

Transfer Learning dengan CLAHE dan *Sharpening filter* untuk Deteksi Pneumonia pada Citra X-Ray

Karan¹, Rahmad Firdaus², Harun Mukhtar³, Febby Apri Wenando⁴
^{1,2,3}Jurusan Teknik Informatika, Ilmu Komputer, Universitas Muhammadiyah Riau

⁴Jurusan Sistem Informasi, Teknologi Informasi, Universitas Andalas

¹220401206@student.umri.ac.id*, ²rahmadfirdaus@umri.ac.id, ³harunmukhtar@umri.ac.id, ⁴febby.apri@it.unand.ac.id

Abstract

Pneumonia is a respiratory infection that remains a leading cause of death, especially in children, requiring an automatic detection system based on chest X-ray images. The main challenge in automatic classification is low image quality, such as suboptimal contrast and unclear lung details, which can affect the feature extraction process by deep learning models. To address these issues, this study applies Contrast Limited Adaptive Histogram Equalization (CLAHE) to enhance image contrast and a sharpening filter to clarify lung edge details. The study aims to analyze the effect of preprocessing on classification performance using EfficientNet-B0 based on Transfer Learning with a full fine-tuning strategy. The dataset used is Chest X-Ray Pneumonia from Kaggle with 5,856 images consisting of Normal and Pneumonia classes. Experiments compare the Baseline model, CLAHE, and a combination of CLAHE and sharpening in three data sharing scenarios. Evaluation is carried out using accuracy, precision, recall, and image quality metrics PSNR, SSIM, and CII. The results of the study showed that the combination of CLAHE and sharpening in the 80:10:10 scenario produced the best performance with an accuracy of 97.61%, precision of 0.97, recall of 0.99, and an increase in image quality based on a CII value of 1.157.

Keywords: Pneumonia, chest x-ray, CLAHE, transfer learning, efficientNet-B0

Abstrak

Pneumonia merupakan penyakit infeksi saluran pernapasan yang masih menjadi salah satu penyebab utama kematian, terutama pada anak-anak, sehingga diperlukan sistem deteksi otomatis berbasis citra X-ray dada. Tantangan utama dalam klasifikasi otomatis adalah kualitas citra yang rendah, seperti kontras yang kurang optimal dan detail paru-paru yang tidak jelas, sehingga dapat memengaruhi proses ekstraksi fitur oleh model *deep learning*. Untuk mengatasi permasalahan tersebut, penelitian ini menerapkan *Contrast Limited Adaptive Histogram Equalization* (CLAHE) untuk meningkatkan kontras citra serta *sharpening filter* untuk memperjelas detail tepi paru-paru. Penelitian bertujuan menganalisis pengaruh *preprocessing* terhadap performa klasifikasi menggunakan *EfficientNet-B0* berbasis *Transfer Learning* dengan strategi *full fine-tuning*. Dataset yang digunakan adalah *Chest X-Ray Pneumonia* dari Kaggle sebanyak 5.856 citra yang terdiri dari kelas *Normal* dan *Pneumonia*. Eksperimen membandingkan model *Baseline*, CLAHE, serta kombinasi CLAHE dan *sharpening* pada tiga skenario pembagian data. Evaluasi dilakukan menggunakan *accuracy*, *precision*, *recall*, serta metrik kualitas citra *PSNR*, *SSIM*, dan *CII*. Hasil penelitian menunjukkan kombinasi CLAHE dan *sharpening* pada skenario 80:10:10 menghasilkan performa terbaik dengan akurasi 97,61%, *precision* 0,97, *recall* 0,99, serta peningkatan kualitas citra berdasarkan nilai *CII* sebesar 1,157.

Kata kunci: pneumonia, x-ray dada, CLAHE, transfer learning, *efficientNet-B0*

©This work is licensed under a Creative Commons Attribution -ShareAlike 4.0 International License

1. Pendahuluan

Pneumonia merupakan infeksi pada saluran pernapasan bagian bawah yang masih menjadi salah satu penyebab kematian tertinggi di dunia, khususnya pada kelompok anak-anak dan lanjut usia. Penyakit ini terjadi ketika alveoli di paru-paru terisi cairan atau nanah sehingga proses pertukaran oksigen di dalam tubuh menjadi terganggu [1]. Berdasarkan data *World Health Organization* (WHO), pneumonia menyebabkan sekitar 2,5 juta kematian setiap tahun di seluruh dunia, termasuk 740.180 kasus kematian pada anak berusia di bawah lima tahun [2]. Di Indonesia, pneumonia termasuk salah satu faktor utama penyebab kematian balita dan kelompok rentan lainnya sehingga diperlukan proses diagnosis yang cepat dan akurat [3]. Selain itu, tingginya jumlah kasus pneumonia setiap tahun menyebabkan kebutuhan terhadap sistem diagnosis yang efektif dan efisien menjadi semakin

penting, khususnya pada fasilitas kesehatan dengan keterbatasan tenaga radiolog.

Dalam praktik klinis, citra X-ray dada merupakan metode pencitraan medis yang paling umum digunakan untuk mendeteksi pneumonia karena bersifat cepat, non-invasif, dan relatif mudah diakses. Melalui citra X-ray, tenaga medis dapat mengamati adanya infiltrat, konsolidasi, maupun kelainan lain pada paru-paru yang mengindikasikan pneumonia. Namun, interpretasi citra secara manual masih dipengaruhi oleh pengalaman radiolog serta berisiko menimbulkan kesalahan diagnosis, terutama pada citra dengan kualitas rendah seperti kontras yang kurang optimal, *noise*, serta pencahayaan yang tidak merata [4]. Variasi kualitas citra tersebut dapat menyebabkan perbedaan hasil interpretasi antar pengamat dan meningkatkan risiko kesalahan identifikasi penyakit.

Perkembangan teknologi mendorong meningkatnya penggunaan kecerdasan buatan di bidang kesehatan, terutama untuk analisis citra medis. Salah satu metode yang banyak diterapkan ialah *deep learning* berbasis CNN karena mampu mengenali dan mengekstraksi pola visual pada citra secara otomatis. CNN mampu mengenali pola penting pada citra, mulai dari tepi, tekstur, hingga struktur kompleks yang berkaitan dengan karakteristik penyakit. Penelitian sebelumnya menunjukkan bahwa CNN mampu memberikan performa yang tinggi dalam klasifikasi citra medis [5]. Selain itu, penerapan *Transfer Learning* membantu model memanfaatkan bobot pra-latih dari dataset besar sehingga proses pelatihan menjadi lebih cepat dan efektif pada dataset medis yang terbatas [5].

Berbagai penelitian terdahulu telah menerapkan metode *deep learning* untuk klasifikasi pneumonia berbasis citra X-ray dada dengan hasil yang cukup baik. Pasha et al., (2025) menyatakan bahwa penggunaan CNN mampu meningkatkan akurasi klasifikasi pneumonia dibandingkan metode konvensional [6]. Sebastian et al., (2025) menggunakan arsitektur ResNet-50 dan memperoleh performa klasifikasi yang baik, namun masih menghadapi kendala pada variasi kualitas citra dan ketidakseimbangan data [7]. Penelitian lain Li et al., (2022) menunjukkan bahwa pengembangan arsitektur EfficientNet mampu meningkatkan performa klasifikasi pneumonia dengan efisiensi komputasi yang lebih baik dibanding beberapa arsitektur CNN lainnya [8]. Temuan-temuan tersebut menunjukkan bahwa kualitas citra dan tahap pra-pemrosesan memiliki pengaruh besar terhadap performa model *deep learning*.

Kualitas visual citra X-ray dada menjadi salah satu faktor penting dalam keberhasilan proses klasifikasi pneumonia. Variasi kontras, pencahayaan, distribusi intensitas piksel, serta ketajaman detail struktur paru-paru dapat memengaruhi proses ekstraksi fitur oleh model *deep learning*. Citra dengan kontras rendah dan detail yang kurang jelas berpotensi menyebabkan model kesulitan mengenali pola pneumonia secara konsisten sehingga menurunkan akurasi klasifikasi [9]. Pengamatan terhadap beberapa sampel citra pada dataset menunjukkan bahwa sebagian citra memiliki distribusi intensitas yang tidak merata dan detail tepi paru-paru yang kurang tajam, sehingga diperlukan teknik peningkatan kualitas citra untuk memperjelas informasi visual sebelum proses klasifikasi dilakukan.

