

Optimalisasi Model CNN dengan Teknik Kontras Lokal CLAHE untuk Klasifikasi Pneumonia pada Citra X-Ray

Rania Alfita Salma*, Christian Sri Kusuma Aditya

Fakultas Teknik, Program Studi Informatika, Universitas Muhammadiyah Malang, Malang, Indonesia

Email: ^{1,*}raniaalfita04@webmail.umm.ac.id, ²christianskaditya@umm.ac.id

Email Penulis Korespondensi: raniaalfita04@webmail.umm.ac.id

Submitted: 20/08/2025; Accepted: 30/09/2025; Published: 30/09/2025

Abstrak—Pneumonia merupakan infeksi paru-paru yang berdampak luas bagi kesehatan masyarakat, terutama pada wilayah yang memiliki akses layanan kesehatan terbatas. Citra X-ray dada berperan penting dalam mendeteksi penyakit ini, namun kualitas kontras yang rendah seringkali menjadi hambatan dalam klasifikasi otomatis berbasis *deep learning*. Penelitian ini bertujuan untuk mengevaluasi efektivitas metode *Contrast Limited Adaptive Histogram Equalization* (CLAHE) dalam meningkatkan kualitas kontras citra X-ray, serta menganalisis pengaruhnya terhadap performa model *Convolutional Neural Network* (CNN) dalam mendeteksi pneumonia. CLAHE meningkatkan visibilitas detail radiografis melalui redistribusi kontras lokal dengan *clip limit*, sehingga struktur patologis pneumonia yang sebelumnya samar dapat dikenali lebih baik oleh CNN. Dataset yang digunakan terdiri dari 2.623 citra X-ray yang dibagi menjadi dua kelas, yaitu Normal dan Pneumonia. Proses pelatihan dilakukan dalam dua pendekatan, yaitu tanpa dan dengan penerapan CLAHE. Hasil evaluasi menunjukkan bahwa model CNN tanpa CLAHE mencapai akurasi 96,18%, sedangkan model dengan CLAHE meningkat hingga 99,69%. Peningkatan ini signifikan karena menurunkan tingkat kesalahan klasifikasi dari sekitar 3,8% pada model tanpa CLAHE menjadi hanya 0,3% pada model dengan CLAHE, sekaligus meningkatkan *precision*, *recall*, dan *f1-score* pada seluruh kelas. Dengan demikian, kombinasi CLAHE dan CNN dapat diterapkan sebagai pendekatan efektif dalam mendeteksi pneumonia secara akurat, konsisten, dan efisien, terutama pada lingkungan dengan keterbatasan sumber daya komputasi.

Kata Kunci: CNN; CLAHE; Pneumonia; Citra X-Ray; Klasifikasi

Abstract—Pneumonia is a lung infection that has a widespread impact on public health, particularly in areas with limited access to healthcare services. Chest X-ray imaging plays an important role in diagnosing this disease; however, low contrast quality often becomes an obstacle to automated classification using deep learning methods. This study aims to evaluate the effectiveness of the Contrast Limited Adaptive Histogram Equalization (CLAHE) method in enhancing the visual quality of chest X-ray images and to analyze its impact on the performance of a Convolutional Neural Network (CNN) model in detecting pneumonia. CLAHE enhances the visibility of radiographic details through local contrast redistribution with a clip limit, allowing previously indistinct pathological structures to be more clearly recognized by the CNN. The dataset used consists of 2,623 X-ray images that are divided into two classes, namely Normal and Pneumonia. The training process was conducted under two scenarios, without and with the application of CLAHE. The evaluation results show that the CNN model without CLAHE achieved an accuracy of 96.18%, while the model with CLAHE improved to 99.69%. This improvement is significant as it reduced the classification error rate from approximately 3.8% in the model without CLAHE to only 0.3% in the model with CLAHE, while also increasing precision, recall, and f1-score across all classes. Therefore, combination of CLAHE and CNN can be applied as an effective approach for pneumonia detection that is accurate, consistent, and efficient, especially in environments with limited computational resources.

