Equalization (CLAHE) telah banyak digunakan untuk meningkatkan kontras citra medis dengan kualitas rendah, terutama pada citra retina, sehingga membantu model CNN mengekstraksi fitur yang lebih diskriminatif dan meningkatkan akurasi klasifikasi [12]. Selain itu, Teknik ini diterapkan untuk memperjelas struktur Retina, terutama pada area yang memiliki intensitas rendah atau kontras tidak merata. CLAHE bekerja dengan membagi citra ke dalam sejumlah tiles kemudian melakukan pemerataan histogram secara adaptif pada setiap region tersebut, CLAHE juga menerapkan clip limit untuk mencegah peningkatan kontras berlebih yang dapat menimbulkan noise pada area homogen [22]. Penggunaan augmentasi data secara sistematis terbukti efektif dalam meningkatkan generalisasi model dan mengurangi risiko overfitting pada dataset medis yang terbatas [23], [15].

Meskipun model deep learning menunjukkan performa yang sangat tinggi, tantangan utama yang masih dihadapi adalah sifatnya yang sering dianggap sebagai *black box*. Kurangnya transparansi dalam proses pengambilan keputusan model menimbulkan kekhawatiran dalam konteks klinis, di mana interpretabilitas dan kepercayaan terhadap sistem AI menjadi aspek krusial. Untuk mengatasi permasalahan ini, pendekatan Explainable Artificial Intelligence (XAI) dikembangkan guna memberikan penjelasan visual dan konseptual terhadap prediksi model sehingga hasil klasifikasi dapat dipahami dengan lebih baik oleh pengguna dan praktisi medis [24], [25], [26], [18].

Salah satu teknik XAI yang paling banyak digunakan dalam analisis citra medis adalah Gradient-weighted Class Activation Mapping (Grad-CAM). Metode ini menghasilkan peta panas yang menyoroti area citra yang paling berkontribusi terhadap keputusan model, sehingga membantu praktisi medis memahami fokus perhatian model CNN [15]. Namun, penelitian terbaru menunjukkan bahwa Grad-CAM memiliki sejumlah keterbatasan, seperti asumsi korespondensi spasial yang tidak selalu valid pada model dengan bidang reseptif besar, potensi munculnya peta penjelasan kosong, serta sensitivitas terhadap arsitektur jaringan yang digunakan [23]. Oleh karena itu, pemilihan lapisan yang tepat dan pemahaman terhadap karakteristik model menjadi aspek penting dalam penerapan Grad-CAM secara klinis. Selain Grad-CAM, berbagai metode XAI lain seperti LIME, SHAP, CAM, dan pendekatan

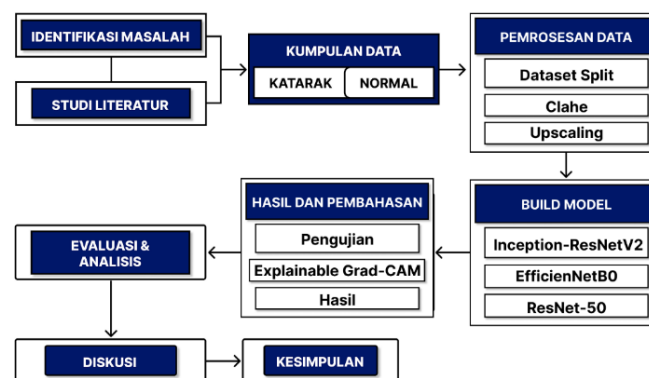
berbasis gangguan juga telah dieksplorasi untuk meningkatkan transparansi model deep learning dalam pencitraan medis [25], [18]. Meskipun demikian, tantangan seperti biaya komputasi yang tinggi, kurangnya standar evaluasi interpretabilitas, serta keterbatasan generalisasi pada data multimodal masih menjadi isu yang perlu ditangani secara serius [25], [18], [6].

Dalam ranah klasifikasi citra medis multimodal, model seperti ResoMergeNet menunjukkan potensi besar dengan kemampuannya menangani berbagai jenis citra medis, termasuk citra mata untuk katarak dan citra histopatologis untuk kanker paru-paru serta kanker payudara. Model ini mengintegrasikan pembelajaran residual, fusi fitur lokal dan global, serta teknik regularisasi untuk mencapai akurasi tinggi dan stabilitas model yang baik [10]. Pendekatan semacam ini relevan untuk dikembangkan lebih lanjut, khususnya dalam konteks diagnosis katarak berbasis citra, yang memerlukan sistem yang tidak hanya akurat tetapi juga andal dan dapat dijelaskan.

Meskipun berbagai penelitian sebelumnya telah menerapkan teknik peningkatan citra maupun arsitektur deep learning untuk analisis citra medis, sebagian besar studi tersebut masih berfokus pada satu model atau satu metode pra-pemrosesan secara terpisah [4], [6]. Beberapa penelitian melaporkan peningkatan performa melalui teknik peningkatan citra seperti Contrast Limited Adaptive Histogram Equalization (CLAHE), namun evaluasinya umumnya terbatas pada satu jenis arsitektur jaringan saraf [12], [22]. Selain itu, penerapan Explainable Artificial Intelligence (XAI) untuk menganalisis interpretabilitas model deep learning dalam konteks klasifikasi katarak masih relatif terbatas dibandingkan dengan bidang citra medis lainnya [18], [24]. Oleh karena itu, penelitian ini mengisi celah tersebut dengan mengevaluasi secara komprehensif pengaruh kombinasi CLAHE dan upscaling terhadap performa tiga arsitektur CNN berbasis transfer learning, yaitu Inception-ResNetV2, EfficientNetB0, dan ResNet-50, serta menganalisis interpretabilitas model menggunakan Grad-CAM.

## 2. METODE PENELITIAN

Metodologi penelitian disusun untuk menggambarkan tahapan proses klasifikasi katarak berbasis citra retina secara sistematis.



Gambar 1. Alur Metodologi Penelitian


Alur metodologi penelitian ini ditunjukkan pada Gambar 1, dimana penelitian ini mengkaji klasifikasi katarak berbasis citra retina dengan membandingkan tiga arsitektur deep learning, yaitu Inception-ResNetV2, EfficientNetB0, dan ResNet-50, dengan dataset yang diuji melalui dua skema, yaitu menggunakan citra asli dan citra hasil preprocessing berupa penerapan Contrast Limited Adaptive Histogram Equalization (CLAHE) dan upscaling. Seluruh model dilatih menggunakan pendekatan transfer learning dan dievaluasi berdasarkan metrik akurasi, presisi, recall, dan F1-score, kemudian dilanjutkan dengan analisis interpretabilitas menggunakan Grad-CAM untuk memastikan bahwa fokus prediksi model berada pada area klinis yang relevan, sehingga hasil evaluasi tersebut dapat digunakan untuk menentukan arsitektur dan skema terbaik dalam klasifikasi katarak.