Salah satu teknik peningkatan kualitas citra yang banyak digunakan ialah *Contrast Limited Adaptive Histogram Equalization* (CLAHE). Teknik ini bekerja dengan meningkatkan kontras lokal pada citra sehingga detail struktur paru-paru dapat terlihat lebih jelas tanpa meningkatkan *noise* secara berlebihan (Elizabeth, 2020). Penelitian oleh Azzumzumi et al., (2024) menghasilkan performa klasifikasi yang tinggi pada citra X-ray paru-paru [10]. Selain itu, Rizki Chandranegara et al., (2024) melaporkan bahwa penerapan CLAHE dan augmentasi data dapat

membantu meningkatkan stabilitas performa model serta mengurangi *overfitting* pada proses pelatihan CNN [11].

Namun demikian, peningkatan kontras saja belum sepenuhnya mampu memperjelas batas antar jaringan maupun struktur abnormal pada paru-paru. Selain kontras, ketajaman detail tepi dan tekstur citra juga memiliki peran penting dalam membantu model *deep learning* mengenali pola pneumonia [10]. Oleh karena itu, diperlukan teknik *sharpening filter* untuk mempertegas detail tepi dan meningkatkan kejelasan struktur paru-paru pada citra X-ray. Penelitian oleh Ahamed et al., (2021) menunjukkan bahwa penerapan *sharpening filter* sebelum proses pelatihan model mampu membantu meningkatkan kualitas fitur visual dan memberikan kontribusi terhadap peningkatan performa klasifikasi [12].

Meskipun berbagai penelitian telah menerapkan teknik CLAHE maupun *sharpening filter* sebagai bagian dari *preprocessing* citra, sebagian besar penelitian hanya berfokus pada hasil akhir akurasi model tanpa melakukan evaluasi komparatif secara sistematis terhadap kontribusi masing-masing teknik *preprocessing*. Selain itu, penelitian yang menggunakan arsitektur EfficientNet umumnya berfokus pada varian model yang lebih besar seperti EfficientNet-B3 atau EfficientNet-B4, sedangkan kajian mengenai pengaruh kombinasi CLAHE dan *sharpening filter* terhadap performa EfficientNet-B0 masih relatif terbatas. Padahal, EfficientNet-B0 memiliki kompleksitas model yang lebih ringan dan efisien sehingga berpotensi diterapkan pada sistem diagnosis dengan kebutuhan komputasi yang lebih rendah.

Berdasarkan tinjauan literatur tersebut, penelitian ini mengidentifikasi beberapa keterbatasan pada penelitian sebelumnya, seperti minimnya evaluasi komparatif terhadap kontribusi masing-masing teknik *preprocessing* serta terbatasnya penggunaan arsitektur EfficientNet-B0 pada klasifikasi pneumonia citra X-ray dada. Sebagian besar penelitian terdahulu lebih berfokus pada peningkatan akurasi model tanpa menganalisis pengaruh peningkatan kualitas citra terhadap kemampuan ekstraksi fitur model secara sistematis. Selain itu, evaluasi kualitas citra menggunakan metrik seperti *Peak Signal-to-Noise Ratio* (PSNR), *Structural Similarity Index Measure* (SSIM), dan *Contrast Improvement Index* (CII) juga masih jarang dilakukan.


Untuk mengatasi keterbatasan tersebut, penelitian ini menerapkan evaluasi komparatif pada tiga skenario *preprocessing*, yaitu tanpa *preprocessing*, CLAHE, serta kombinasi CLAHE dan *sharpening filter* menggunakan arsitektur EfficientNet-B0 berbasis *Transfer Learning*. Seluruh eksperimen dilakukan menggunakan dataset dan konfigurasi pelatihan yang sama sehingga pengaruh masing-masing teknik *preprocessing* terhadap performa model dapat

dianalisis secara lebih objektif dan sistematis. Selain mengevaluasi performa klasifikasi, penelitian ini juga menganalisis kualitas citra hasil *preprocessing* untuk mengetahui kontribusinya terhadap peningkatan kemampuan model untuk mengidentifikasi pneumonia melalui citra X-ray dada.

Penelitian ini bertujuan untuk menganalisis pengaruh penerapan CLAHE dan *sharpening filter* terhadap performa klasifikasi pneumonia menggunakan arsitektur *EfficientNet-B0* berbasis *Transfer Learning*, serta mengevaluasi kontribusi peningkatan kualitas citra terhadap kemampuan model untuk mengidentifikasi pneumonia melalui citra X-ray dada. Penelitian menggunakan Chest X-Ray Pneumonia Dataset yang diperoleh dari platform Kaggle dan terdiri dari dua kelas, yaitu Normal dan Pneumonia. Selain penerapan *preprocessing* citra, penelitian ini juga menerapkan augmentasi data pada data latih untuk meningkatkan keragaman sampel dan kemampuan generalisasi model.

2. Metode Penelitian

Pada penelitian ini diterapkan pendekatan *deep learning* berbasis *Transfer Learning* dengan arsitektur *EfficientNet-B0* untuk mendeteksi pneumonia pada citra X-ray dada. Metode penelitian dirancang untuk menganalisis pengaruh peningkatan kualitas citra terhadap performa klasifikasi pneumonia menggunakan kombinasi teknik CLAHE dan *sharpening filter*. Tahapan penelitian meliputi pengumpulan dataset, *preprocessing* citra, augmentasi data, pemodelan menggunakan *EfficientNet-B0*, pelatihan model, pengujian model, dan evaluasi performa klasifikasi. Alur tahapan penelitian yang diterapkan pada penelitian ini ditunjukkan pada Gambar 1.



Gambar 1. Alur Penelitian

2.1. Dataset

Penelitian ini memanfaatkan dataset Chest X-Ray Images (*Pneumonia*) yang diperoleh melalui platform Kaggle. Dataset tersebut terdiri dari 5.856 citra X-ray dada yang terbagi ke dalam dua kelas, yaitu 1.583 citra kelas Normal dan 4.273 citra kelas Pneumonia. Dataset ini dipilih karena banyak digunakan pada penelitian klasifikasi pneumonia berbasis *deep learning* sehingga relevan untuk digunakan sebagai acuan dalam mengevaluasi performa model yang diusulkan.

Struktur dataset bawaan Kaggle terdiri atas folder *train*, *validation*, dan *test*. Namun, jumlah data validasi pada struktur asli dataset relatif kecil sehingga kurang representatif untuk memantau performa model selama proses pelatihan. Oleh karena itu, seluruh data

digabungkan kembali dan dilakukan pembagian ulang *dataset* menggunakan metode *stratified sampling*. Teknik ini digunakan untuk memastikan distribusi kelas Normal dan Pneumonia tetap proporsional pada setiap *subset* data.

Pada penelitian ini diterapkan tiga skenario pembagian data untuk menganalisis pengaruh proporsi data terhadap performa model. Rincian pembagian data latih, data validasi, dan data uji pada setiap skenario ditunjukkan pada Tabel 1.

Tabel 1. Tabel Pembagian Data

Pembagian	Data Latih	Data Validasi	Data Uji
1	70%	10%	20%
2	80%	10%	10%
3	90%	5%	5%

Rincian pembagian data pada setiap skenario ditunjukkan pada Tabel 1. Berdasarkan Tabel 1, penelitian ini menerapkan tiga skenario pembagian data, yaitu 70:10:20, 80:10:10, dan 90:5:5 untuk data latih, data validasi, dan data uji. Proses pembagian dataset dilakukan menggunakan *fixed seed* (*random state* = 123) untuk menjaga konsistensi dan reproduibilitas hasil eksperimen. Data latih digunakan dalam tahap pelatihan model, data validasi digunakan untuk memantau performa model selama proses *training*, sedangkan data uji digunakan untuk mengevaluasi kemampuan model dalam mengenali data baru yang belum pernah diproses sebelumnya.

