

Deteksi Kanker Paru-Paru pada Citra X-Ray Berbasis *Visual Recognition* dan *Preprocessing* Stabilisasi Kanal L

¹Anisah Nabilah, ²Nikko Riestian Putra Wardoyo

³Mochamad Fadillah Abdullah, ⁴Muhammad Mursyid

^{1*,2,3,4} Informatika, Fakultas Ilmu Komputer, Universitas PGRI Jombang, Jombang, Indonesia

*Korespondensi: anisah11nabilah@gmail.com

Submit : 08 Jul 2026 | Diterima : 08 Sept 2026 | Terbit : 17 Sept 2026

ABSTRACT

Chest X-ray images are the most widely used screening modality for lung disorders due to their relatively affordable cost, but their diagnostic value is often hampered by low contrast, noise, and anatomical structures such as ribs that obscure nodules in the early stages. This study aims to analyze the effect of L-channel stabilization Preprocessing techniques using Contrast Limited Adaptive Histogram Equalization (CLAHE) on the performance of Convolutional Neural Network (CNN) models in detecting lung cancer in chest X-ray images. Unlike the common approach that applies CLAHE directly to grayscale or RGB images, this study separates the Lightness (L) channel from the LAB color space so that contrast enhancement is performed independently of color information, in order to minimize unwanted distortion. The dataset used is 1,726 chest X-ray images with specifications based on classes of 1,491 for the number of lung X-ray image classes with the cancer category, 235 for the normal category. In splitting the data into train, validation, and test using a ratio of 80:10:10, then trained using three pre-trained CNN architectures namely VGG16, ResNet50, and MobileNetV2 through a transfer learning approach with Adam optimizer, categorical cross-entropy loss function, and early stopping technique. Evaluation was carried out using accuracy, precision, recall, and F1-score metrics. The results showed that VGG16 obtained the highest and most balanced performance with an accuracy of 94.2%, the ResNet50 architecture had an accuracy of 93.0% and MobileNetV2 91.5. This study shows that L-channel-based CLAHE stabilization is able to improve image contrast with minimal distortion and contributes to reliable CNN-based lung cancer detection.

Keywords: Chest X-Ray, CLAHE, Convolutional Neural Network, Lung Cancer Detection, Stabilization of L Channel.

ABSTRAK

Citra X-Ray dada merupakan modalitas skrining kelainan paru-paru yang paling banyak digunakan karena biaya yang relatif terjangkau, namun nilai diagnostiknya sering terkendala oleh kontras yang rendah, noise, dan struktur anatomi seperti tulang rusuk yang menyamarkan nodul pada tahap awal. Penelitian ini bertujuan untuk menganalisis pengaruh teknik *Preprocessing* berbasis stabilisasi kanal L menggunakan *Contrast Limited Adaptive Histogram Equalization (CLAHE)* terhadap performa model *Convolutional Neural Network (CNN)* dalam mendeteksi kanker paru-paru pada citra X-Ray dada. Berbeda dengan pendekatan umum yang menerapkan CLAHE langsung pada citra grayscale atau RGB, penelitian ini memisahkan kanal Lightness (L) dari ruang warna LAB sehingga peningkatan kontras dilakukan secara independen dari informasi warna, guna meminimalkan distorsi yang tidak diinginkan. Dataset yang digunakan berjumlah 1.726 citra X-Ray dada dengan spesifikasi berdasarkan kelas sejumlah 1.491 untuk jumlah kelas citra x-ray paru-paru dengan katagori cancer, 235 katagori normal. Dalam split data menjadi train, validation, dan test menggunakan rasio 80:10:10, kemudian dilatih menggunakan tiga arsitektur CNN pre-trained yaitu VGG16, ResNet50, dan MobileNetV2 melalui pendekatan transfer learning dengan optimizer Adam, fungsi loss categorical cross-entropy, dan teknik early stopping. Evaluasi dilakukan menggunakan metrik akurasi, precision, recall, dan F1-score. Hasil penelitian menunjukkan bahwa VGG16 memperoleh performa tertinggi dan paling seimbang dengan akurasi 94,2%, arsitektur ResNet50 memiliki akurasi 93,0% dan MobileNetV2 91,5. Penelitian ini menunjukkan bahwa stabilisasi CLAHE berbasis kanal L mampu memperbaiki kontras citra dengan distorsi minimal dan berkontribusi pada deteksi kanker paru-paru berbasis CNN yang andal.

Kata Kunci: *Chest X-Ray, CLAHE, Convolutional Neural Network, Lung Cancer Detection, Stabilisasi Kanal L.*