## 2.1. Data

Dataset yang digunakan dalam penelitian ini berasal dari platform Kaggle, yaitu **Ocular Disease Intelligent Recognition (ODIR-5K)**. Dataset tersebut terdiri dari total 2.000 citra mata, yang terbagi secara seimbang ke dalam dua kelas, yaitu 1.000 citra mata normal dan 1.000 citra mata katarak. Distribusi kelas yang seimbang ini bertujuan untuk menghindari bias pada proses pelatihan model serta memastikan bahwa model memiliki kemampuan yang setara dalam mengenali kedua kategori citra.


Seluruh citra pada dataset disimpan dalam format RGB (Red, Green, Blue), sehingga informasi warna tetap terjaga dan dapat dimanfaatkan secara optimal oleh model deep learning dalam mengekstraksi fitur visual yang relevan. Selain itu, setiap citra telah melalui proses standarisasi ukuran menjadi  $224 \times 224$  piksel, yang disesuaikan dengan kebutuhan input arsitektur model deep learning yang digunakan dalam penelitian ini. Proses penyeragaman ukuran citra dilakukan untuk memastikan konsistensi dimensi input, mengurangi kompleksitas komputasi, serta meningkatkan efisiensi dan stabilitas selama proses pelatihan dan pengujian model.

Dengan struktur dataset yang terorganisasi, seimbang, dan telah melalui tahap pra-pemrosesan dasar tersebut, diharapkan model yang dikembangkan mampu mempelajari karakteristik visual citra mata normal dan katarak secara lebih efektif, sehingga dapat menghasilkan performa klasifikasi yang optimal dan andal.



Gambar 2. Citra Kelas Normal

Pada Gambar 2 mata normal didefinisikan sebagai keadaan dimana mata dalam kondisi baik, lensa mata yang jernih dan dilalui cahaya menuju retina [27]. Secara visual, tidak ditemukan adanya lapisan putih atau area buram yang menutupi bagian dalam mata. Kejernihan ini membuat tekstur retina terlihat sangat detail, sehingga informasi yang diterima oleh model deep learning menjadi lebih berkualitas dan bebas dari gangguan visual (noise).



Gambar 3. Citra kelas Katarak

Gambar 3 menunjukkan katarak pada citra ditandai oleh kehilangan transparansi dan kekeruhan pada lensa mata. Kondisi ini menyebabkan lensa mata menjadi buram dan menyebarkan cahaya saat melewatinya, yang mengurangi ketajaman penglihatan di retina dan menyebabkan penglihatan menjadi kabur [28]. Secara visual, hal ini terlihat dari adanya bercak putih atau lapisan keruh yang menutupi detail retina, sehingga warna orange kemerahan yang seharusnya bersih menjadi redup dan tidak jelas. Kekeruhan inilah yang menjadi ciri utama bagi model deep learning untuk mengenali bahwa citra tersebut termasuk dalam kategori katarak.


## 2.2. Preprocessing, Feature Extraction, dan Explainability

Penggunaan *preprocessing*, *feature extraction*, dan *explainability* memberikan kontribusi penting dalam membangun sistem klasifikasi citra yang akurat dan dapat dipertanggungjawabkan [29]. Preprocessing seperti CLAHE dan segmentasi bertujuan meningkatkan kualitas citra sehingga fitur klinis menjadi lebih jelas dan mudah dipelajari model [12]. Tahap ekstraksi fitur, baik yang dilakukan otomatis oleh arsitektur deep learning maupun secara statistik pada model klasik, mengubah citra mentah menjadi representasi yang lebih informatif sehingga meningkatkan kemampuan model dalam membedakan kelas. Sementara itu, pendekatan *explainability* seperti Grad-CAM memastikan bahwa keputusan model dapat dijelaskan secara visual dengan menunjukkan area yang menjadi fokus prediksi, sehingga meningkatkan kepercayaan dan validitas klinis dalam penerapan sistem klasifikasi citra medis [23].

### 2.2.1 Contrast Limited Adaptive Histogram Equalization (CLAHE)

Contrast Limited Adaptive Histogram Equalization (CLAHE) merupakan salah satu teknik pra-pemrosesan citra yang digunakan untuk meningkatkan kualitas kontras dengan pendekatan adaptif pada area lokal citra. Berbeda dengan histogram equalization konvensional yang bekerja secara global, CLAHE membagi citra menjadi beberapa region kecil (tiles) dan melakukan peningkatan kontras secara terpisah pada setiap region. Pendekatan ini memungkinkan detail lokal pada citra retina, khususnya pada area lensa mata, menjadi lebih jelas dan informatif [30].

Dalam konteks penelitian ini, penerapan CLAHE bertujuan untuk memperjelas struktur lensa serta tingkat opasitas yang menjadi karakteristik utama pada citra mata katarak. Selain itu, mekanisme contrast limiting pada CLAHE berfungsi untuk membatasi amplifikasi kontras yang berlebihan, sehingga dapat mengurangi kemunculan noise dan artefak yang tidak diinginkan. Dengan demikian, citra hasil pra-pemrosesan memiliki kualitas visual yang lebih stabil dan representatif untuk tahap ekstraksi fitur oleh model deep learning [31].




Gambar 4. Visualisasi dataset setelah CLAHE

Gambar 4 merupakan penerapan Contrast Limited Adaptive Histogram Equalization (CLAHE) pada citra fundus menghasilkan peningkatan kontras lokal yang signifikan. Struktur vaskular tampak lebih tegas, distribusi intensitas lebih merata, dan detail jaringan retina termasuk area makula dan papil saraf optik menjadi lebih mudah teridentifikasi. Dibandingkan citra asli yang cenderung memiliki pencahayaan lembut dan kontras rendah, citra hasil CLAHE menunjukkan peningkatan visibilitas tepi dan tekstur tanpa menyebabkan amplifikasi berlebih pada noise. Secara keseluruhan, CLAHE meningkatkan kualitas diagnostik citra retina.