2.2. Preprocessing Data

Tahap *preprocessing* bertujuan memperbaiki kualitas visual citra sebelum data digunakan pada proses pelatihan model *deep learning*. *Preprocessing* bertujuan untuk menyeragamkan karakteristik citra dan memperjelas detail struktur paru-paru sehingga fitur visual lebih mudah dipelajari oleh model. Tahapan *preprocessing* pada penelitian ini meliputi *resizing*, peningkatan kontras menggunakan CLAHE, peningkatan ketajaman menggunakan *sharpening filter*, normalisasi, dan augmentasi data.

2.2.1 Resizing

Pada tahap *preprocessing*, seluruh citra X-ray dada diubah menjadi ukuran 224×224 piksel supaya sesuai dengan kebutuhan input arsitektur *EfficientNet-B0*. Penyeragaman ukuran citra bertujuan untuk menjaga konsistensi dimensi data serta mengurangi kompleksitas komputasi selama proses pelatihan model. Selain itu, *resizing* juga membantu mempercepat proses pelatihan tanpa menghilangkan informasi visual penting pada citra.

2.2.2 Contrast Limited Adaptive Histogram Equalization (CLAHE)

Setelah proses *resizing*, citra diproses menggunakan metode CLAHE untuk meningkatkan kontras lokal pada citra X-ray dada. CLAHE merupakan pengembangan dari metode *Histogram Equalization*

yang bekerja dengan membagi citra menjadi beberapa area kecil (*tile*), kemudian melakukan proses ekualisasi histogram secara adaptif pada setiap area tersebut.

Pada penelitian ini digunakan parameter *Number of Tiles* sebesar 8×8 dan Contrast Limit sebesar 0,01. Penerapan CLAHE bertujuan untuk memperjelas distribusi intensitas piksel dan meningkatkan visibilitas detail struktur paru-paru, terutama pada area dengan kontras rendah. Teknik ini dipilih karena mampu meningkatkan kualitas citra tanpa memperbesar *noise* secara berlebihan sehingga detail visual tetap terjaga dengan baik.

2.2.3 Sharpening filter

Selain peningkatan kontras, penelitian ini juga menerapkan *sharpening filter* untuk meningkatkan ketajaman detail citra. Teknik sharpening digunakan untuk memperjelas struktur tepi dan tekstur paru-paru dengan meningkatkan perbedaan intensitas antar piksel yang berdekatan [13]. Penerapan *sharpening filter* penting dalam klasifikasi pneumonia karena area infiltrat dan opasitas pada paru-paru sering memiliki batas jaringan yang kurang jelas.

Pada penelitian ini, *sharpening* diterapkan menggunakan kernel konvolusi berukuran 3×3 seperti pada Persamaan (1).

$$\begin{bmatrix} 0 & -1 & 0 \\ -1 & 5 & -1 \\ 0 & -1 & 0 \end{bmatrix} \quad (1)$$

Kernel tersebut digunakan untuk mempertegas struktur tepi dan meningkatkan komponen frekuensi tinggi pada citra sehingga detail jaringan paru-paru menjadi lebih jelas. Dengan citra yang lebih tajam, model *deep learning* diharapkan mampu mengekstraksi fitur spasial secara lebih optimal sehingga proses klasifikasi menjadi lebih akurat.

2.2.4 Normalisasi dan Augmentasi Data

Setelah proses peningkatan kualitas citra, dilakukan normalisasi menggunakan fungsi *preprocess_input* dari EfficientNet agar distribusi nilai piksel sesuai dengan standar pelatihan ImageNet. Pendekatan ini membantu meningkatkan stabilitas pelatihan dan mempercepat proses konvergensi model. Selain normalisasi, penelitian ini juga menerapkan augmentasi data pada data latih untuk memperkaya keragaman data citra serta meminimalkan kemungkinan *overfitting*. Parameter augmentasi data yang digunakan pada penelitian ini ditunjukkan pada Tabel 2.

Tabel 2. Parameter Augmentasi Data

Parameter	Nilai
Rotation Range	25°
Width Shift Range	0,05
Height Shift Range	0,05
Zoom Range	0,05
Shear Range	0,05

Horizontal Flip	True
-----------------	------

Berdasarkan Tabel 2, proses augmentasi hanya dilakukan pada data latih, sedangkan data validasi dan data uji tetap menggunakan citra asli tanpa modifikasi. Hal ini bertujuan agar evaluasi performa model dapat menggambarkan kemampuan model dalam mengenali data nyata secara lebih akurat.

2.2.5 Evaluasi Kuantitatif Kualitas Citra

Untuk memastikan bahwa proses *preprocessing* memberikan peningkatan kualitas citra secara objektif, dilakukan evaluasi menggunakan beberapa metrik kuantitatif, yaitu *Peak Signal-to-Noise Ratio* (PSNR), *Structural Similarity Index Measure* (SSIM), dan *Contrast Improvement Index* (CII). Ketiga metrik tersebut digunakan untuk membandingkan kualitas citra hasil *preprocessing* dengan citra asli.

PSNR digunakan untuk mengevaluasi tingkat distorsi antara citra asli dan citra hasil *preprocessing* berdasarkan rasio *noise*. Semakin tinggi nilai PSNR, menunjukkan kualitas citra hasil *preprocessing* dianggap semakin baik karena perbedaan dengan citra asli semakin kecil.

SSIM dimanfaatkan untuk mengukur tingkat kemiripan struktur antara citra asli dan citra hasil *preprocessing*. Nilai SSIM berada pada rentang 0 hingga 1, di mana nilai yang semakin mendekati 1 menunjukkan bahwa struktur citra hasil *preprocessing* semakin serupa dengan citra asli.

Sementara itu, CII digunakan untuk mengukur tingkat peningkatan kontras citra setelah *preprocessing* diterapkan. Nilai CII yang lebih tinggi menunjukkan peningkatan kontras yang lebih baik pada citra hasil *preprocessing*. Evaluasi menggunakan ketiga metrik tersebut dilakukan untuk menganalisis kontribusi peningkatan kualitas citra terhadap performa klasifikasi pneumonia menggunakan *EfficientNet-B0*.

2.3. Pemodelan *EfficientNet-B0* dengan *Transfer Learning*

Penelitian ini menerapkan arsitektur *EfficientNet-B0* berbasis *Transfer Learning* sebagai model utama dalam proses klasifikasi pneumonia pada citra X-ray dada. *EfficientNet-B0* dipilih karena memiliki keseimbangan antara performa klasifikasi dan efisiensi komputasi sehingga sesuai untuk diterapkan pada klasifikasi citra medis. Model menggunakan bobot awal dari ImageNet dan menerapkan strategi *full fine-tuning* agar seluruh *layer* dapat menyesuaikan karakteristik fitur citra X-ray dada secara optimal. Konfigurasi arsitektur *EfficientNet-B0* yang digunakan pada penelitian ini ditunjukkan pada Tabel 3.

Tabel 3. Konfigurasi Arsitektur *EfficientNet-B0*

Komponen Model	Konfigurasi
Arsitektur Dasar	<i>EfficientNet-B0</i>
Pendekatan	<i>Transfer Learning</i>
Bobot Awal	ImageNet
Strategi Pelatihan	Full Fine-Tuning

Ukuran Input	224 × 224 × 3
Base Model	include_top = False
Pooling Layer	Global Max Pooling
Batch Normalization	Digunakan
Dense Layer	256 neuron
Regularisasi	L1 dan L2
Dropout	0,45
Output Layer	Dense 2 neuron
Fungsi Aktivasi Output	Softmax
Kelas Output	Normal dan Pneumonia

Berdasarkan Tabel 3, model menggunakan tambahan *dense layer*, *dropout*, dan regularisasi L1-L2 untuk membantu model mempelajari representasi fitur yang lebih spesifik serta mengurangi risiko *overfitting* selama proses pelatihan.