Keywords: CNN; CLAHE; Pneumonia; X-Ray Image; Classification

1. PENDAHULUAN

Paru-paru adalah organ penting dalam sistem pernapasan manusia, bertanggung jawab atas pertukaran gas oksigen (O₂) dan karbon dioksida (CO₂), serta menjaga agar sel-sel tubuh tetap hidup [1]. Berbagai jenis infeksi juga dapat menyerang organ ini. Salah satunya adalah pneumonia, merupakan infeksi paru-paru yang disebabkan oleh bakteri, virus, atau jamur. Menurut laporan terbaru dari *World Health Organization* (WHO) tahun 2019, pneumonia menjadi penyebab kematian bagi 740.180 anak di bawah usia lima tahun, atau sekitar 14% dari total kematian dalam kelompok usia tersebut [2]. Pada tahun 2023, angka kematian akibat pneumonia meningkat menjadi 23%, bersamaan dengan diare, dengan total 1,17 juta kematian di seluruh dunia. Di Indonesia, pneumonia juga masih menjadi masalah kesehatan masyarakat yang serius, terutama di wilayah yang memiliki keterbatasan layanan medis [3]. Sebuah studi epidemiologi di Provinsi Sumatera Utara mencatat sebanyak 23.147 kasus pneumonia dalam *Community Acquired Pneumonia*, CAP dalam kurun waktu 2019 hingga 2022, dengan 94,6% kasus terjadi di daerah pedesaan. Prevalensi kasus di wilayah pedesaan tercatat mencapai 194,9 per 100.000 penduduk, jauh lebih tinggi dibandingkan daerah perkotaan yang hanya sebesar 32,4 per 100.000 penduduk [4]. Kondisi tersebut mengindikasikan adanya kesenjangan distribusi kasus berdasarkan geografis yang dapat dipengaruhi oleh faktor lingkungan, perilaku hidup sehat, dan keterbatasan akses layanan kesehatan. Selain itu, tren kasus CAP sempat menurun pada tahun 2020 akibat intervensi pandemi COVID-19, namun kembali melonjak tajam sekitar sepuluh kali lipat pada tahun berikutnya sebelum menurun kembali secara moderat pada tahun 2022 [5]. Fluktuasi ini menegaskan pentingnya sistem deteksi dini dan respons berbasis wilayah untuk mengurangi dampak pneumonia secara berkelanjutan. Dampak pneumonia tidak hanya pada aspek kesehatan individu, tetapi juga berkontribusi terhadap beban ekonomi keluarga serta tekanan pada sistem pelayanan kesehatan, khususnya di wilayah dengan sumber daya terbatas [6]. Oleh karena itu, strategi pencegahan seperti imunisasi, perbaikan status gizi, dan peningkatan akses terhadap pengobatan yang cepat dan tepat

menjadi kunci utama dalam menurunkan angka morbiditas dan mortalitas akibat pneumonia, baik di tingkat nasional maupun global [4].

Deteksi pneumonia berbasis citra medis semakin berkembang dengan bantuan teknologi kecerdasan buatan, khususnya *deep learning* [7], yang memiliki kemampuan untuk mengolah data citra medis dalam jumlah besar dan menemukan pola visual yang seringkali tidak terlihat dengan cara konvensional [8]. *Convolutional Neural Network* atau CNN adalah teknik yang banyak digunakan karena mampu mendeteksi gejala pneumonia secara dini melalui analisis citra radiologi dada secara otomatis [9]. Penerapan *deep learning* dalam bidang medis telah menunjukkan efektivitas tinggi [10], terutama melalui CNN yang mampu mengekstraksi karakteristik penting dari citra X-ray dada secara otomatis melalui lapisan konvolusi, *pooling*, dan aktivasi [11]. Namun, kualitas citra X-ray pneumonia pada dataset publik sering kali rendah, ditandai dengan kontras yang kurang, pencahayaan yang tidak homogen, serta artefak visual [12]. Kondisi ini menyulitkan CNN dalam mengenali struktur penting seperti batas paru-paru, dinding dada, maupun infiltrasi, sehingga akurasi klasifikasi menurun [13]. Oleh karena itu, diperlukan teknik pra-pemrosesan citra yang dapat meningkatkan kualitas visual sebelum digunakan dalam pelatihan model, sehingga pola patologis lebih mudah dikenali dan hasil klasifikasi menjadi lebih akurat.

Dalam beberapa penelitian sebelumnya penggunaan arsitektur CNN menjadi solusi yang efektif dalam klasifikasi pneumonia. Terdapat penelitian sebelumnya yang mencapai akurasi sebesar 93% dalam mengklasifikasi citra X-ray menggunakan arsitektur CNN [14]. Penelitian lainnya menunjukkan bahwa model CNN yang dibangun dari awal dapat memberikan performa yang kompetitif, dengan akurasi hingga 79% pada data tanpa augmentasi [15]. Bahkan, dalam penelitian lain menggunakan rancangan CNN dengan penambahan *dropout* pada bagian konvolusi dan memperoleh akurasi sebesar 97,20%, serta nilai *recall* dan *precision* di atas 97% [16]. Ketiga penelitian tersebut memperkuat bukti bahwa pendekatan berbasis CNN memiliki potensi tinggi untuk diterapkan dalam sistem klasifikasi pneumonia secara otomatis dan efisien.