### 2.2.2 Upscaling

Upscaling digunakan untuk meningkatkan ukuran dan resolusi citra, sehingga detail tekstur pada retina menjadi lebih jelas dan lebih mudah ditangkap oleh model deep learning. Teknik ini membantu memperbaiki representasi fitur pada citra beresolusi rendah dan meningkatkan konsistensi pola visual sebelum memasuki proses ekstraksi fitur [32].



Gambar 5. Dataset Upscaling

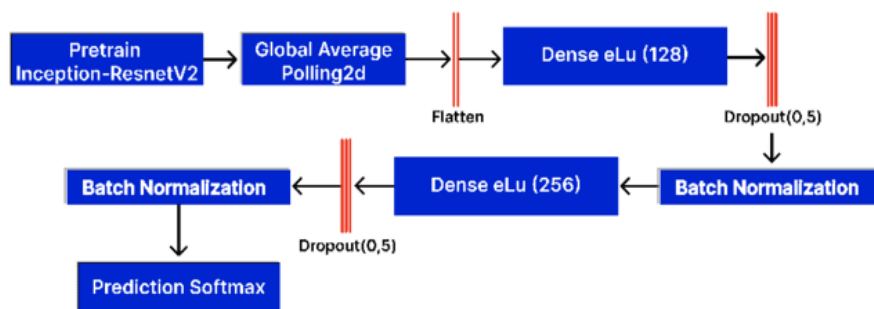
Pada Gambar 5 proses upscaling meningkatkan ketajaman dan kejelasan struktur pada citra fundus. Pada data normal, detail vaskular, kontur diskus optik, dan tekstur makula tampak lebih terdefinisi dan halus. Pada data katarak, meskipun kekeruhan lensa tetap membatasi visibilitas struktur retina, upscaling memperjelas pola kekeruhan, konsistensi tekstur, serta batas area yang teropasifikasi. Secara keseluruhan, upscaling berhasil meningkatkan kualitas visual dan keterbacaan citra tanpa menghasilkan artefak yang mengganggu.

### 2.3 Deep Learning Model

Penelitian ini menggunakan tiga model klasifikasi: Inception-ResNetV2, EfficientNetB0, dan ResNet-50. Ketiga model deep learning, Inception-ResNetV2 dan EfficientNetB0, dilatih melalui pendekatan transfer learning dengan bobot awal berbasis ImageNet. Lapisan akhir, atau lapisan yang benar-benar terhubung, diubah untuk memenuhi persyaratan klasifikasi dua kelas. Ini juga menambahkan dropout sebagai mekanisme regularisasi. Selama pelatihan, model mengoptimalkan fungsi cross-entropy kategoris untuk mengurangi kesalahan prediksi. Meskipun demikian, model ResNet-50 yang merupakan arsitektur Convolutional Neural Network (CNN) dengan mekanisme residual learning digunakan sebagai model pembandingan (baseline) dalam evaluasi kinerja. Proses inferensi pada ResNet-50 menghasilkan label prediksi akhir berdasarkan probabilitas kelas tertinggi yang diperoleh dari lapisan softmax.

#### 2.3.1 Inception-ResNetV2

Model Inception-ResNetV2 digunakan dalam penelitian ini sebagai arsitektur deep learning untuk ekstraksi fitur citra retina.




Gambar 6. Arsitektur Inception-ResNetV2

Arsitektur Inception-ResNetV2 yang digunakan dalam penelitian ini dapat dilihat pada Gambar 6. Inception-ResNetV2 pre-train digunakan sebagai ekstraktor fitur utama, kemudian fitur diringkas dengan GlobalAveragePooling2D dan diubah menjadi vektor melalui Flatten. Representasi ini

diperkaya oleh Dense eLU (128) dan Dense eLU (256), masing-masing distabilkan dengan Batch Normalization dan diregularisasi dengan Dropout (0.5) untuk mencegah overfitting[18] . Pada tahap akhir, Prediction Softmax menghasilkan probabilitas kelas. Struktur ini memastikan ekstraksi fitur yang kuat, regularisasi optimal, dan performa klasifikasi yang stabil.

### 2.3.2 EfficientNetB0

Model EfficientNetB0 digunakan dalam penelitian ini sebagai arsitektur deep learning untuk ekstraksi fitur citra retina.

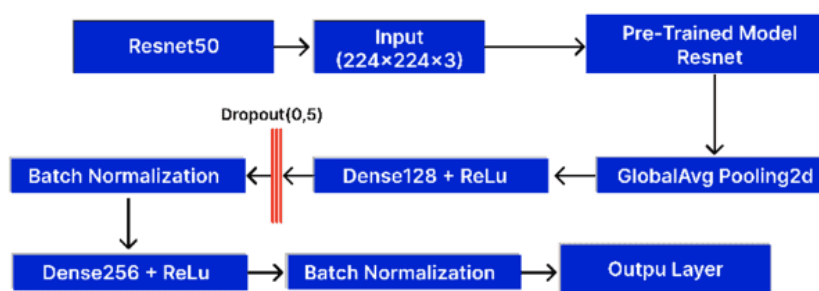


Gambar 7. Arsitektur EfficientnetB0

Arsitektur model EfficientnetB0 dapat dilihat pada Gambar 7, menerima citra melalui Input Layer, kemudian mengekstraksi fitur menggunakan EfficientNetB0. Hasil ekstraksi diringkas oleh GlobalAveragePooling2D, lalu diperkaya melalui Dense 128, distabilkan dengan Batch Normalization, dan dilindungi dari overfitting menggunakan Dropout (0.5). Akhirnya, Dense 1 menghasilkan output klasifikasi. Struktur ini memastikan ekstraksi fitur yang efisien dan generalisasi yang optimal.

### 2.3.3 ResNet-50

ResNet-50 diterapkan dalam penelitian ini sebagai salah satu arsitektur deep learning untuk ekstraksi fitur citra retina yang kompleks dan mendalam.



Gambar 8. Arsitektur ResNet-50

ResNet-50 dapat dilihat pada Gambar 8, digunakan sebagai ekstraktor fitur dengan input citra berukuran  $224 \times 224 \times 3$ , di mana lapisan awal mengekstraksi fitur dasar melalui konvolusi, batch normalization, aktivasi ReLU, dan pooling, sedangkan residual blocks dengan skip connection menjaga stabilitas aliran gradien untuk pembelajaran fitur tingkat tinggi. Fitur keluaran kemudian diringkas menggunakan Global Average Pooling 2D dan diproses melalui dua lapisan fully connected berukuran 128 dan 256 neuron dengan aktivasi ReLU, yang diperkuat oleh Dropout dan Batch Normalization untuk mengurangi overfitting, sebelum dilakukan klasifikasi biner menggunakan satu neuron beraktivasi sigmoid [6].