2.4. Hyperparameter Pelatihan

Pelatihan model dilakukan menggunakan *optimizer* Adamax dengan *learning rate* sebesar 0,001 [14]. *Optimizer* Adamax dipilih karena mampu memberikan konvergensi yang stabil pada proses *Transfer Learning* untuk klasifikasi citra medis. Batch size yang digunakan sebesar 16 dengan maksimum epoch sebanyak 50. Fungsi loss yang diterapkan dalam penelitian ini adalah *categorical cross-entropy* karena penelitian ini menggunakan klasifikasi dua kelas dengan fungsi aktivasi Softmax pada output layer.

Untuk mengurangi risiko *overfitting*, penelitian ini menerapkan *callback Early Stopping* dengan *parameter patience* sebesar 5 yang memantau nilai *validation loss* selama proses pelatihan. Mekanisme ini memungkinkan proses pelatihan dihentikan secara otomatis ketika performa model tidak lagi mengalami peningkatan.

2.5 Desain Eksperimen

Penelitian ini menggunakan tiga skenario eksperimen untuk menganalisis pengaruh *preprocessing* terhadap performa model klasifikasi pneumonia. Setiap skenario menggunakan arsitektur *EfficientNet-B0* berbasis *Transfer Learning* dengan konfigurasi pelatihan, pembagian data, dan teknik augmentasi yang sama. Perbedaan antar skenario terletak pada teknik *preprocessing* citra yang diterapkan sebelum proses pelatihan model. Desain eksperimen yang digunakan pada penelitian ini ditunjukkan pada Tabel 4.

Tabel 4. Desain Eksperimen

Model	CLAHE	Sharpening	Keterangan
Baseline	Tidak	Tidak	Tanpa <i>preprocessing</i>
CLAHE	Ya	Tidak	Peningkatan kontras
Proposed	Ya	Ya	CLAHE + sharpening

Berdasarkan Tabel 4, seluruh skenario menggunakan dataset, pembagian data, arsitektur model, teknik augmentasi, dan *hyperparameter* pelatihan yang sama sehingga perbedaan hasil evaluasi merepresentasikan pengaruh langsung dari teknik *preprocessing* yang diterapkan terhadap performa model *EfficientNet-B0*.

2.6 Evaluasi Model

Evaluasi model dilakukan menggunakan data uji yang tidak dilibatkan dalam proses pelatihan. Kinerja model dianalisis menggunakan beberapa metrik evaluasi, yaitu *accuracy*, *precision*, *recall*, dan *F1-score*. Selain itu, *Confusion Matrix* digunakan untuk menganalisis hasil klasifikasi pada masing-masing kelas, yaitu *Normal* dan *Pneumonia* [15].

Penelitian ini juga menggunakan *learning curve* untuk memantau perubahan nilai *accuracy* dan *loss* pada data latih dan data validasi selama proses pelatihan. Analisis *learning curve* dilakukan untuk menilai kestabilan model serta mendeteksi kemungkinan terjadinya *overfitting* maupun *underfitting* pada model klasifikasi pneumonia yang dibangun.

2.7 McNemar's Test

Penelitian ini menerapkan *McNemar's Test* untuk menganalisis signifikansi statistik perbedaan performa antar model klasifikasi yang diuji. Pengujian dilakukan terhadap model *Baseline*, model dengan CLAHE, dan model usulan menggunakan kombinasi CLAHE dan *sharpening filter*.

McNemar's Test digunakan karena pengujian dilakukan pada data uji yang sama sehingga hasil prediksi antar model bersifat berpasangan (*paired data*) [16]. Pengujian difokuskan pada jumlah prediksi yang berbeda antara dua model untuk mengetahui apakah perbedaan performa yang diperoleh terjadi secara signifikan atau hanya disebabkan oleh faktor kebetulan.

Pengambilan keputusan dilakukan menggunakan nilai *p-value* dengan tingkat signifikansi sebesar 0,05. Jika nilai *p-value* < 0,05 maka perbedaan performa antar model dinyatakan signifikan secara statistik, sedangkan jika nilai *p-value* > 0,05 maka perbedaan performa antar model dinyatakan tidak signifikan secara statistik.

3. Hasil dan Pembahasan

Hasil penelitian diperoleh melalui proses pelatihan dan pengujian model *EfficientNet-B0* berbasis *Transfer Learning* pada dataset Chest X-Ray Pneumonia. Penelitian dilakukan dengan membandingkan tiga skenario *preprocessing*, yaitu model tanpa *preprocessing* (*Baseline*), model dengan CLAHE, serta model dengan kombinasi CLAHE dan *sharpening filter*. Evaluasi dilakukan menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score* untuk mengetahui pengaruh peningkatan kualitas citra terhadap performa klasifikasi pneumonia.

3.1. Pengumpulan

Dataset yang digunakan pada penelitian ini terdiri dari 5.856 citra *X-ray* dada yang terbagi menjadi dua kelas, yaitu 1.583 citra kelas *Normal* dan 4.273 citra kelas *Pneumonia* [16]. Seluruh dataset digabungkan kembali sebelum dilakukan pembagian ulang menggunakan metode *stratified sampling* agar distribusi kelas tetap proporsional pada setiap subset data. Deskripsi dataset

yang digunakan pada penelitian ini ditunjukkan pada Tabel 5.

Tabel 5. Deskripsi Dataset

Karakteristik	Deskripsi
Jenis Data	Citra medis (X-ray dada)
Format Data	JPEG
Jumlah Total Citra	5.856 gambar
Jumlah Kelas	2 (Normal dan Pneumonia)
Distribusi Kelas	1.583 Normal, 4.273 Pneumonia
Sumber Dataset	Guangzhou Women and Children's Medical Center
Lisensi	CC BY 4.0

Berdasarkan Tabel 5, dataset menunjukkan distribusi kelas yang tidak seimbang, di mana jumlah citra *Pneumonia* lebih besar dibandingkan *Normal*. Ketidakseimbangan ini berpotensi memengaruhi performa model klasifikasi, terutama pada metrik akurasi. Oleh karena itu, evaluasi performa pada penelitian ini tidak hanya menggunakan *accuracy*, tetapi juga *precision*, *recall*, dan *F1-score* agar penilaian kemampuan model dalam mengklasifikasikan kedua kelas dapat dilakukan secara lebih menyeluruh.

3.2 Pembagian data

Penelitian ini menerapkan tiga skenario pembagian data, yaitu 70:10:20, 80:10:10, dan 90:5:5 untuk data latih, validasi, dan data uji. Penggunaan beberapa skenario pembagian data ditujukan untuk mengevaluasi pengaruh jumlah data latih terhadap kemampuan generalisasi model dalam mendeteksi pneumonia. Distribusi data untuk skenario 70:10:20, 80:10:10, dan 90:5:5 masing-masing ditunjukkan pada Tabel 6, Tabel 7, dan Tabel 8.

Tabel 6. Distribusi Data Skenario 70:10:20

Subset	Normal	Pneumonia	Total
Train	1108	2991	4099
Validation	158	427	585
Test	317	855	1172
Total	1583	4273	5856

Berdasarkan Tabel 6, pada skenario 70:10:20 jumlah data uji lebih besar dibandingkan skenario lainnya sehingga evaluasi model dilakukan pada jumlah sampel yang lebih banyak.

Tabel 7. Distribusi Data Skenario 80:10:10

Subset	Normal	Pneumonia	Total
Train	1266	3418	4684
Validation	159	427	586
Test	158	428	586
Total	1583	4273	5856

Berdasarkan Tabel 7, skenario 80:10:10 memberikan proporsi data latih dan data uji yang lebih seimbang sehingga diharapkan mampu menghasilkan performa generalisasi model yang optimal.

Tabel 8. Distribusi Data Skenario 90:5:5

Subset	Normal	Pneumonia	Total
Train	1425	3845	5270

Validation	79	214	293
Test	79	214	293
Total	1583	4273	5856


Berdasarkan Tabel 8, skenario 90:5:5 memiliki jumlah data latih paling besar, namun jumlah data validasi dan data uji relatif lebih sedikit dibandingkan skenario lainnya.