PENDAHULUAN

Citra X-Ray dada merupakan salah hasil pemeriksaan medis menggunakan sinar radiografi memiliki jumlah dataset yang paling banyak digunakan dalam skrining kelainan pada organ paru-paru, banyak dimanfaatkan untuk mendeteksi indikasi awal kanker paru-paru karena biaya pemeriksaan yang relatif terjangkau (Yoon et al., 2025) (Shimazaki et al., 2022). Permasalahan yang muncul pada citra X-Ray memiliki kualitas citra yang susah dianalisis, baik secara visual oleh manusia maupun secara komputasional oleh sistem otomatis. Salah satu permasalahan utama adalah rendahnya kontras citra, yang disebabkan oleh prinsip kerja sinar-X merepresentasikan kepadatan jaringan dalam rentang nilai *grayscale* sempit. Hal ini menyebabkan perbedaan intensitas antara jaringan paru normal dengan jaringan abnormal seperti mendeteksi nodul atau massa tumor seringkali kurang optimal karena gambar tampak sangat tipis dan sulit dibedakan, terutama pada tahap awal pertumbuhan kanker ketika ukuran lesi masih kecil (Megat Ramli et al., 2025). Selain kontras yang rendah, citra X-Ray memiliki noise yang muncul akibat faktor teknis selama proses akuisisi citra, seperti pengaturan dosis radiasi, kualitas sensor detektor, maupun kondisi alat pencitraan yang berbeda-beda antar fasilitas kesehatan. Noise pada citra akan mengaburkan detail-detail halus yang menyebabkan tersamarnya visual citra yang susah untuk dideteksi (Yadav et al., 2025). Selain terkait permasalahan kontras citra X-Ray, tantangan yang muncul pada citra adalah adanya overlapping dikarenakan struktur anatomi paru-paru yang terlindungi oleh tulang rusuk, sehingga dalam pendeteksian nodul di area paru-paru jadi terhalang. Apabila citra dengan kualitas kejelasan terhadap objek yang masih belum terlihat jelas dilakukan proses training tanpa adanya tahap perbaikan kualitas terlebih dahulu, mengakibatkan model hasil training yang dihasilkan berisiko mempelajari fitur yang kurang representatif, yang berdampak pada menurunnya akurasi dan keandalan sistem deteksi yang dibangun.

Perkembangan teknologi pada era sekarang banyak penelitian yang mengembangkan teknologi menggunakan machine learning dan deep learning, menjadi salah satu solusi untuk membangun sistem deteksi otomatis yang dapat membantu tenaga medis dalam proses diagnosis khususnya pada penyakit kanker paru-paru (Javed et al., 2024). Beberapa penelitian yang telah dilakukan sebelumnya mengembangkan pendeteksian kanker paru-paru dengan pendekatan deep learning yakni menggunakan metode Convolutional Neural Network dan teknik *Preprocessing* berbasis peningkatan kontras untuk deteksi kanker paru-paru, namun sebagian besar masih menerapkan CLAHE secara langsung pada citra grayscale atau seluruh kanal warna sekaligus, tanpa memisahkan komponen kecerahan dari informasi warna.

Studi berikutnya yang mengevaluasi arsitektur VGG16 pada tugas klasifikasi kanker paru-paru melaporkan akurasi sebesar 92,96% pada data uji independen. Meskipun menggunakan arsitektur yang sama dengan salah satu model dalam penelitian ini, hasil tersebut masih berada di bawah akurasi VGG16 yang dicapai melalui pendekatan *Preprocessing* CLAHE berbasis kanal L pada penelitian ini (94,2%) (Sarker et al., 2024).

Penelitian yang dilakukan oleh Xu, Yu et al., dalam pengembangan model CNN berbasis VGG16 untuk skrining kanker paru-paru dari citra CT, melaporkan akurasi klasifikasi sebesar 91,7% dengan sensitivitas 77,6%. Studi menggunakan teknik augmentasi data random resizing, cropping, horizontal flipping, color jitter, random rotation and normalization (Xu et al., 2024).

Selanjutnya penelitian yang dilakukan oleh Aaseegha, M. D., & Venkataramana, B pada tahun 2026 menggunakan Model yang menggabungkan multi-scale feature fusion dengan channel dan spatial attention ini mengungguli CNN standar serta VGG16 dan ResNet50, mencapai akurasi 98,12% (precision 98,17%, recall 98,12%, F1-score 98,13%), dengan kesalahan klasifikasi minimal terutama pada nodul malignant. Peta atensi juga meningkatkan interpretabilitas dengan menyoroti area yang relevan secara klinis (M. D & B, 2026).

Pada tahun 2026 kembali terdapat penelitian penelitian yang mengintegrasikan CLAHE pada tahap *Preprocessing* untuk klasifikasi citra X-Ray dada multi-kelas menggunakan EfficientNetB0, melaporkan AUC rata-rata sebesar 0,906 dan recall 0,824, mengungguli DenseNet121 dan MobileNetV2. Studi ini juga menerapkan CLAHE secara umum tanpa memisahkan kanal kecerahan dari informasi warna, sehingga peningkatan kontras berpotensi disertai distorsi warna yang tidak diinginkan (Hegazy & Sawah, 2026).


Convolutional Neural Network (CNN) menjadi salah satu arsitektur deep learning yang paling banyak diadopsi dalam tugas klasifikasi dan deteksi citra medis karena kemampuannya mengekstraksi fitur secara hierarkis langsung dari data citra tanpa memerlukan proses ekstraksi fitur manual (Mienye et al., 2025) (Chen et al., 2025). Namun, karena citra X-Ray memiliki kualitas citra yang masih perlu adanya tahap *Preprocessing* yang tepat, kontras rendah, noise, dan overlapping struktur anatomi pada citra X-Ray dapat menjadi penghalang signifikan bagi model dalam mempelajari pola-pola pembeda antara jaringan normal dan abnormal.