### 2.3.4 Grad-CAM

Gradient-weighted Class Activation Mapping (Grad-CAM) digunakan sebagai pendekatan explainable artificial intelligence untuk meningkatkan interpretabilitas model klasifikasi katarak. Metode ini menghasilkan peta panas (heatmap) berdasarkan gradien dari kelas prediksi terhadap feature map pada lapisan konvolusi terakhir model CNN. Heatmap yang dihasilkan kemudian dioverlay pada citra retina asli untuk menunjukkan area yang paling berkontribusi terhadap keputusan klasifikasi model. Dengan pendekatan ini, dapat dianalisis apakah model memfokuskan perhatian pada area yang relevan secara klinis, seperti kekeruhan lensa atau perubahan tekstur retina pada citra katarak. Penerapan Grad-CAM membantu memastikan bahwa prediksi model tidak hanya akurat secara numerik, tetapi juga dapat dipertanggungjawabkan secara klinis, sehingga meningkatkan kepercayaan terhadap sistem klasifikasi citra medis yang diusulkan.

### 2.4 Evaluasi Model

Evaluasi kinerja model dilakukan dengan menggunakan metrik akurasi, presisi, recall, dan F1-score yang diperoleh dari confusion matrix pada data pengujian. Perhitungan masing-masing metrik evaluasi tersebut mengacu pada persamaan (1) hingga (4). Selain pengukuran performa, aspek interpretabilitas model juga dianalisis dengan menerapkan metode Gradient-weighted Class Activation Mapping (Grad-CAM) pada arsitektur Inception ResNet-V2, EfficientNetB0, ResNet-50. Grad-CAM menghasilkan visualisasi berupa heatmap yang menunjukkan area citra yang berkontribusi dominan terhadap keputusan klasifikasi. Visualisasi ini digunakan untuk mengevaluasi apakah model memberikan perhatian pada region mata yang relevan secara klinis dalam proses deteksi katarak, sekaligus sebagai dasar analisis kinerja model secara menyeluruh [33].

$$Presisi = \frac{TP}{TP+FP} \tag{1}$$

$$Recall = \frac{TP}{TP+FN} \tag{2}$$

$$F1Score = \frac{2x(RecallxPresisi)}{(Recall+Presisi)} \tag{3}$$

$$Akurasi = \frac{TP+TN}{TP+TN+FP+FN} \tag{4}$$

		Actual Values	
		1 (Positive)	0 (Negative)
Predicted Values	1 (Positive)	<p><b>TP</b> (True Positive)</p>	<p><b>FP</b> (False Positive) <i>Type I Error</i></p>
	0 (Negative)	<p><b>FN</b> (False Negative) <i>Type II Error</i></p>	<p><b>TN</b> (True Negative)</p>

Gambar 9. Tabel Confusion Matrix

Gambar 9 menyajikan confusion matrix yang digunakan untuk mengevaluasi kinerja model klasifikasi terhadap data uji. Matriks ini merepresentasikan hubungan antara label aktual dan hasil

prediksi model. Nilai true positive (TP) dan true negative (TN) menunjukkan kemampuan model dalam mengklasifikasikan data secara benar, sedangkan false positive (FP) dan false negative (FN) merefleksikan kesalahan prediksi yang terjadi selama proses klasifikasi.

### 3. PENGUJIAN DAN EVALUASI

Bagian ini menyajikan proses pengujian dan hasil evaluasi kinerja model klasifikasi katarak melalui dua skenario utama. Pada skenario pertama, citra asli tanpa preprocessing CLAHE digunakan langsung sebagai input ke tiga model deep learning, yaitu Inception-ResNetV2, EfficientNetB0, dan ResNet-50. Skema ini bertujuan untuk melihat kemampuan dasar masing-masing arsitektur dalam mengekstraksi fitur dari citra fundus tanpa intervensi peningkatan kualitas gambar.

Pada skenario kedua, citra terlebih dahulu ditingkatkan kualitasnya menggunakan metode Contrast Limited Adaptive Histogram Equalization (CLAHE) serta upscaling untuk menghasilkan detail visual yang lebih tajam dan distribusi intensitas yang lebih merata. Hasil preprocessing ini kemudian dijadikan input untuk ketiga model yang sama untuk mengevaluasi sejauh mana peningkatan kualitas citra dapat memengaruhi performa klasifikasi. Perbandingan kedua skenario ini memungkinkan analisis menyeluruh mengenai dampak preprocessing terhadap akurasi model deep learning serta konsistensi prediksinya pada tugas klasifikasi katarak.

#### 3.1. Skema Pengujian

Penelitian ini diuji melalui dua skenario. Pada skenario pertama, citra asli digunakan sebagai input untuk ketiga model deep learning Inception-ResNetV2, EfficientNetB0, dan ResNet-50. Ketiga model dilatih menggunakan transfer learning dengan bobot awal ImageNet dan disesuaikan pada bagian fully connected layer menggunakan fungsi loss categorical cross-entropy.

Pada skenario kedua, citra ditingkatkan kualitasnya melalui CLAHE untuk memperbaiki kontras lokal, kemudian dilakukan upscaling untuk meningkatkan resolusi detail citra. Hasil preprocessing ini digunakan sebagai input untuk ketiga model klasifikasi untuk mengevaluasi sejauh mana peningkatan kualitas citra memengaruhi performa masing-masing arsitektur.

##### 3.1.1. Hasil Pengujian Tanpa CLAHE dan Upscaling

Tabel 1. Hasil Pengujian Skema 1

No	Model	Akurasi
1	Inception-ResNetV2	92%
2	EfficientNetB0	96%
3	ResNet-50	94%

Tabel 1 hasil skema pengujian tanpa CLAHE dan upscaling, model EfficientNetB0 menunjukkan performa terbaik dengan akurasi pengujian sebesar 96% serta kestabilan metrik antar kelas. Model ini menghasilkan f1-score 0.96 untuk kedua kelas, dengan jumlah kesalahan prediksi yang sangat rendah. ResNet-50 memiliki akurasi 94% dan menunjukkan generalisasi yang baik meskipun akurasi pelatihannya lebih rendah, menandakan model tidak mengalami overfitting. Sebaliknya, Inception-ResNetV2 mencapai 92% akurasi pengujian namun menunjukkan indikasi overfitting yang cukup kuat (train 99% vs val 91%). Model ini juga memiliki recall kelas katarak yang lebih rendah dibanding dua model lainnya. Secara keseluruhan, EfficientNetB0 paling konsisten dalam mendeteksi katarak pada data asli, sementara ResNet-50 memberikan stabilitas yang baik dan Inception-ResNetV2 memerlukan regularisasi tambahan.