Secara keseluruhan, distribusi kelas pada setiap subset tetap terjaga secara proporsional sehingga dapat mengurangi potensi bias model terhadap kelas mayoritas. Pendekatan *stratified sampling* juga membantu menjaga konsistensi distribusi data selama proses eksperimen dilakukan.

3.2 Pra-prosesan Data

Tahap pra-prosesan data merupakan bagian penting yang dilakukan dalam proses pelatihan model *deep learning*. Proses ini bertujuan untuk meningkatkan kualitas citra, menyeragamkan ukuran input, serta menyiapkan data agar sesuai dengan kebutuhan arsitektur model yang digunakan. Selain itu, pra-prosesan juga membantu model dalam mengekstraksi fitur yang lebih relevan dari citra X-ray dada.

Pada penelitian ini, proses pra-prosesan data dilakukan melalui beberapa tahapan, yaitu pembagian dataset, resizing citra, peningkatan kontras menggunakan metode CLAHE, peningkatan ketajaman menggunakan *sharpening filter*, evaluasi kualitas citra, normalisasi data, serta augmentasi data. Dataset dibagi menggunakan metode stratified sampling dengan skenario pembagian data sebesar 80:10:10 untuk data latih, data validasi, dan data uji agar distribusi kelas tetap proporsional pada setiap subset data. Alur lengkap proses pra-prosesan data yang diterapkan pada penelitian ini ditunjukkan pada Gambar 2.



Gambar 2. Alur *Preprocessing* Citra

Pada Gambar 2, proses *preprocessing* dimulai dengan resizing citra menjadi ukuran 224×224 piksel, dilanjutkan dengan peningkatan kontras menggunakan CLAHE, kemudian peningkatan ketajaman menggunakan *sharpening filter*. Setelah itu dilakukan evaluasi kualitas citra, normalisasi data, dan augmentasi data sebelum citra digunakan dalam proses pelatihan model.

3.2.1 Resizing Citra

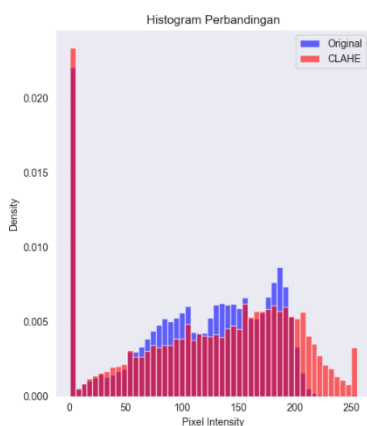
Seluruh citra X-ray dada dilakukan proses resizing menjadi 224×224 piksel agar sesuai dengan kebutuhan input pada arsitektur *EfficientNet-B0*. Proses resizing

dilakukan menggunakan fungsi `cv2.resize()` sehingga seluruh citra memiliki dimensi yang seragam dan kompatibel dengan model pre-trained. Selain untuk menyeragamkan ukuran input, `resizing` juga membantu mengurangi kompleksitas komputasi selama proses pelatihan berlangsung.

3.2.2 Peningkatan Kontras Menggunakan CLAHE

Setelah proses `resizing`, citra diproses menggunakan metode CLAHE untuk meningkatkan kontras lokal pada citra *X-ray* dada sehingga detail struktur paru-paru dapat terlihat lebih jelas. Pada penelitian ini digunakan parameter `clipLimit = 0,01` dan `tileGridSize = (8,8)`. Pemilihan parameter tersebut mengacu pada penelitian Buriboev et al. (2025), yang menunjukkan bahwa konfigurasi `tile 8x8` dan `contrast limit 0,01` mampu meningkatkan kontras citra secara efektif tanpa menyebabkan peningkatan *noise* dan artefak yang berlebihan pada citra medis [17]. Ukuran `tile 8x8` dipilih karena mampu menghasilkan peningkatan kontras lokal yang seimbang pada area paru-paru, sedangkan nilai `clipLimit 0,01` digunakan untuk membatasi amplifikasi histogram agar detail struktur tetap terjaga dan *noise* tidak meningkat secara berlebihan.

Perbandingan distribusi histogram intensitas piksel sebelum dan sesudah penerapan CLAHE ditunjukkan pada Gambar 3.




Gambar 3. Histogram Perbandingan

Gambar 3 menunjukkan bahwa histogram citra hasil CLAHE memiliki distribusi intensitas piksel yang lebih menyebar dibandingkan citra asli. Pada citra asli, distribusi histogram cenderung terkonsentrasi pada rentang intensitas tertentu sehingga menyebabkan kontras citra menjadi kurang optimal. Setelah CLAHE diterapkan, distribusi intensitas piksel menyebar ke rentang yang lebih luas serta puncak histogram yang sebelumnya terkonsentrasi pada intensitas tertentu menjadi lebih merata. Kondisi tersebut menunjukkan bahwa CLAHE mampu mengurangi dominasi piksel pada area dengan intensitas homogen dan meningkatkan perbedaan intensitas antar area lokal citra. Dengan penyebaran histogram yang lebih merata, detail struktur paru-paru dan area infiltrat menjadi lebih


jelas sehingga informasi visual pada citra lebih mudah dikenali oleh model *deep learning*.

Perbandingan visual citra *X-ray* dada sebelum dan sesudah penerapan CLAHE ditunjukkan pada Gambar 4.



Gambar 4. Perbandingan Citra Sebelum dan Sesudah CLAHE

Berdasarkan Gambar 4, citra hasil CLAHE menunjukkan peningkatan kontras lokal dibandingkan citra asli. Struktur tulang rusuk, batas paru-paru, dan area infiltrat terlihat lebih jelas setelah proses peningkatan kontras dilakukan. Peningkatan kualitas visual tersebut membantu memperjelas detail anatomi paru-paru sehingga model *deep learning* diharapkan mampu mengekstraksi fitur spasial secara lebih optimal.



Gambar 5. Original, CLAHE, Sharpening, dan CLAHE + Sharpening


Berdasarkan Gambar 5, citra hasil kombinasi CLAHE dan sharpening menunjukkan detail tepi paru-paru yang lebih tegas dibandingkan citra sebelum sharpening diterapkan. Struktur tulang rusuk dan pola jaringan paru-paru tampak lebih jelas sehingga pola infiltrat dan area abnormal pada paru-paru menjadi lebih mudah diamati. Peningkatan ketajaman tersebut diharapkan dapat membantu model dalam mengekstraksi fitur spasial secara lebih optimal.

3.2.4 Evaluasi Kualitas Citra

Untuk mengevaluasi pengaruh *preprocessing* terhadap kualitas citra, dilakukan pengukuran menggunakan metrik PSNR, SSIM, dan CII. Ketiga metrik tersebut digunakan untuk mengukur tingkat peningkatan kualitas citra setelah *preprocessing* diterapkan.

Tabel 9. Evaluasi Kualitas Citra Setelah *Preprocessing*

Metode	PSNR	SSIM	CII
Original	—	1.000	1.000
CLAHE	27.09	0.963	1.049
CLAHE + Sharpening	20.12	0.562	1.157




Gambar 6. Perbandingan Metrik Kualitas Citra

Berdasarkan Tabel 9 dan Gambar 6, metode CLAHE menghasilkan nilai PSNR dan SSIM yang lebih tinggi dibandingkan kombinasi CLAHE + sharpening, yang menunjukkan bahwa struktur citra masih sangat mirip dengan citra asli setelah proses peningkatan kontras dilakukan. Namun, kombinasi CLAHE dan sharpening menghasilkan nilai CII tertinggi sebesar 1,157, yang menunjukkan peningkatan kontras dan ketajaman citra yang lebih signifikan. Hasil ini menunjukkan bahwa kombinasi *preprocessing* mampu memperjelas detail struktur paru-paru sehingga citra menjadi lebih informatif untuk proses klasifikasi pneumonia.

3.2.5 Normalisasi dan Augmentasi Data

Setelah *preprocessing* citra selesai dilakukan, tahap berikutnya adalah normalisasi dan augmentasi data. Normalisasi dilakukan menggunakan fungsi *preprocess_input* dari *EfficientNet-B0* untuk menyesuaikan distribusi nilai piksel dengan standar pelatihan ImageNet. Proses ini membantu meningkatkan stabilitas pelatihan dan mempercepat konvergensi model.