Untuk mengatasi permasalahan tersebut, tahap *Preprocessing* citra menjadi langkah terpenting sebelum data dilatih menggunakan model CNN (Buriboev et al., 2024). Salah satu teknik *Preprocessing* yang terbukti efektif dalam meningkatkan kualitas citra medis adalah Contrast Limited Adaptive Histogram Equalization (CLAHE). Berbeda dengan metode histogram equalization konvensional yang dapat menyebabkan over-enhancement dan amplifikasi noise pada area homogen, CLAHE bekerja secara adaptif dengan membatasi tingkat kontras pada setiap region kecil citra, sehingga mampu meningkatkan visibilitas detail lokal tanpa menurunkan kualitas citra secara keseluruhan. Dalam penelitian ini, penerapan CLAHE dilakukan secara spesifik dan terfokus pada kanal L atau Lightness dari ruang warna LAB (Saifullah & Dreżewski, 2024). Pendekatan ini dipilih karena kanal L merepresentasikan informasi pencahayaan dan kontras citra secara independen dari informasi warna yakni kanal A dan B, pendekatan serupa pada citra medis lain menunjukkan bahwa penerapan enhancement secara selektif pada kanal lightness ruang warna LAB mampu memperbaiki kontras sekaligus mempertahankan fidelitas color fidelity, dibandingkan enhancement konvensional yang diterapkan pada seluruh kanal sekaligus (Anupama et al., 2025). Sehingga stabilisasi pada kanal L diharapkan dapat memperbaiki kontras citra X-Ray secara lebih presisi tanpa menimbulkan distorsi yang tidak diinginkan, yang pada akhirnya dapat meningkatkan kemampuan model CNN dalam mengenali pola-pola abnormal pada citra.

Penelitian ini bertujuan untuk menganalisis pengaruh *Preprocessing* berbasis stabilisasi kanal L menggunakan metode CLAHE terhadap performa model Convolutional Neural Network untuk mendeteksi kanker paru-paru pada citra X-Ray. Penelitian ini diharapkan dapat memberikan kontribusi mengenai efektivitas teknik *Preprocessing* yang terfokus pada kanal L dalam meningkatkan akurasi deteksi.

METODE PENELITIAN

Penelitian ini bertujuan untuk mendeteksi kanker paru-paru pada citra X-Ray, menggunakan dataset X-Ray dada yang diperoleh dari National Institutes of Health Chest X-Ray Dataset. Terdapat tantangan dalam pengolahan citra X-Ray yakni terkait citra asli yang masih memiliki noise tinggi, dan juga komposisi kontras yang belum stabil, maka dari itu digunakan teknik preprocessing dengan pendekatan CLAHE untuk memperbaiki kontras dengan fokus memperbaiki pada kanal L. Selanjutnya citra akan dilakukan proses training untuk penentuan klasifikasi keadaan paru-paru terdiagnosis kanker dan normal. Pendekatan yang digunakan untuk training dataset X-Ray dada menggunakan Convolutional Neural Network, diproses dengan tiga arsitektur untuk mendapatkan hasil yang terbaik yakni VGG16, ResNet50, dan MobileNetV2. Dan Tahap terakhir dari penelitian adalah evaluasi model hasil training dilakukan dengan menghitung tingkat akurasi, tingkat kesalahan (error rate), presisi, sensitivitas, spesifisitas dan skor F1. (Lakshmi G & Nagaraj, 2025), pada gambar 1 menunjukkan diagram desain sistem dari penelitian yang dilakukan.




Gambar 1. Diagram Desain Sistem
Sumber : Penulis (2026)

Data Preparation

Dataset yang digunakan dalam penelitian ini terdiri atas citra X-Ray dada dengan dua kelas label, yaitu normal dan cancer. Dataset dibagi menjadi tiga subset, yakni data train sebanyak 1.208 citra, data validation sebanyak 259 citra, dan data test sebanyak 259 citra. Pada gambar 2 menunjukkan diagram pembagian dataset. Pembagian dataset ke dalam train, validation, dan test set ini menggunakan standar dalam pengembangan model deep learning untuk klasifikasi citra medis, di mana data validation digunakan untuk memantau performa model dan melakukan tuning hyperparameter selama training mencegah overfitting, sementara data test digunakan untuk mengevaluasi generalisasi model pada data yang belum pernah dilihat sebelumnya.

Proses pelabelan dilakukan secara manual berdasarkan diagnosis ground truth yang tersedia pada sumber dataset, mengelompokkan setiap citra ke dalam kelas normal atau cancer. Pendekatan supervised learning ini sejalan dengan sebagian besar penelitian klasifikasi citra medis berbasis CNN, yang membutuhkan label kelas eksplisit untuk proses pelatihan model.



Gambar 2. Distribusi Dataset

Sumber : Data Primer Penelitian, diolah oleh penulis(2026)

Preprocessing Citra : CLAHE Berbasis Stabilitas Kanal L

Tahap *Preprocessing* pada penelitian ini menjadi titik fokus dan kontribusi utama, yaitu penerapan *Contrast Limited Adaptive Histogram Equalization (CLAHE)* yang dimodifikasi agar hanya bekerja pada kanal L (Lightness) dari ruang warna LAB, alih-alih diterapkan secara langsung pada citra grayscale atau seluruh kanal warna sekaligus sebagaimana umum dilakukan pada penelitian-penelitian sebelumnya.

Secara teknis, prosedur *Preprocessing* dilakukan melalui tahapan berikut:

Citra X-Ray asli umumnya grayscale atau RGB, lalu dikonversi ke ruang warna LAB, yang memisahkan informasi kontras atau kanal L dari informasi kanal A dan B. CLAHE diterapkan secara eksklusif pada kanal L. CLAHE bekerja dengan membagi citra ke dalam beberapa region tile, kemudian melakukan histogram equalization secara lokal pada masing-masing tile dengan parameter clip limit untuk membatasi nilai histogram agar tidak melampaui ambang batas tertentu, sehingga mengontrol efek amplifikasi noise parameter clip limit dirancang untuk mengendalikan efek amplifikasi noise dengan membatasi nilai-nilai dalam histogram citra agar tidak melampaui ambang batas yang telah ditentukan. Selanjutnya, batas antar-tile dihaluskan menggunakan interpolasi bilinear untuk menghilangkan artefak blok yang muncul akibat proses equalization lokal wilayah citra yang bertetangga kemudian digabungkan menggunakan interpolasi bilinear untuk menghilangkan batas-batas yang muncul secara artifisial antar wilayah tersebut. Kanal L yang telah diproses CLAHE kemudian digabungkan kembali dengan kanal A dan B asli, lalu citra dikonversi kembali ke ruang warna semula sebelum diteruskan ke tahap ekstraksi fitur/klasifikasi.