**3.1.2. Hasil Pengujian dengan CLAHE dan Upscaling**

Tabel 2. Hasil Pengujian Skema 2

No	Model	Akurasi
1	Inception-ResNetV2	83%
2	EfficientNetB0	83%
3	ResNet-50	95%


Hasil skema pengujian dengan CLAHE dan Upscaling pada Tabel 2, menunjukkan bahwa implementasi CLAHE dan Upscaling memberikan dampak yang berbeda pada setiap arsitektur CNN. Pada EfficientNetB0 dan Inception-ResNetV2, performa model menurun drastis dari 96% dan 92% menjadi 83%. Penurunan ini terjadi karena kedua model bersifat sensitif terhadap perubahan kontras dan tekstur, sehingga distribusi fitur yang berubah setelah preprocessing tidak sesuai dengan pola fitur yang dibutuhkan oleh arsitektur tersebut. Sebaliknya, ResNet-50 menunjukkan peningkatan performa dari 94% menjadi 95% setelah preprocessing. Hal ini menunjukkan bahwa arsitektur residual lebih mampu memanfaatkan peningkatan detail dan kontras yang diberikan CLAHE serta Upscaling. Dengan demikian, efektivitas preprocessing sangat bergantung pada karakteristik backbone CNN yang digunakan. Dengan demikian, ResNet-50 dapat disimpulkan sebagai model paling optimal dan reliabel dalam proses klasifikasi citra pada pengujian ini.

**3.2. Visualisasi Hasil dan Evaluasi Model**

Hasil penelitian menunjukkan bahwa performa model meningkat setelah penerapan pra-pemrosesan. Pada skema 1 (dataset asli), akurasi model masih terbatas oleh variasi pencahayaan, kontras rendah, dan detail citra yang kurang jelas. Pada skema 2, penggunaan CLAHE dan upscaling memberikan perbaikan konsisten. CLAHE memperjelas kontras lokal sehingga fitur lebih mudah dikenali, sementara upscaling meningkatkan detail pada citra resolusi rendah. Kombinasi keduanya menghasilkan akurasi validasi yang lebih tinggi dan loss yang lebih rendah dibanding skema 1. Visualisasi Grad-CAM juga menunjukkan fokus model yang lebih tepat pada area fitur penting, menandakan peningkatan kualitas ekstraksi dan interpretabilitas. Secara keseluruhan, preprocessing pada skema 2 terbukti efektif meningkatkan kinerja model.

**3.2.1. Analisis Hasil Pengujian Tanpa CLAHE dan Upscaling**

Untuk memahami perilaku pembelajaran model pada skema pengujian tanpa CLAHE dan upscaling, dilakukan analisis terhadap kurva akurasi dan loss selama proses pelatihan dan validasi.




Gambar 10. Acc & Loss Model ResNet-50

Pada Skema Pengujian tanpa CLAHE dan upscaling, Gambar 10 menunjukkan bahwa akurasi pada data pelatihan dan validasi menunjukkan tren peningkatan yang stabil dengan selisih yang relatif kecil selama proses pelatihan. Kondisi ini mengindikasikan bahwa model ResNet-50 mampu mempelajari pola dan karakteristik data secara konsisten pada skema pengujian ini. Selain itu, nilai loss


pada data pelatihan dan validasi mengalami penurunan secara bertahap, yang menandakan bahwa proses optimasi model berjalan dengan baik.

Nilai loss pada data validasi tercatat secara konsisten lebih rendah dibandingkan dengan loss pada data pelatihan, yang menunjukkan kemampuan generalisasi model yang cukup baik terhadap data validasi pada skema pengujian ini. Pola pembelajaran tersebut mengindikasikan bahwa ResNet-50 mampu mengekstraksi fitur-fitur penting yang relevan tanpa menunjukkan indikasi overfitting, sehingga menghasilkan performa yang stabil dalam konfigurasi pengujian pertama.



Gambar 11. Confusion Matrix Model ResNet-50

Confusion matrix pada Gambar 11 menunjukkan bahwa ResNet-50 memiliki performa klasifikasi yang sangat stabil, dengan keberhasilan tinggi pada kedua kelas. Model mampu mengenali cataract dengan benar sebanyak 267 kasus dan hanya salah 10 kali, sementara kelas normal juga diklasifikasi akurat dengan 203 prediksi benar dan 20 kesalahan. Pola ini menandakan keseimbangan recall antar kelas, minim bias, serta kemampuan generalisasi yang baik pada distribusi data uji.

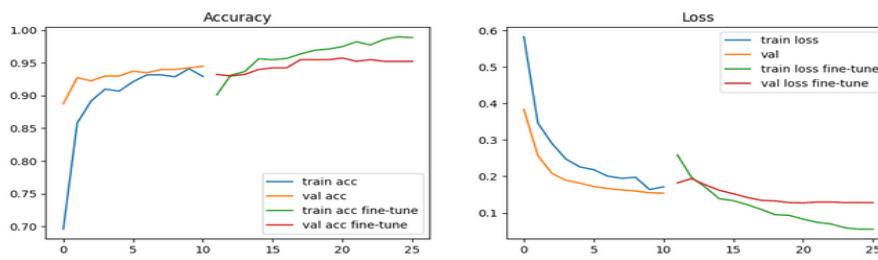


Gambar 12. Visualisasi Grad-CAM Model ResNet-50

Grad-CAM Gambar 12, menunjukkan bahwa model fokus pada area yang benar untuk membedakan katarak dan normal. Pada citra katarak, hotspot terkonsentrasi pada bagian lensa yang tampak berkabut, sedangkan pada citra normal fokus menyebar pada pola pembuluh darah dan disk optik. Hal ini menandakan bahwa model menggunakan fitur anatomis yang relevan, sehingga prediksi lebih dapat dipercaya.


### 3.2.2. Analisis Hasil Pengujian dengan CLAHE dan Upscaling

Untuk mengevaluasi pola pembelajaran model pada skema dengan CLAHE dan upscaling, dilakukan pengamatan terhadap kurva akurasi dan loss selama tahap pelatihan dan validasi.