Selain normalisasi, augmentasi data diterapkan pada data latih guna memperbanyak keragaman sampel serta membantu meminimalkan potensi *overfitting*. Pada penelitian ini, augmentasi dilakukan menggunakan parameter *rotation_range* sebesar 25°, *width_shift_range* sebesar 0,05, *height_shift_range* sebesar 0,05, *zoom_range* sebesar 0,05, *shear_range* sebesar 0,05, serta *horizontal_flip* bernilai *True*. Contoh hasil augmentasi data pada citra *X-ray* dada ditunjukkan pada Gambar 7.



Gambar 7. Contoh Hasil Augmentasi Data pada Citra *X-ray* Dada

Berdasarkan Gambar 7, augmentasi menghasilkan variasi posisi, orientasi, dan skala citra tanpa mengubah struktur anatomi utama paru-paru. Variasi tersebut membantu model dalam mempelajari pola pneumonia secara lebih robust terhadap variasi kondisi citra pada data nyata.

3.3 Penerapan *Transfer Learning EfficientNet-B0*

Penelitian ini menggunakan arsitektur *EfficientNet-B0* berbasis *Transfer Learning* dengan strategi full fine-tuning. Seluruh layer *EfficientNet-B0* diatur dalam kondisi trainable sehingga bobot model dapat diperbarui secara optimal selama proses pelatihan. Pendekatan ini memungkinkan model menyesuaikan representasi fitur dengan karakteristik citra *X-ray* dada

3.3.1 Arsitektur Model

Model dibangun menggunakan *EfficientNet-B0* dengan bobot awal ImageNet dan parameter *include_top=False*. Pada bagian akhir model ditambahkan layer *GlobalMaxPooling2D*, *Batch Normalization*, *Dense layer* sebanyak 256 neuron, *Dropout* sebesar 0,45, dan *output layer Softmax* untuk klasifikasi dua kelas. Arsitektur model *EfficientNet-B0* ditunjukkan pada Gambar 8, sedangkan konfigurasi lengkap model disajikan pada Tabel 10.

Layer (type)	Output Shape	Param #
lambda (Lambda)	(None, 224, 224, 3)	0
efficientnetb0 (Functional)	(None, 1280)	4,049,571
batch_normalization (BatchNormalization)	(None, 1280)	5,120
dense (Dense)	(None, 256)	327,936
dropout (Dropout)	(None, 256)	0
dense_1 (Dense)	(None, 2)	514

Total params: 4,383,141 (16.72 MB)

Trainable params: 4,338,558 (16.55 MB)

Non-trainable params: 44,583 (174.16 KB)

Gambar 8. Arsitektur Model *EfficientNet-B0*

Tabel 10. Konfigurasi Arsitektur Model

Layer (type)	Output Shape	Param #
lambda (Lambda)	(None, 224, 224, 3)	0
efficientnetb0 (Functional)	(None, 1280)	4,049,571
batch_normalization (BatchNormalization)	(None, 1280)	5,120
dense (Dense)	(None, 256)	327,936
dropout (Dropout)	(None, 256)	0
dense_1 (Dense)	(None, 2)	514

Berdasarkan Tabel 10, total parameter model mencapai sekitar 4,3 juta parameter dengan sebagian besar parameter berada pada kondisi *trainable*. Pendekatan *full fine-tuning* memungkinkan model menyesuaikan fitur yang dipelajari terhadap karakteristik citra medis secara lebih optimal.


3.3.2 Proses Pelatihan Model

Model dilatih menggunakan optimizer Adamax dengan learning rate sebesar 0,001, batch size 16, dan maksimum epoch sebanyak 50. Selain itu, diterapkan mekanisme EarlyStopping dengan patience sebesar 5 untuk mencegah *overfitting*.

Tabel 11. Perkembangan Nilai Training dan Validation

Epoch	Training Accuracy	Validation Accuracy	Training Loss	Validation Loss
1	0.7726	0.7287	6.9994	4.8915
5	0.8034	0.9386	1.2210	0.9996
10	0.8589	0.9505	0.5135	0.4268
15	0.8809	0.9710	0.4224	0.3202
20	0.9110	0.9505	0.3560	0.2832
24	0.9033	0.9744	0.3575	0.2389
29	0.9295	0.9317	0.3046	0.3099

Gambar 9 menunjukkan grafik perkembangan nilai loss dan accuracy pada data latih dan data validasi selama proses pelatihan.




Gambar 9. Grafik Training dan Validation Accuracy serta Loss

Berdasarkan Gambar 9, nilai training loss dan validation loss mengalami penurunan secara bertahap selama proses pelatihan berlangsung. Validation accuracy mencapai nilai tertinggi sebesar 97,44% pada epoch ke-24 sebelum mengalami fluktuasi ringan pada epoch berikutnya. Kurva training dan validation menunjukkan pola yang stabil tanpa gap yang signifikan sehingga model tidak mengalami *overfitting* yang berlebihan.

3.4 Hasil Evaluasi Model

Setelah tahap pelatihan selesai, performa model diuji menggunakan data testing untuk mengetahui kemampuan model dalam melakukan generalisasi terhadap data baru yang belum pernah digunakan sebelumnya. Penilaian kinerja model dilakukan melalui metrik *accuracy*, *precision*, *recall*, dan *F1-score*.



Gambar 10. Confusion Matrix Data Uji

Berdasarkan *Confusion Matrix* pada Gambar 10, sebagian besar citra berhasil diklasifikasikan dengan benar pada kedua kelas. Pada kelas Pneumonia, model hanya menghasilkan sedikit *false negative* sehingga kemampuan deteksi kasus pneumonia tergolong sangat baik.

Tabel 12. Hasil Evaluasi Kinerja Model pada Data Uji

Kelas	Precision	Recall	F1-Score	Support
Normal	0,9800	0,9300	0,9500	158
Pneumonia	0,9700	0,9900	0,9800	428
Accuracy			0,9761	586
Macro Avg	0,9800	0,9600	0,9700	586
Weighted Avg	0,9800	0,9800	0,9800	586

Berdasarkan Tabel 12, model dengan kombinasi CLAHE dan *sharpening filter* pada skenario pembagian data 80:10:10 menghasilkan performa terbaik dengan *accuracy* sebesar 97,61%, *precision* sebesar 0,97, *recall* sebesar 0,99, dan *F1-score* sebesar 0,98 pada kelas *Pneumonia*. Tingginya nilai *recall* menunjukkan bahwa hampir seluruh kasus pneumonia berhasil terdeteksi oleh model. Selain itu, nilai *precision* yang tinggi menunjukkan bahwa prediksi positif yang dihasilkan model sebagian besar merupakan kasus pneumonia yang benar.

3.5 Perbandingan Metode Peningkatan Citra

Pada tahap ini dilakukan analisis terhadap pengaruh metode *preprocessing* terhadap performa model *EfficientNet-B0*. Tiga skenario *preprocessing* yang dibandingkan meliputi model *Baseline* tanpa *preprocessing*, model dengan CLAHE, dan model dengan kombinasi CLAHE dan *sharpening filter* sebagai metode usulan. Setiap eksperimen dijalankan dengan konfigurasi pelatihan yang identik pada skenario pembagian data 80:10:10 sehingga perbedaan performa yang diperoleh sepenuhnya dipengaruhi oleh metode *preprocessing* yang diterapkan.

Tabel 13. Perbandingan Metode Peningkatan Citra

Metode	Loss	Accuracy	Precision (Pneumonia)	Recall (Pneumonia)	F1-Score (Pneumonia)
Baseline	0,13	97,10 %	0,99	0,97	0,97
CLAE	0,15	97,44 %	0,99	0,97	0,98
Proposed	0,17	97,61 %	0,97	0,99	0,98

Berdasarkan Tabel 13, seluruh metode menghasilkan performa klasifikasi yang tinggi dengan *accuracy* di atas 97%. Model *Baseline* menghasilkan *accuracy* sebesar 97,10%, sedangkan penerapan CLAHE meningkatkan *accuracy* menjadi 97,44%. Peningkatan tersebut menunjukkan bahwa peningkatan kontras citra membantu model dalam mengenali pola pneumonia pada citra X-ray dada.