Modifikasi ini berbeda dari pendekatan umum yang menerapkan CLAHE langsung pada citra grayscale tanpa pemisahan kanal. Pendekatan berbasis kanal L dipilih karena kanal ini merepresentasikan informasi kecerahan secara independen dari informasi warna, sehingga proses perbaikan kontras menjadi lebih presisi dan minim distorsi. Pendekatan *Preprocessing* berbasis CLAHE pada citra medis ini didukung oleh berbagai studi yang melaporkan bahwa

peningkatan kontras melalui CLAHE secara signifikan memperbaiki kemampuan deteksi tepi pada citra, yang pada akhirnya meningkatkan akurasi klasifikasi citra medis yang diproses dengan contrast-limited adaptive histogram equalization (CLAHE) secara signifikan meningkatkan deteksi tepi, yang mengarah pada peningkatan akurasi klasifikasi. Pengaruh CLAHE terhadap performa klasifikasi citra medis berbasis CNN juga telah diuji pada studi serupa di domain lain, yang melaporkan peningkatan akurasi signifikan pada berbagai arsitektur CNN setelah penerapan CLAHE dibandingkan dengan citra asli maupun citra dengan filter lain evaluasi arsitektur CNN pada citra yang telah diproses CLAHE menunjukkan peningkatan signifikan pada performa klasifikasi dibandingkan dengan citra asli maupun citra yang diproses filter lain(Hussein et al., 2022).

Klasifikasi Menggunakan *Convolutional Neural Network (CNN)*

Setelah melalui tahap *Preprocessing*, citra digunakan sebagai input untuk proses training menggunakan pendekatan transfer learning dengan tiga arsitektur CNN yang telah pre-trained pada dataset ImageNet, yaitu VGG16, ResNet50, dan MobileNetV2. Penggunaan transfer learning pada ketiga arsitektur ini sejalan dengan praktik umum pada penelitian klasifikasi citra medis, di mana lapisan konvolusi awal yang menangkap fitur generik seperti tepi dan tekstur dibekukan, sementara lapisan-lapisan lebih dalam dilakukan fine-tuning agar sesuai dengan karakteristik domain citra medis yang spesifik model yang diusulkan memanfaatkan kekuatan masing-masing jaringan pre-trained dengan membekukan lapisan konvolusi awal dan melakukan fine-tuning pada lapisan yang lebih dalam. BMC Medical Imaging Ketiga arsitektur dipilih karena merepresentasikan karakteristik desain yang berbeda, sehingga memungkinkan perbandingan komprehensif:

- VGG16** merepresentasikan arsitektur CNN sekuensial klasik dengan filter konvolusi kecil (3x3) yang disusun berlapis-lapis, dikenal memiliki kemampuan ekstraksi fitur yang baik namun dengan jumlah parameter yang besar.
- ResNet50** menggunakan mekanisme residual/skip connection yang memungkinkan pelatihan jaringan yang lebih dalam tanpa mengalami vanishing gradient, dan secara konsisten dilaporkan memberikan akurasi yang kompetitif pada berbagai studi klasifikasi citra dada berbasis CNN ResNet50 mencapai akurasi validasi tinggi yang kompetitif dibandingkan arsitektur lain pada radiograf dada. medrxiv
- MobileNetV2** dirancang dengan pendekatan inverted residual dan linear bottleneck yang membuatnya lebih ringan secara komputasi arsitektur MobileNetV2 menggunakan struktur inverted residual dan linear bottleneck, sehingga relevan untuk skenario implementasi dengan keterbatasan sumber daya komputasi, sebagaimana telah diterapkan pada studi klasifikasi citra paru lainnya MobileNetV2 telah diterapkan pada klasifikasi citra CT-Scan paru menggunakan pendekatan transfer learning. ScienceDirectPolibatam

Proses training dilakukan dengan optimizer Adam dan fungsi loss categorical cross-entropy, sebagaimana umum digunakan pada studi transfer learning serupa transfer learning diterapkan menggunakan representasi fitur dari model-model CNN dengan optimizer Adam dan fungsi loss categorical cross-entropy, disertai teknik early stopping berdasarkan validation loss untuk mencegah overfitting selama proses pelatihan, secara lengkap untuk arsitektur dan parameter yang digunakan disajikan pada tabel 1.

Tabel 1. *Arsitektur Pretrained dan Parameter Training*

Parameter	VGG16	ResNet50	MobileNetV2
Jumlah Layer (Depth)	16	50	53 (dengan bottleneck)
Jumlah Parameter ($\pm$ ImageNet)	$\pm$ 138 juta	$\pm$ 25,6 juta	$\pm$ 3,4 juta
Optimizer	Adam	Adam	Adam
Fungsi Loss	Categorical Cross-Entropy	Categorical Cross-Entropy	Categorical Cross-Entropy
Teknik Regularisasi	Early Stopping (berdasarkan validation loss)	Early Stopping (berdasarkan validation loss)	Early Stopping (berdasarkan validation loss)
Monitor Metric	Validation Loss	Validation Loss	Validation Loss