CNN telah terbukti efektif dalam klasifikasi pneumonia, akan tetapi performanya masih dipengaruhi oleh kualitas citra asli X-ray dengan capaian akurasi penelitian sebelumnya sebesar 93% [14] dan 79% [15]. Untuk mengatasi permasalahan tersebut, diperlukan teknik pra-pemrosesan data yang mampu meningkatkan kualitas visual citra sebelum digunakan dalam pelatihan model. Salah satu pendekatan yang terbukti efektif dalam meningkatkan kualitas visual citra X-ray ialah *Contrast Limited Adaptive Histogram Equalization* (CLAHE) yang meningkatkan kontras lokal citra dengan membatasi amplifikasi *noise* pada area seragam [17]. Dengan menghasilkan citra yang lebih tajam dan kaya informasi visual, CLAHE mempermudah model CNN dalam mengenali pola patologis secara lebih akurat dan efisien [18]. CLAHE bekerja dengan membagi citra menjadi blok kecil dan menerapkan *histogram equalization* secara terbatas [19], sehingga dalam peningkatan kontras di bagian gelap maupun terang, terutama pada batas paru-paru, tidak menghasilkan distorsi yang berlebih [20]. Dengan karakteristik tersebut, CLAHE terbukti efektif dalam mendukung kinerja model CNN. Kombinasi keduanya mampu meningkatkan efisiensi dan akurasi dalam sistem deteksi pneumonia berbasis citra digital tanpa memerlukan intervensi manual yang signifikan [21]. Beberapa penelitian sebelumnya yang menggabungkan CNN dengan CLAHE menunjukkan adanya peningkatan akurasi. Salah satunya mendapatkan akurasi sebesar 95,21% [22], namun arsitektur CNN yang digunakan relatif sederhana dengan hanya dua hingga tiga lapisan konvolusi dan membutuhkan pelatihan hingga 180 *epoch*, sehingga kurang efisien. Penelitian lain mencapai akurasi 96,40% dengan penerapan CLAHE yang mampu memperjelas detail anatomi citra [23], tetapi penggunaan parameter CLAHE yang bersifat statis masih berisiko menimbulkan *noise* pada area homogen. Dalam penelitian lainnya, arsitektur CNN yang lebih kompleks dengan sembilan hingga sepuluh lapisan, mampu mencapai akurasi 97,20% [15], namun tanpa integrasi CLAHE performa model tetap sangat dipengaruhi oleh kualitas citra asli sehingga pola patologis sulit untuk dikenali secara konsisten.

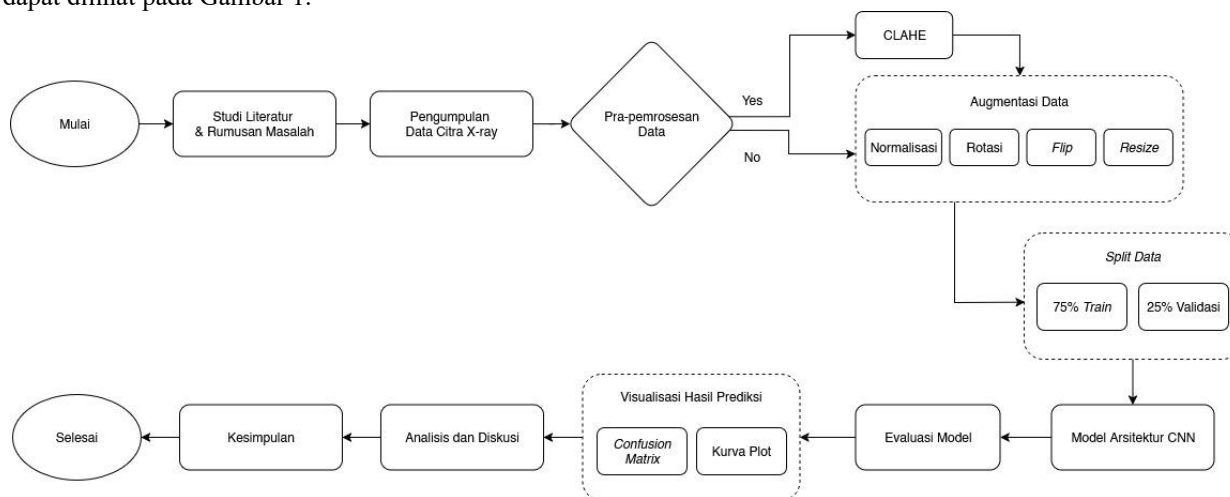
Penelitian ini bertujuan untuk mengoptimalkan model CNN dengan menerapkan teknik kontras lokal CLAHE pada citra X-ray pneumonia. Fokus penelitian diarahkan pada evaluasi efektivitas CLAHE dalam meningkatkan kualitas visual citra serta analisis pengaruhnya terhadap kinerja CNN dalam klasifikasi pneumonia. Selain itu, penelitian ini membandingkan hasil klasifikasi dengan dan tanpa penerapan CLAHE untuk menentukan pendekatan yang paling optimal dalam meningkatkan akurasi prediksi.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Melalui tahapan penelitian yang disusun secara sistematis, model *Convolutional Neural Network* (CNN) digunakan untuk mengklasifikasikan pneumonia berdasarkan gambar X-ray. Proses dimulai dengan studi literatur dan perumusan masalah guna memahami pendekatan yang relevan dan mendukung perancangan metode. Setelah itu dilakukan pengumpulan data citra X-ray yang mencakup dua kelas, yaitu Normal dan Pneumonia. Data yang telah dikumpulkan kemudian diproses, melalui penerapan metode *Contrast Limited Adaptive Histogram Equalization* (CLAHE) guna meningkatkan kualitas kontras citra. Jika peningkatan kontras diperlukan, selanjutnya citra akan melalui proses augmentasi data yang mencakup normalisasi, rotasi, *flipping*, dan *resizing* untuk memperluas keragaman data pelatihan. Data yang telah diproses kemudian dibagi menjadi dua bagian, yaitu 75% untuk pelatihan dan 25% untuk validasi. Proses berikutnya mencakup perancangan dan pelatihan model CNN, serta evaluasi performa melalui metrik *accuracy*, *precision*, *recall*, dan *f1-score*. Hasil klasifikasi divisualisasikan dalam bentuk *confusion matrix* dan kurva