Metode usulan berupa kombinasi CLAHE dan *sharpening filter* menghasilkan accuracy tertinggi sebesar 97,61% dengan recall sebesar 0,99 pada kelas Pneumonia. Hasil tersebut menunjukkan bahwa kombinasi peningkatan kontras dan ketajaman citra mampu membantu model mengekstraksi fitur visual secara lebih optimal. Selain meningkatkan accuracy, metode usulan juga menghasilkan jumlah *false negative* yang lebih rendah dibandingkan metode lainnya sehingga kemampuan deteksi pneumonia menjadi lebih baik.


3.6 Perbandingan Skenario Pembagian Data

Selain pengaruh *preprocessing*, penelitian ini juga menganalisis pengaruh variasi pembagian data terhadap performa model klasifikasi pneumonia. Tiga skenario pembagian data yang digunakan meliputi 70:10:20, 80:10:10, dan 90:5:5 untuk data latih, validasi, dan data uji.

Tabel 14. Perbandingan Performa Berdasarkan Skenario Pembagian Data

Split	Loss	Accuracy	Precision (Pneumonia)	Recall (Pneumonia)	F1-Score (Pneumonia)
70:10:20	0,2276	97,27%	0,97	0,99	0,98
80:10:10	0,1784	97,61%	0,97	0,99	0,98
90:5:5	0,1607	96,93%	0,98	0,98	0,98

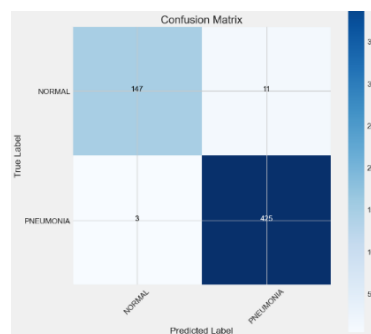
Berdasarkan Tabel 14, seluruh skenario pembagian data menghasilkan performa klasifikasi yang tinggi dengan akurasi di atas 96%. Namun demikian, terdapat perbedaan performa antar skenario yang menunjukkan pengaruh proporsi data latih dan data uji terhadap kemampuan model dalam melakukan generalisasi.



Gambar 11. Confusion Matrix Skenario 70:10:20


Pada skenario 70:10:20, model memperoleh akurasi sebesar 97,27% dengan nilai *recall* kelas Pneumonia sebesar 0,99. Berdasarkan *Confusion Matrix* pada Gambar 4.10, dari total 855 citra Pneumonia pada data uji, sebanyak 845 citra berhasil diklasifikasikan dengan benar dan 10 citra salah diprediksi sebagai Normal. Pada kelas Normal, 295 dari 317 citra dikenali dengan benar, sedangkan 22 citra salah diklasifikasikan sebagai Pneumonia. Jumlah kesalahan yang relatif kecil pada kedua kelas menunjukkan bahwa model

mampu melakukan klasifikasi dengan baik pada konfigurasi ini.



Gambar 12. Confusion Matrix Skenario 80:10:10

Pada skenario 80:10:10, model mencapai akurasi tertinggi sebesar 97,61% dengan nilai loss yang lebih rendah dibandingkan skenario lainnya. Berdasarkan Gambar 12, dari 428 citra Pneumonia pada data uji, sebanyak 425 citra dapat diklasifikasikan secara benar dan hanya 3 citra salah diprediksi sebagai Normal. Pada kelas Normal, 147 dari 158 citra dikenali dengan tepat, sedangkan 11 citra salah diprediksi sebagai Pneumonia. Jumlah *false negative* yang sangat kecil menunjukkan kemampuan deteksi kasus pneumonia yang sangat baik. Nilai recall sebesar 0,99 mengindikasikan bahwa hampir seluruh kasus positif berhasil teridentifikasi.



Gambar 13. Confusion Matrix Skenario 90:5:5

Pada skenario 90:5:5, model memperoleh akurasi sebesar 96,93% pada data uji. Berdasarkan Gambar 13, dari total 214 citra Pneumonia, sebanyak 210 citra diklasifikasikan secara benar dan 4 citra salah diprediksi sebagai Normal, sedangkan pada kelas Normal, 74 dari 79 citra dikenali dengan tepat dan 5 citra salah diprediksi sebagai Pneumonia. Jumlah *false negative* yang relatif kecil menunjukkan bahwa kemampuan model dalam mendeteksi kasus Pneumonia tetap sangat baik dengan nilai recall sebesar 0,98. Meskipun akurasi pada skenario ini sedikit lebih rendah dibandingkan skenario 80:10:10, performa klasifikasi secara keseluruhan tetap tinggi, namun ukuran data uji yang lebih kecil membuat hasil evaluasi menjadi lebih sensitif terhadap setiap kesalahan prediksi.

Selain itu, ukuran data uji pada skenario 90:5:5 relatif lebih kecil dibandingkan skenario lainnya sehingga hasil evaluasi menjadi lebih sensitif terhadap kesalahan prediksi. Jika dianalisis secara keseluruhan, model

menunjukkan tingkat kesalahan yang lebih tinggi pada kelas Normal dibandingkan kelas Pneumonia pada seluruh skenario pembagian data. Kondisi tersebut kemungkinan dipengaruhi oleh distribusi dataset yang tidak seimbang, di mana jumlah citra Pneumonia lebih dominan dibandingkan citra Normal.

Secara keseluruhan, hasil eksperimen menunjukkan bahwa skenario pembagian data 80:10:10 memberikan keseimbangan yang paling optimal antara jumlah data latih dan data uji. Skenario ini menghasilkan *accuracy* tertinggi, nilai loss yang lebih rendah, serta jumlah kesalahan klasifikasi yang lebih sedikit dibandingkan skenario lainnya. Oleh karena itu, konfigurasi pembagian data 80:10:10 dipilih sebagai skenario terbaik pada penelitian ini.

3.7 Uji Signifikansi Statistik

Penelitian ini menerapkan McNemar's Test untuk menganalisis apakah perbedaan performa antar model memiliki signifikansi secara statistik. Pengujian dilakukan terhadap model *Baseline*, model dengan CLAHE, dan model usulan menggunakan kombinasi CLAHE dan *sharpening filter*.

Tabel 15. Hasil Uji McNemar

Perbandingan Model	b	c	χ^2	p-value	Keterangan
Baseline vs CLAHE	0	2	0.50	0.48	Tidak signifikan
Baseline vs Proposed	3	0	1.33	0.25	Tidak signifikan
CLAHE vs Proposed	1	0	0.00	1.00	Tidak signifikan

Berdasarkan hasil pengujian, seluruh perbandingan model menghasilkan nilai *p-value* melebihi 0,05 sehingga perbedaannya tidak signifikan secara statistik antar model yang dibandingkan. Meskipun demikian, secara empiris model dengan kombinasi CLAHE dan *sharpening filter* tetap menunjukkan performa terbaik dengan *accuracy* sebesar 97,61% dan *recall* yang lebih tinggi pada kelas Pneumonia.

Hasil tersebut menunjukkan bahwa peningkatan kualitas citra melalui CLAHE dan *sharpening filter* tetap memberikan kontribusi positif terhadap kemampuan model dalam mengidentifikasi pola pneumonia pada citra X-ray dada.