Parameter	VGG16	ResNet50	MobileNetV2
Ciri khas Praitrained	Struktur sederhana, menggunakan tumpukan convolution 3x3 berulang	Menggunakan residual connection (skip connection) untuk mengatasi vanishing gradient	Menggunakan depthwise separable convolution dan inverted residual block, efisien untuk perangkat dengan sumber daya terbatas

Sumber : Penulis(2026)

Teknik Analisis Data dan Evaluasi Performa

Evaluasi performa ketiga model dilakukan menggunakan data test berjumlah 259 citra yang tidak dilibatkan sama sekali dalam proses training maupun validasi, guna memperoleh estimasi performa model yang objektif terhadap data baru. Metrik evaluasi yang digunakan meliputi:

- a. **Accuracy** untuk mengetahui proporsi prediksi benar terhadap keseluruhan data uji, dihitung menggunakan rumus 1

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

- b. **recision** untuk mengetahui prediksi positif cancer yang benar-benar merupakan kasus kanker, dihitung menggunakan rumus 2.

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

- c. **Recall (sensitivity)** untuk mengetahui kemampuan model mendeteksi seluruh kasus kanker yang sebenarnya, dihitung menggunakan rumus 3.

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

Metrik ini menjadi perhatian khusus dalam konteks medis karena risiko false negative yang mendeinisikan kasus kanker jauh lebih kritis dibandingkan false positive.

- d. **F1-score** untuk mengetahui rata-rata harmonik antara precision dan recall, memberikan gambaran keseimbangan performa terutama bila distribusi kelas pada dataset tidak seimbang.


Selain keempat metrik utama tersebut, dilakukan pula analisis confusion matrix untuk melihat distribusi prediksi benar dan salah pada masing-masing kelas, serta perbandingan kurva akurasi dan loss antara data training dan validation pada setiap epoch guna mengidentifikasi indikasi overfitting atau underfitting pada masing-masing arsitektur. Hasil evaluasi dari ketiga model (VGG16, ResNet50, MobileNetV2) yang telah melalui *Preprocessing* CLAHE berbasis kanal L kemudian dibandingkan secara kuantitatif untuk menentukan arsitektur dengan performa deteksi kanker paru-paru terbaik, sekaligus untuk menganalisis sejauh mana *Preprocessing* yang diusulkan memberikan pengaruh konsisten di seluruh arsitektur yang diuji.

HASIL DAN PEMBAHASAN

Tahapan penelitian yang dilakukan diantaranya data preparation, preproesiing dataset menggunakan CLAHE untuk menstabilkan kanal L, proses traing dataset menggunakan tiga arsitecture convolution neural network yakni VGG16, ResNet50, dan MobileNetV2, arsitecture ini digunakan untuk membandingkan hasil training dengan arsitecture yang sudah berusia sepuluh tahun lebih dengan arsitecture terbaru untuk menemukan hasil training yang terbaik terhadap dataset x-ray dada untuk mendeteksi terdapat temuan nodul yang mengindikasikan adanya penyakit kanker paru-paru. Dan proses terakhir evaluasi model untuk analisa performa dari model yang di hasilkan dari ketiga arsitecture.

Data Preparation

Tahapan ini bertujuan untuk mempersiapkan dataset yang akan dilakukan training, untuk menunjang hasil training yang maksimal dibutuhkan keseimbangan jumlah dataset pada setiap kelas dan pada komposisi jumlah dataset training, validasi, dan test. Pada gambar 3 merupakan jumlah dataset pada setiap kelas.



Gambar 3. Distribusi dataset pada setiap kelas
Sumber : Data Primer Penelitian, diolah oleh penulis(2026)

Karena di butuhkan nya untuk mendeteksi kanker paru-paru pada citra x-ray dada, pada penelitian ini menggunakan jumlah dataset lebih banyak pada kelas cancer yakni 1491 agar sistem lebih mengenali fitur yang ada. Untuk split dataset training, validation, dan testing penelitian menggunakan rumus 80:10:10, dengan jumlah train 1.200 citra, validation 259 citra, dan testing 259 citra.

Preprocessing Dataset with CLAHE

Karena CLAHE pada dasarnya dirancang untuk bekerja pada citra grayscale atau satu kanal intensitas, maka penerapan CLAHE pada citra berwarna (atau citra X-ray yang direpresentasikan dalam ruang warna tertentu) memerlukan konversi ruang warna terlebih dahulu, umumnya dari ruang warna RGB ke ruang warna Lab (CIELAB). Ruang warna Lab dipilih karena memisahkan informasi kecerahan (Lightness/kanal L) dari informasi warna (kanal a dan b), sehingga proses peningkatan kontras dapat difokuskan hanya pada komponen luminansi/kecerahan citra tanpa mengubah informasi warna aslinya. Pada gambar 4 merupakan hasil dari penstabilan kanal L menggunakan CLAHE.