Gambar 13. Acc & Loss Model ResNet-50

Grafik pada Gambar 13, menunjukkan peningkatan kinerja yang sangat stabil setelah fine-tuning. Akurasi training dan validasi meningkat konsisten hingga mendekati 97–98%, dengan gap yang kecil, menandakan model tidak overfitting. Grafik loss juga menurun halus, dan setelah fine-tuning, loss menjadi sangat rendah baik pada train maupun validation, yang menunjukkan bahwa preprocessing dan penyesuaian bobot berhasil membuat model menangkap pola fitur dengan lebih presisi. Secara keseluruhan, ResNet-50 pada Uji 2 tampil paling optimal, menunjukkan generalisasi kuat dan stabilitas tinggi sepanjang pelatihan.



Gambar 14. Confusion Matrix Model ResNet-50

Confusion matrix Gambar 14 menunjukkan bahwa hasil fine-tuning ResNet-50 menghasilkan performa yang sangat seimbang dan akurat. Model berhasil mengklasifikasikan cataract dengan tepat pada 188 sampel dan hanya salah pada 12 kasus, sementara kelas normal dikenali dengan benar pada 193 sampel dengan hanya 7 kesalahan. Kesalahan yang rendah dan distribusi prediksi yang seimbang antar kelas menandakan bahwa model memiliki generalisasi kuat, tidak bias terhadap salah satu kelas, serta mampu memanfaatkan hasil preprocessing dan fine-tuning secara efektif.



Gambar 15. Visualisasi Grad-CAM

Hasil Grad-CAM pada Gambar 15 memperlihatkan visualisasi area perhatian model terhadap citra fundus yang paling berkontribusi dalam proses pengambilan keputusan klasifikasi. Visualisasi ini

menunjukkan bahwa model tidak melakukan prediksi secara acak, melainkan memfokuskan perhatian pada region tertentu yang memiliki informasi penting. Intensitas aktivasi yang ditunjukkan melalui gradasi warna merah hingga kuning merepresentasikan area dengan tingkat kontribusi tertinggi terhadap output model.

Pada citra katarak, aktivasi dominan teramati pada area yang mengalami kekeruhan serta perubahan tekstur di sekitar bagian tengah retina, yang merupakan karakteristik visual utama dari kondisi katarak. Sementara itu, pada citra mata normal, respons model cenderung tersebar pada struktur fisiologis yang jelas, seperti pola pembuluh darah dan jaringan retina yang masih terdefinisi dengan baik. Perbedaan pola aktivasi ini mengindikasikan bahwa model mampu membedakan karakteristik visual antara kedua kelas secara konsisten. Dengan demikian, hasil visualisasi Grad-CAM mendukung bahwa model berhasil mengekstraksi fitur-fitur diskriminatif yang relevan, sehingga meningkatkan keandalan interpretabilitas serta kepercayaan terhadap hasil klasifikasi yang dihasilkan.

#### 4. DISKUSI

Hasil penelitian menunjukkan bahwa efektivitas preprocessing citra sangat dipengaruhi oleh karakteristik arsitektur CNN yang digunakan. Penerapan CLAHE dan upscaling tidak memberikan peningkatan performa yang konsisten pada seluruh model. EfficientNetB0 dan Inception-ResNetV2 mengalami penurunan akurasi yang signifikan, masing-masing dari 96% dan 92% menjadi 83%. Penurunan ini mengindikasikan bahwa kedua arsitektur tersebut sensitif terhadap perubahan distribusi kontras dan tekstur citra, terutama karena EfficientNet dirancang untuk bekerja optimal pada distribusi data yang mendekati dataset pra-latihnya [8]. Selain itu, perubahan tekstur akibat CLAHE dapat mengganggu keseimbangan fitur multi-skala pada Inception-ResNetV2, sebagaimana juga dilaporkan pada penelitian citra medis sebelumnya [10], [18], [19].

Sebaliknya, ResNet-50 menunjukkan peningkatan performa dari 94% menjadi 95% setelah penerapan preprocessing. Hal ini menegaskan keunggulan arsitektur residual dalam memanfaatkan peningkatan kontras dan detail citra tanpa kehilangan informasi penting dari lapisan awal [6]. Koneksi residual memungkinkan aliran gradien yang lebih stabil sehingga ResNet lebih adaptif terhadap variasi kualitas citra medis, termasuk citra dengan kontras rendah dan noise [9], [11].

Secara keseluruhan, temuan ini menegaskan bahwa tidak terdapat satu pendekatan preprocessing yang universal untuk semua arsitektur CNN. Pemilihan metode peningkatan kualitas citra harus mempertimbangkan kesesuaian dengan mekanisme ekstraksi fitur pada model. Dalam konteks klasifikasi katarak berbasis citra retina, kombinasi ResNet-50 dengan CLAHE dan upscaling terbukti paling optimal, sementara EfficientNetB0 lebih stabil tanpa preprocessing CLAHE dan Inception-ResNetV2 memerlukan strategi preprocessing yang lebih spesifik [8], [10].

Selain kontribusi teknis, temuan penelitian ini memiliki implikasi penting terhadap pengembangan sistem deteksi katarak berbasis kecerdasan buatan dalam praktik klinis. Hasil penelitian menunjukkan bahwa peningkatan performa model tidak hanya bergantung pada kompleksitas arsitektur, tetapi juga pada kesesuaian antara karakteristik data, strategi preprocessing, dan mekanisme ekstraksi fitur. Temuan ini sejalan dengan studi terkini pada citra medis yang menekankan pentingnya desain pipeline yang adaptif terhadap kondisi pencitraan nyata, khususnya pada fasilitas kesehatan dengan keterbatasan kualitas perangkat akuisisi citra [9], [10], [31].

Dari perspektif ilmu informatika, penelitian ini memberikan kontribusi pada pemahaman hubungan antara preprocessing citra dan arsitektur deep learning dalam sistem klasifikasi citra medis. Pendekatan yang diusulkan berkontribusi dalam mendorong pengembangan sistem skrining katarak yang lebih andal, terinterpretasi, dan aplikatif, serta memperkuat peran kecerdasan buatan dalam pengambilan keputusan klinis berbasis data. Dengan demikian, penelitian ini tidak hanya relevan secara teknis, tetapi juga memiliki urgensi dalam pengembangan sistem AI di bidang pengolahan citra medis.