4. Kesimpulan

Berdasarkan hasil penelitian, penerapan teknik CLAHE dan *sharpening filter* mampu meningkatkan performa model *EfficientNet-B0* berbasis *Transfer Learning* dalam klasifikasi pneumonia pada citra X-ray dada. Model *Baseline* menghasilkan *accuracy* sebesar 97,10%, sedangkan penggunaan CLAHE meningkatkan *accuracy* menjadi 97,44%. Kombinasi CLAHE dan *sharpening filter* memberikan performa terbaik dengan *accuracy* sebesar 97,61%, *precision* sebesar 0,97, *recall* sebesar 0,99, dan *F1-score* sebesar 0,98 pada kelas *Pneumonia*. Selain meningkatkan performa klasifikasi, *preprocessing* menggunakan

CLAHE dan *sharpening filter* juga terbukti mampu meningkatkan kualitas visual citra secara objektif berdasarkan evaluasi menggunakan PSNR, SSIM, dan CII. Nilai SSIM yang tinggi menunjukkan bahwa struktur penting pada citra paru-paru tetap terjaga setelah *preprocessing*, sedangkan peningkatan nilai CII menunjukkan bahwa kontras dan ketajaman citra menjadi lebih baik sehingga detail jaringan paru-paru dan area infiltrat lebih mudah dikenali oleh model. Hasil tersebut menunjukkan bahwa peningkatan kualitas citra melalui peningkatan kontras dan ketajaman mampu membantu model dalam mengekstraksi fitur visual secara lebih optimal sehingga kemampuan deteksi pneumonia menjadi lebih baik.

Selain itu, hasil evaluasi menunjukkan bahwa skenario pembagian data 80:10:10 memberikan performa paling optimal dibandingkan skenario lainnya. Meskipun demikian, berdasarkan hasil uji *McNemar*, peningkatan performa antar model belum menunjukkan perbedaan yang signifikan secara statistik. Penelitian selanjutnya dapat dikembangkan dengan menerapkan teknik penanganan ketidakseimbangan data, segmentasi paru-paru, penggunaan dataset eksternal, serta integrasi metode *Explainable Artificial Intelligence (XAI)* untuk meningkatkan kemampuan generalisasi dan interpretabilitas model.

Ucapan Terimakasih

Penulis mengucapkan terima kasih kepada Universitas Muhammadiyah Riau dan Program Studi Teknik Informatika atas dukungan fasilitas penelitian yang diberikan selama pelaksanaan penelitian ini.

Daftar Rujukan

- [1] P. W. Dwiyantri and D. Hisni, "Analisis Asuhan Keperawatan melalui Intervensi Kolaborasi Pemberian Nebulizer dan Batuk Efektif pada Pasien Ny.P dan Tn.W dengan Diagnosa Medis Pneumonia di Wilayah RS DKI Jakarta," *Jurnal Kreativitas Pengabdian Kepada Masyarakat (PKM)*, vol. 7, no. 4, pp. 1654–1665, Apr. 2024, doi: 10.33024/jkpm.v7i4.13837.
- [2] A. Safitri, N. P. Alya, S. Salsabila N, H. Fauzi, and J. Ariyanto, "Kematian Anak akibat Pneumonia : Tinjauan Literatur tentang Peran Deteksi Dini dan Intervensi Medis," *GALENICAL: Jurnal Kedokteran dan Kesehatan Mahasiswa Malikussaleh*, vol. 4, no. 4, pp. 55–67, 2025.
- [3] Kemenkes RI, *Profil Kesehatan Indonesia*. Jakarta: Kementerian Kesehatan Republik Indonesia, 2023.
- [4] I. Kurniawati, R. Akbar, Y. Ardina Kusuma, and I. Fahma Kusumawati, "Identifikasi Pneumonia pada Balita melalui Citra X-ray Menggunakan Metode Convolutional Neural Network (CNN)," *Journal of Manufacturing in Industrial Engineering & Technology*, vol. 3, no. 1, pp. 10–23, Jun. 2024, doi: 10.30651/mine-tech.v3i1.23391.
- [5] S. A. Adzkie and T. Arifin, "Perbandingan Arsitektur CNN Berbasis Transfer Learning untuk Klasifikasi pada BreastMNIST," *Jurnal Nasional Teknologi dan Sistem Informasi*, vol. 11, no. 2, pp. 192–200, Sep. 2025, doi: 10.25077/teknosi.v11i2.2025.192-200.
- [6] R. K. Pasha and K. Budiman, "Optimasi Model CNN Berbasis Transfer Learning Untuk Klasifikasi Pneumonia pada Citra X-Ray Dada," *SMATIKA JURNAL*, vol. 15, no. 01, pp. 167–178, Jun. 2025, doi: 10.32664/smatika.v15i01.1985.

- [7] N. Sebastian and B. Ankayarkanni, "Enhanced ResNet-50 with Multi-Feature Fusion for Robust Detection of Pneumonia in Chest X-Ray Images," *Diagnostics*, vol. 15, no. 16, pp. 1–23, Aug. 2025, doi: 10.3390/diagnostics15162041.
- [8] L. Li, Z. Tan, and X. Han, "An Improved EfficientNet Model and its Applications in Pneumonia Image Classification," *Journal of Engineering Science and Technology Review*, vol. 15, no. 6, pp. 49–54, 2022, doi: 10.25103/jestr.156.07.
- [9] M. A. Anwar, Y. A. Gerhana, and U. Syaripudin, "Implementasi Model CNN ResNet50V2 untuk Klasifikasi Pneumonia pada Citra X-Ray," *SMATIKA JURNAL*, vol. 15, no. 01, pp. 126–135, Jun. 2025, doi: 10.32664/smatika.v15i01.1538.
- [10] A. D. Azzumzumi, M. Hanafi, and W. M. P. Duhita, "Klasifikasi Penyakit Paru-Paru Berdasarkan Peningkatan Kualitas Kontras dan EfficientNet Menggunakan Gambar X-Ray," *Teknika*, vol. 13, no. 2, pp. 293–300, Jul. 2024, doi: 10.34148/teknika.v13i2.881.
- [11] D. Rizki Chandranegara, V. Dwi Vitanti, W. Suharso, H. Wibowo, and S. Arifianto, "Analysis of Pneumonia on Chest X-Ray Images Using Convolutional Neural Network Model ResNet-RS," *International Journal of Informatics Visualization*, vol. 8, no. 1, pp. 183–189, 2024, [Online]. Available: www.joiv.org/index.php/joiv
- [12] K. U. Ahamed *et al.*, "A deep learning approach using effective preprocessing techniques to detect COVID-19 from chest CT-scan and X-ray images," *Comput. Biol. Med.*, vol. 139, Dec. 2021, doi: 10.1016/j.combiomed.2021.105014.
- [13] M. A. Fadila, B. Irawan, A. Faqih, R. D. Dana, and A. R. Renaldi, "Analisis Korelasi Restorasi Visual Dan Performa Klasifikasi Metode Image Sharpening Pada Daun Tomat," *JOURNAL OF COMPUTER SCIENCE AND ARTIFICIAL INTELLIGENCE (JCSAI)*, vol. 01, no. 03, 2026, [Online]. Available: <https://ikmi.ac.id/page/18/?lang=de>
- [14] G. A. Sandag, T. J. Mulalinda, G. A. M. Susanto, and S. R. Pungus, "Advanced pneumonia classification using transfer learning on chest X-ray data with EfficientNet and ResNet," *TELKOMNIKA (Telecommunication Computing Electronics and Control)*, vol. 23, no. 5, p. 1304, Oct. 2025, doi: 10.12928/telkomnika.v23i5.26387.
- [15] Khairudin, Bobi Agustian, and B. Nursakinah, "Klasifikasi Citra Medis Penyakit Pneumonia dengan Metode Convolutional Neural Network," *Bulletin of Computer Science Research*, vol. 5, no. 4, pp. 763–769, Jun. 2025, doi: 10.47065/bulletincsr.v5i4.576.
- [16] M. Nur Halizah, S. Najla, S. Amala Putri, N. Febita, M. Luthfi Hidayat, and M. Surakarta Abstrak, "Perbandingan Kinerja Artificial Neural Network Random Forest dan LightGBM dalam Prediksi Penyakit Jantung Menggunakan Dataset Kaggle," *Jurnal Ilmiah Wahana Pendidikan*, vol. 12, no. C, pp. 196–209, 2026.
- [17] A. Shavkatovich Buriboev, A. Abduvaitov, and H. S. Jeon, "Binary Classification of Pneumonia in Chest X-Ray Images Using Modified Contrast-Limited Adaptive Histogram Equalization Algorithm," *Sensors*, vol. 25, no. 13, Jul. 2025, doi: 10.3390/s25133976.