Gambar 4. Hasil *preprocessing* menggunakan CLAHE
Sumber : Data Hasil *Preprocessing*, diolah oleh penulis(2026)

Pada citra pertama (Original NORMAL), terlihat bahwa area jaringan paru cenderung memiliki kontras yang lebih datar/rendah, di mana batas antara jaringan lunak, tulang rusuk, dan rongga paru tidak terlalu tegas, terutama pada area dengan intensitas piksel yang cenderung gelap atau menengah. Pada citra kedua (Setelah CLAHE, clip=2.0, tile=(8, 8)), tampak peningkatan kontras yang cukup signifikan, di mana Struktur tulang rusuk terlihat lebih tajam dan jelas. Detail jaringan paru pada bagian tengah dan tepi citra menjadi lebih terlihat. Perbedaan intensitas antar area (misalnya antara jaringan lunak dan rongga udara pada paru) menjadi lebih kontras, sehingga fitur-fitur halus yang berpotensi menjadi indikator anomali dapat lebih mudah diidentifikasi baik secara visual maupun oleh model CNN. Sedangkan Grafik histogram pada bagian kanan gambar menunjukkan distribusi intensitas piksel pada kanal L, dengan warna biru merepresentasikan citra original dan warna merah/oranye merepresentasikan citra setelah

CLAHE. Puncak tinggi di sekitar nilai piksel 0 pada kedua histogram menunjukkan adanya area gelap yang dominan pada citra, biasanya berasal dari latar belakang/area di luar tubuh pasien (background hitam pada citra X-ray). Pada citra original, distribusi piksel cenderung menumpuk pada rentang menengah (sekitar 100–180) dengan bentuk yang kurang merata, mengindikasikan kontras yang belum optimal. Setelah penerapan CLAHE, terlihat bahwa distribusi piksel pada rentang menengah menjadi lebih tersebar dan lebih merata dibandingkan citra original, meskipun bentuk puncaknya tidak berubah drastis. Hal ini menunjukkan bahwa CLAHE berhasil melakukan redistribusi intensitas piksel secara lokal, sehingga variasi kontras pada tiap area citra meningkat tanpa mengubah karakteristik keseluruhan citra secara ekstrem (berbeda dengan histogram equalization global yang biasanya menghasilkan distribusi piksel yang jauh lebih rata/flat di seluruh rentang 0–255). Perbedaan yang tidak terlalu ekstrem antara histogram original dan CLAHE ini justru menunjukkan bahwa parameter clip limit 2.0 bekerja dengan baik dalam membatasi penguatan kontras berlebihan, sehingga citra hasil CLAHE tetap terlihat natural dan tidak menimbulkan artefak visual yang mengganggu proses interpretasi maupun pelatihan model.

Klasifikasi Kanker paru-paru pada Citra X-Ray dada menggunakan CNN

Proses training dilakukan dengan pendekatan transfer learning menggunakan tiga arsitektur CNN pre-trained, yaitu VGG16, ResNet50, dan MobileNetV2, yang masing-masing telah dilatih sebelumnya pada dataset ImageNet. Ketiga model kemudian dilakukan fine-tuning menggunakan dataset citra X-ray dada yang telah melalui tahap *Preprocessing* CLAHE, dengan optimizer Adam, fungsi loss categorical cross-entropy, serta teknik early stopping berdasarkan validation loss untuk mencegah overfitting. Proses training dipantau melalui dua metrik utama pada setiap epoch, yaitu loss dan accuracy, baik pada data training maupun data validasi. Pada gambar 5 menunjukkan grafik hasil training.



Gambar 5. Grafik hasil Training
Sumber : Data Hasil Training, diolah oleh penulis(2026)

Berdasarkan grafik loss pada gambar, terlihat bahwa ketiga model menunjukkan tren penurunan nilai loss yang signifikan pada beberapa epoch awal (epoch 1–5), yang mengindikasikan bahwa model dengan cepat mempelajari pola-pola dasar dari data training. ResNet50 di tunjukkan pada garis merah, menunjukkan nilai loss awal yang paling tinggi (di atas 0.55) namun mengalami penurunan paling tajam di antara ketiga model, dan mencapai nilai loss terendah secara konsisten sekitar 0.15 dalam rentang epoch yang lebih singkat kurang dari 15 epoch, menandakan proses konvergensi yang cepat. MobileNetV2 di tunjukkan dengan garis hijau, menunjukkan pola konvergensi yang cukup cepat dengan nilai loss training dan validasi yang berdekatan pada awal training, namun pada beberapa epoch berikutnya sekitar epoch 8–11 terlihat validation loss di tunjukkan pada garis hijau putus-putus, mulai menunjukkan sedikit fluktuasi/kenaikan dibandingkan training loss, yang bisa menjadi indikasi awal terjadinya overfitting ringan sebelum early stopping menghentikan proses training. VGG16 di tunjukkan dengan garis biru, memiliki proses penurunan loss yang lebih landai/gradual dibandingkan dua model lainnya, namun training berlangsung lebih lama hingga epoch ke-25 dan berhasil mencapai nilai loss yang stabil di kisaran 0.13–0.15 pada bagian akhir, dengan jarak antara training loss dan validation loss yang relatif konsisten, menunjukkan proses pembelajaran yang lebih stabil tanpa indikasi overfitting yang signifikan.

Pada grafik akurasi, ketiga model menunjukkan peningkatan akurasi yang tajam pada epoch-epoch awal, kemudian mulai stabil pada rentang akurasi 0.90–0.95. VGG16 menunjukkan

tren peningkatan akurasi yang paling stabil dan konsisten hingga mencapai training accuracy tertinggi sekitar 0.95 pada epoch akhir, dengan validation accuracy yang mengikuti pola serupa meski sedikit lebih rendah, menandakan generalisasi model yang baik terhadap data validasi. ResNet50 mencapai akurasi tinggi lebih cepat dibandingkan model lain, bahkan validation accuracy di tunjukkan oleh garis merah putus-putus, sempat berada di atas training accuracy pada beberapa epoch awal, namun proses training relatif lebih singkat dan berhenti lebih awal akibat early stopping. MobileNetV2 menunjukkan validation accuracy yang cenderung stagnan di kisaran 0.89–0.90 setelah epoch ke-6, sementara training accuracy terus meningkat, sehingga gap antara training dan validation accuracy terlihat lebih lebar dibandingkan dua model lainnya, ini menjadi indikasi awal bahwa MobileNetV2 lebih rentan mengalami overfitting pada kelas minoritas (NORMAL) dibandingkan VGG16 dan ResNet50.