## 5. KESIMPULAN

Penelitian ini mengevaluasi dampak Contrast Limited Adaptive Histogram Equalization (CLAHE) dan image upscaling terhadap kinerja klasifikasi katarak berbasis citra retina menggunakan tiga arsitektur deep learning, yaitu Inception-ResNetV2, EfficientNetB0, dan ResNet-50. Hasil eksperimen menunjukkan bahwa teknik peningkatan citra tidak memberikan efek yang seragam pada seluruh model. EfficientNetB0 menunjukkan performa paling stabil pada citra tanpa preprocessing dengan akurasi tertinggi sebesar 96%, sedangkan ResNet-50 mengalami peningkatan kinerja setelah penerapan CLAHE dan upscaling hingga mencapai akurasi 95%. Sebaliknya, Inception-ResNetV2 dan EfficientNetB0 mengalami penurunan performa pada citra hasil preprocessing akibat perubahan distribusi kontras dan tekstur yang tidak sepenuhnya selaras dengan karakteristik ekstraksi fitur arsitekturnya.

Analisis interpretabilitas menggunakan Grad-CAM menunjukkan bahwa ketiga model mampu memfokuskan perhatian pada area yang relevan secara klinis, seperti bagian lensa yang mengalami kekeruhan dan perubahan tekstur pada citra katarak. Visualisasi ini memperkuat bahwa keputusan model tidak bersifat acak, melainkan didasarkan pada fitur anatomis yang bermakna, sehingga meningkatkan kepercayaan dan validitas klinis terhadap sistem klasifikasi yang diusulkan.

Dari sisi aplikasi praktis, temuan penelitian ini menunjukkan bahwa kombinasi arsitektur model dan strategi preprocessing perlu disesuaikan dengan karakteristik data dan tujuan klinis. Pipeline klasifikasi berbasis ResNet-50 dengan preprocessing CLAHE dan upscaling berpotensi diterapkan sebagai sistem pendukung keputusan untuk skrining katarak, khususnya di fasilitas kesehatan dengan keterbatasan tenaga ahli dan sumber daya. Sistem ini dapat membantu mempercepat proses deteksi dini secara objektif dan konsisten, sehingga mendukung pengambilan keputusan medis yang lebih akurat.

Namun demikian, implementasi di lingkungan klinis nyata masih menghadapi tantangan, seperti variasi kualitas citra akibat perbedaan perangkat akuisisi, kondisi pencahayaan, serta heterogenitas karakteristik pasien. Oleh karena itu, penelitian selanjutnya disarankan untuk menggunakan dataset yang lebih besar dan lebih beragam guna meningkatkan kemampuan generalisasi model. Selain itu, eksplorasi teknik enhancement citra alternatif yang lebih adaptif serta integrasi data multimodal, seperti Optical Coherence Tomography (OCT), berpotensi meningkatkan ketahanan dan reliabilitas sistem klasifikasi katarak. Dengan pengembangan lanjutan tersebut, sistem yang diusulkan diharapkan dapat diadaptasi secara lebih luas dalam mendukung protokol skrining kesehatan mata.

## UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada dosen pembimbing atas bimbingan, arahan, dan masukan konstruktif yang diberikan selama proses penelitian dan penyusunan naskah. Apresiasi juga disampaikan kepada pihak-pihak yang telah memberikan dukungan dan diskusi teknis selama penelitian berlangsung. Penulis turut mengucapkan terima kasih kepada Universitas Muhammadiyah Malang atas dukungan institusional dan fasilitas akademik yang disediakan.

## REFERENSI

- [1] P. A. Sulthon, Y. A. Romadhon, Moch. T. Azenta, and R. A. Zakaria, "Pencegahan Kebutaan melalui Edukasi dan Deteksi Dini Katarak di Desa Sanggung, Kabupaten Sukoharjo, Provinsi Jawa Tengah," *Jurnal Inovasi Pengabdian dan Pemberdayaan Masyarakat*, vol. 5, no. 1, pp. 19–28, May 2025, doi: 10.54082/jippm.751.
- [2] F. Damayanti *et al.*, "Hubungan Diabetes Melitus Terhadap Penderita Katarak." [Online]. Available: <http://journal.scientic.id/index.php/sciena/issue/view/20>
- [3] M. J. Greenberg and S. Bamba, "Diabetic cataracts," *Disease-a-Month*, vol. 67, no. 5, May 2021, doi: 10.1016/j.disamonth.2021.101134.