Analisis Data dan Evaluasi Performa

Untuk analisis model, pada penelitian ini akan evaluasi dengan menghitung akurasi, precision, recall, dan juga F1 score. Pada tabel 2 disajikan data hasil perhitungan dari evaluasi model.

Tabel 2. Evaluasi Performa Hasil Training

Metrik	Kelas	VGG16	ResNet50	MobileNetV2
<i>Precision</i>	CANCER	0.9906	0.9682	0.9174
<i>Recall</i>	CANCER	0.9420	0.9509	0.9911
<i>F1-Score</i>	CANCER	0.9657	0.9595	0.9528
<i>Precision</i>	NORMAL	0.7174	0.7179	0.8824
<i>Recall</i>	NORMAL	0.9429	0.8000	0.4286
<i>F1-Score</i>	NORMAL	0.8148	0.7568	0.5769
Akurasi		0.942	0.930	0.915

Sumber : Data Hasil Training, diolah oleh penulis(2026)

Melihat hasil dari evaluasi model pada nilai Precision, recall, f1-score, dan akurasi. Training menggunakan arsitektur VGG16 menghasilkan performa paling seimbang di antara kedua kelas. Meskipun precision untuk kelas NORMAL tidak setinggi MobileNetV2, VGG16 memiliki recall NORMAL tertinggi yakni 0.9429, yang berarti model ini paling mampu mengenali kasus NORMAL dengan benar dan meminimalkan risiko false negative pada kelas minoritas, hal ini sangat penting dalam konteks medis, di mana kesalahan mengklasifikasikan pasien NORMAL sebagai CANCER atau sebaliknya memiliki konsekuensi klinis yang serius. Selanjutnya dengan menggunakan arsitektur ResNet50 menunjukkan performa yang mendekati VGG16, dengan precision CANCER sedikit lebih rendah namun recall CANCER sedikit lebih tinggi. Namun pada kelas NORMAL, recall ResNet50 bernilai 0.8000 lebih rendah dibandingkan VGG16, yang berarti ResNet50 lebih sering salah mengklasifikasikan pasien NORMAL sebagai CANCER dibandingkan VGG16. Dan dengan menggunakan arsitektur MobileNetV2 memiliki recall tertinggi untuk kelas CANCER yakni bernilai 0.9911, yang berarti model ini sangat baik dalam mendeteksi kasus kanker secara umum. Namun, performanya pada kelas NORMAL jauh lebih rendah dibandingkan dua model lainnya, dengan recall hanya 0.4286 dan F1-score 0.5769, artinya lebih dari separuh pasien NORMAL justru salah diklasifikasikan sebagai CANCER atau false positive, yang konsisten dengan gap overfitting yang terlihat pada grafik validation accuracy sebelumnya.

Berdasarkan keseluruhan metrik evaluasi dengan menghitung akurasi, F1-score, serta keseimbangan performa antar kelas, VGG16 merupakan model dengan performa terbaik di antara ketiga arsitektur yang diuji. VGG16 menghasilkan akurasi keseluruhan tertinggi 94,2% tetapi juga menunjukkan proses training yang paling stabil berdasarkan grafik loss dan accuracy, dengan gap yang minim antara data training dan validasi, hal ini mengindikasikan kemampuan generalisasi yang baik dan risiko overfitting yang relatif rendah dibandingkan ResNet50 dan MobileNetV2. Pada penelitian ini telah membuktikan bahwa terdapat peningkatan akurasi setelah di tambahkan *Preprocessing* menggunakan CLAHE. Penelitian sebelumnya pada data uji independen menggunakan arsitektur VGG16 menghasilkan akurasi sebesar 92,96% (Sarker et al., 2024). Pada penelitian ini dihasilkan akurasi sebesar 94,2% oleh arsitektur VGG16, dapat disimpulkan bahwa dengan arsitektur yang sama, jika di tambahkan *Preprocessing* sebelum training membuktikan akan menambah angka akurasi pada model yang dihasilkan.

KESIMPULAN

Hasil Penelitian ini menunjukkan bahwa penerapan *Preprocessing* CLAHE yang difokuskan secara khusus pada kanal L dari ruang warna LAB mampu meningkatkan kontras citra X-Ray dada secara presisi tanpa menimbulkan distorsi informasi warna, sehingga berkontribusi pada peningkatan kemampuan model CNN dalam mengenali pola abnormal terkait kanker paru-paru. Dari ketiga arsitektur yang diuji, VGG16 menghasilkan performa terbaik dan paling seimbang dengan akurasi keseluruhan 94,2%, recall kelas normal tertinggi 0,9429, serta gap loss training-validation yang minim, menandakan kemampuan generalisasi yang baik dan risiko overfitting yang rendah. ResNet50 berada pada posisi kedua dengan akurasi 93,0%, sementara MobileNetV2 91,5% meskipun memiliki recall kanker tertinggi 0,9911, terbukti rentan overfitting terhadap kelas minoritas normal dengan recall normal hanya 0,4286. Dibandingkan dengan penelitian-penelitian sejenis yang menerapkan CLAHE secara umum pada seluruh kanal citra dan melaporkan akurasi berkisar 84,45%–92,96%, pendekatan stabilisasi kanal L yang diusulkan terbukti memberikan peningkatan performa yang lebih baik, sekaligus menegaskan bahwa *Preprocessing* yang terfokus dan presisi pada komponen kecerahan citra merupakan faktor penting dalam meningkatkan akurasi deteksi kanker paru-paru berbasis CNN. Penelitian selanjutnya disarankan untuk memperluas jumlah data pada kelas normal guna mengatasi ketidakseimbangan kelas, serta di ujicoba dengan metode pretrained berbasis AI agar proses training akan menambah tingkat akurasi. Dalam meningkatkan proses pengujian, generalisasi model pada dataset dari berbagai sumber dan fasilitas kesehatan yang berbeda.