- 
- [4] I. D. Mienye, T. G. Swart, G. Obaido, M. Jordan, and P. Ilono, "Deep Convolutional Neural Networks in Medical Image Analysis: A Review," Mar. 01, 2025, *Multidisciplinary Digital Publishing Institute (MDPI)*. doi: 10.3390/info16030195.
- [5] S. Kumari and P. Singh, "Data efficient deep learning for medical image analysis: A survey," Oct. 2023, [Online]. Available: <http://arxiv.org/abs/2310.06557>
- [6] P. K. Mall *et al.*, "A comprehensive review of deep neural networks for medical image processing: Recent developments and future opportunities," *Healthcare Analytics*, vol. 4, Dec. 2023, doi: 10.1016/j.health.2023.100216.
- [7] T. Tuncer, P. D. Barua, I. Tuncer, S. Dogan, and U. R. Acharya, "A lightweight deep convolutional neural network model for skin cancer image classification," *Appl. Soft Comput.*, vol. 162, Sep. 2024, doi: 10.1016/j.asoc.2024.111794.
- [8] M. Alruwaili and M. Mohamed, "An Integrated Deep Learning Model with EfficientNet and ResNet for Accurate Multi-Class Skin Disease Classification," *Diagnostics*, vol. 15, no. 5, Mar. 2025, doi: 10.3390/diagnostics15050551.
- [9] J. H. L. Goh *et al.*, "Multi-Comparison of Different Ocular Imaging Modality-based Deep Learning Models for Visually Significant Cataract Detection," *Ophthalmology Science*, vol. 5, no. 6, Nov. 2025, doi: 10.1016/j.xops.2025.100837.
- [10] C. J. Ejiyi *et al.*, "Multi-modality medical image classification with ResoMergeNet for cataract, lung cancer, and breast cancer diagnosis," *Comput. Biol. Med.*, vol. 187, Mar. 2025, doi: 10.1016/j.compbimed.2025.109791.
- [11] C. L. Lin and K. C. Wu, "Development of revised ResNet-50 for diabetic retinopathy detection," *BMC Bioinformatics*, vol. 24, no. 1, Dec. 2023, doi: 10.1186/s12859-023-05293-1.
- [12] M. Hayati *et al.*, "Impact of CLAHE-based image enhancement for diabetic retinopathy classification through deep learning," in *Procedia Computer Science*, Elsevier B.V., 2022, pp. 57–66. doi: 10.1016/j.procs.2022.12.111.
- [13] M. K. Jalehi and B. M. Albaker, "Highly accurate multiclass classification of respiratory system diseases from chest radiography images using deep transfer learning technique," *Biomed. Signal Process. Control*, vol. 84, Jul. 2023, doi: 10.1016/j.bspc.2023.104745.
- [14] J. Singh *et al.*, "Identification of Brain Diseases using Image Classification: A Deep Learning Approach," in *Procedia Computer Science*, Elsevier B.V., 2024, pp. 186–192. doi: 10.1016/j.procs.2024.04.021.
- [15] M. M. M, M. T. R, V. K. V, and S. Guluwadi, "Enhancing brain tumor detection in MRI images through explainable AI using Grad-CAM with Resnet 50," *BMC Med. Imaging*, vol. 24, no. 1, Dec. 2024, doi: 10.1186/s12880-024-01292-7.
- [16] S. Srinivasan, D. Francis, S. K. Mathivanan, H. Rajadurai, B. D. Shivahare, and M. A. Shah, "A hybrid deep CNN model for brain tumor image multi-classification," *BMC Med. Imaging*, vol. 24, no. 1, Dec. 2024, doi: 10.1186/s12880-024-01195-7.
- [17] M. Aamir, Z. Rahman, U. A. Bhatti, W. A. Abro, J. A. Bhutto, and Z. He, "An automated deep learning framework for brain tumor classification using MRI imagery," *Sci. Rep.*, vol. 15, no. 1, Dec. 2025, doi: 10.1038/s41598-025-02209-2.
- [18] D. Muhammad and M. Bendeche, "Unveiling the black box: A systematic review of Explainable Artificial Intelligence in medical image analysis," Dec. 01, 2024, *Elsevier B.V.* doi: 10.1016/j.csbj.2024.08.005.
- [19] I. Tuncer, S. Dogan, and T. Tuncer, "MobileDenseNeXt: Investigations on biomedical image classification," *Expert Syst. Appl.*, vol. 255, Dec. 2024, doi: 10.1016/j.eswa.2024.124685.
- [20] A. Sajust de Bergues de Escalup *et al.*, "Deep learning-based image reconstruction significantly improves image quality of MRI examinations of the orbit at 3 Tesla," *Diagn. Interv. Imaging*, 2025, doi: 10.1016/j.diii.2025.11.003.
- [21] E. Perdana *et al.*, "KLASIFIKASI CITRA ULOS BATAK MENGGUNAKAN METODE SVM DAN KNN DENGAN EKSTRAKSI FITUR BERBASIS RESNET50," 2025.
- [22] M. J. Alwazzan and A. M. Alattar, "Modified algorithm to enhance illumination and detail in colour retinal images using the CLAHE technique with a Wiener filter," *Biomed. Signal Process. Control*, vol. 110, Dec. 2025, doi: 10.1016/j.bspc.2025.108241.
-

- 
- [23] R. Santos, J. Pedrosa, A. M. Mendonça, and A. Campilho, “Grad-CAM: The impact of large receptive fields and other caveats,” *Computer Vision and Image Understanding*, vol. 258, Jul. 2025, doi: 10.1016/j.cviu.2025.104383.
- [24] D. Bhati, F. Neha, and M. Amiruzzaman, “A Survey on Explainable Artificial Intelligence (XAI) Techniques for Visualizing Deep Learning Models in Medical Imaging,” *J. Imaging*, vol. 10, no. 10, Oct. 2024, doi: 10.3390/jimaging10100239.
- [25] B. H. M. van der Velden, H. J. Kuijff, K. G. A. Gilhuijs, and M. A. Viergever, “Explainable artificial intelligence (XAI) in deep learning-based medical image analysis,” Jul. 01, 2022, *Elsevier B.V.* doi: 10.1016/j.media.2022.102470.
- [26] H. Sriraman, S. Badarudeen, S. Vats, and P. Balasubramanian, “A Systematic Review of Real-Time Deep Learning Methods for Image-Based Cancer Diagnostics,” *J. Multidiscip. Healthc.*, vol. 17, pp. 4411–4425, 2024, doi: 10.2147/JMDH.S446745.
- [27] T. N. Siregar and D. Juniati, “IMPLEMENTASI DIMENSI FRAKTAL BOX COUNTING DAN K-MEANS DALAM KLASIFIKASI JENIS PENYAKIT MATA BERDASARKAN CITRA FUNDUS RETINA.” [Online]. Available: <https://www.kaggle.com/datasets/andrewmvd/ocular-disease-recognition-odir5k>
- [28] B. J. Baladiah and A. Ikhssani, “LAPORAN KASUS : CANALICULITIS OD + KATARAK SENILE IMMATURE OS,” vol. 2, no. 3, 2021.
- [29] S. Muliani, B. Sukma Negara, M. Irsyad, and I. Iskandar, “Application of Shapley Additive Explanations (SHAP) in Deep Learning for Lung Disease Detection Using X-ray Images,” *Journal of Artificial Intelligence and Software Engineering*, vol. 5, no. 2, pp. 709–719, 2025, doi: 10.30811/jaise.v5i2.7044.
- [30] D. Clement Sumampouw *et al.*, “OPTIMALISASI DETEKSI WAJAH DLIB-HOG PADA CITRA INTENSITAS RENDAH DENGAN PREPROCESSING CLAHE,” 2025.
- [31] Y. Yoshimi *et al.*, “Image preprocessing with contrast-limited adaptive histogram equalization improves the segmentation performance of deep learning for the articular disk of the temporomandibular joint on magnetic resonance images,” *Oral Surg. Oral Med. Oral Pathol. Oral Radiol.*, vol. 138, no. 1, pp. 128–141, Jul. 2024, doi: 10.1016/j.oooo.2023.01.016.
- [32] K. Wolk, J. Niklewski, M. Kopczynski, M. S. Tatara, and O. Zero, “Enhancing Semantic Forestry Segmentation Through Advanced Preprocessing With ML Models,” *IEEE Access*, vol. 13, pp. 98602–98621, 2025, doi: 10.1109/ACCESS.2025.3575713.
- [33] D. Normawati and S. A. Prayogi, “Implementasi Naïve Bayes Classifier Dan Confusion Matrix Pada Analisis Sentimen Berbasis Teks Pada Twitter,” 2021.