REFERENSI

- Anupama, B. C., Rao, S. N., Malini, M. B., & Athreya, V. V. (2025). *Comparative analysis of novel Preprocessing techniques and deep learning based multi modal feature fusion for diabetic retinopathy grading*. *Scientific Reports*, 16(1), 1743. <https://doi.org/10.1038/s41598-025-31339-w>
- Buriboev, A. S., Khashimov, A., Abduvaitov, A., & Jeon, H. S. (2024). *CNN-Based Kidney Segmentation Using a Modified CLAHE Algorithm*. *Sensors*, 24(23). <https://doi.org/10.3390/s24237703>
- Chen, C., Mat Isa, N. A., & Liu, X. (2025). *A review of convolutional neural network based methods for medical image classification*. *Computers in Biology and Medicine*, 185, 109507. <https://doi.org/https://doi.org/10.1016/j.combiomed.2024.109507>
- Hegazy, N. Y., & Sawah, M. S. (2026). *An optimized EfficientNetB0 framework with CLAHE-based Preprocessing for accurate multi-class chest X-ray classification*. *Scientific Reports*, 16(1), 10811. <https://doi.org/10.1038/s41598-026-42492-1>
- Hussein, F., Mughaid, A., AlZu'bi, S., El-Salhi, S. M., Abuhaija, B., Abualigah, L., & Gandomi, A. H. (2022). *Hybrid CLAHE-CNN Deep Neural Networks for Classifying Lung Diseases from X-ray Acquisitions*. *Electronics*, 11(19). <https://doi.org/10.3390/electronics11193075>
- Javed, R., Abbas, T., Khan, A. H., Daud, A., Bukhari, A., & Alharbey, R. (2024). *Deep learning for lungs cancer detection: a review*. *Artificial Intelligence Review*, 57(8), 197. <https://doi.org/10.1007/s10462-024-10807-1>
- Lakshmi G, G., & Nagaraj, P. (2025). *Lung cancer detection and classification using optimized CNN features and Squeeze-Inception-ResNeXt model*. *Computational Biology and Chemistry*, 117, 108437. <https://doi.org/https://doi.org/10.1016/j.compbiolchem.2025.108437>
- M. D, A., & B, V. (2026). *Enhancing lung cancer classification through a double attention hybrid CNN-HiFuse approach*. *Scientific Reports*, 16(1), 13099. <https://doi.org/10.1038/s41598-026-42290-9>
- Megat Ramli, P. N., Aizuddin, A. N., Ahmad, N., Abdul Hamid, Z., & Ismail, K. I. (2025). *A Systematic Review: The Role of Artificial Intelligence in Lung Cancer Screening in Detecting Lung Nodules on Chest X-Rays*. *Diagnostics*, 15(3). <https://doi.org/10.3390/diagnostics15030246>
- Mienye, I. D., Swart, T. G., Obaido, G., Jordan, M., & Ilono, P. (2025). *Deep Convolutional Neural Networks in Medical Image Analysis: A Review*. *Information*, 16(3). <https://doi.org/10.3390/info16030195>
- Saifullah, S., & Dreżewski, R. (2024). *Advanced Medical Image Segmentation Enhancement: A Particle-Swarm-Optimization-Based Histogram Equalization Approach*. *Applied Sciences*, 14(2). <https://doi.org/10.3390/app14020923>

- Sarker, S., Refat, S. R., Fairuj Preotee, F., Shawon, T. R., & Tanvir, R. (2024). *Comprehensive Lung Disease Detection Using Deep Learning Models and Hybrid Chest X-ray Data with Explainable AI*. 2024 27th International Conference on Computer and Information Technology (ICCIT), 2279–2284. <https://doi.org/10.1109/ICCIT64611.2024.11022605>
- Shimazaki, A., Ueda, D., Choppin, A., Yamamoto, A., Honjo, T., Shimahara, Y., & Miki, Y. (2022). *Deep learning-based algorithm for lung cancer detection on chest radiographs using the segmentation method*. *Scientific Reports*, 12(1), 727. <https://doi.org/10.1038/s41598-021-04667-w>
- Xu, H., Yu, Y., Chang, J., Hu, X., Tian, Z., & Li, O. (2024). *Precision lung cancer screening from CT scans using a VGG16-based convolutional neural network*. *Frontiers in Oncology, Volume 14-2024*. <https://doi.org/10.3389/fonc.2024.1424546>
- Yadav, N. L., Singh, S., Kumar, R., & Nishad, D. K. (2025). *Transfer learning with fuzzy decision support for multi-class lung disease classification: performance analysis of pre-trained CNN models*. *Scientific Reports*, 15(1), 35127. <https://doi.org/10.1038/s41598-025-19114-3>
- Yoon, S.-H., Kim, J., Kim, J., Lee, J.-H., Choi, I., Shin, C.-W., & Park, C.-M. (2025). *Improving Image Quality of Chest Radiography with Artificial Intelligence-Supported Dual-Energy X-Ray Imaging System: An Observer Preference Study in Healthy Volunteers*. *Journal of Clinical Medicine*, 14(6). <https://doi.org/10.3390/jcm14062091>