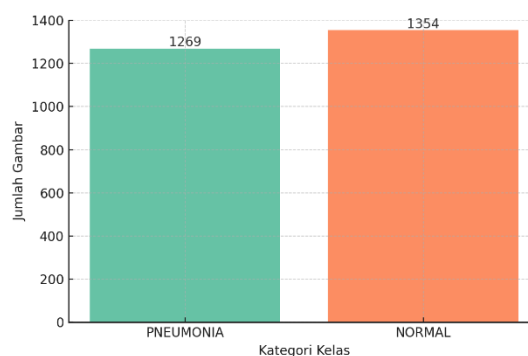
plot, sebelum memasuki tahap analisis dan diskusi, serta penarikan kesimpulan. Alur lengkap metodologi penelitian dapat dilihat pada Gambar 1.



Gambar 1. Alur Metodologi Penelitian

2.2 Sumber Data dan Karakteristik Dataset

Dataset yang digunakan dalam penelitian ini berasal dari Kaggle dengan judul *Chest X-Ray Images (Pneumonia)*. Citra X-ray dada (anterior–posterior) dalam dataset ini berasal dari kohort retrospektif pasien anak berusia satu hingga lima tahun di Guangzhou *Women and Children’s Medical Center*, Guangzhou, yang diambil sebagai bagian dari perawatan klinis rutin pasien. Dataset ini dikembagkan oleh Paul Mooney, sehingga dataset terbagi ke dalam tiga direktori utama, yaitu *train*, *test*, dan *val*. Pada penelitian ini, hanya direktori *train* yang digunakan karena telah memuat distribusi data yang representatif untuk kedua kelas yang diteliti. Direktori *train* terdiri atas dua subdirektori, yaitu Normal dan Pneumonia, yang memudahkan proses pemanggilan data serta pelabelan selama pelatihan. Jumlah citra yang digunakan sebanyak 2.623 gambar, dengan rincian 1.354 citra kelas Normal dan 1.269 citra kelas Pneumonia.



Gambar 2. Distribusi Dataset

Untuk memahami distribusi awal data, jumlah gambar pada masing-masing kelas dihitung dan divisualisasikan dalam bentuk diagram batang seperti yang terlihat pada gambar 2. Visualisasi ini membantu menilai keseimbangan jumlah data antar kelas dan mendeteksi potensi ketimpangan yang dapat memengaruhi performa model. Tahap ini juga bertujuan untuk menemukan potensi ketidakaturan data seperti artefak visual, pencahayaan yang tidak merata, atau kontras yang rendah. Hasil dari pengamatan tersebut menjadi dasar dalam tahap pra-pemrosesan data sebelum proses pelatihan model dilakukan.



Gambar 3. Citra X-ray Kelas Normal (a) dan Pneumonia (b)


Untuk memperlihatkan karakteristik visual, citra dari kedua kelas ditampilkan pada Gambar 3. Citra kelas Normal merepresentasikan kondisi paru-paru yang sehat tanpa indikasi infeksi atau kelainan tertentu, sedangkan citra kelas Pneumonia menampilkan area yang tampak lebih padat atau buram sebagai indikasi adanya infeksi [24].

2.3 Pra-pemrosesan Data

Setelah seluruh data citra X-ray dikumpulkan dan dianalisis, tahap selanjutnya adalah pra-pemrosesan data dengan menerapkan metode *Contrast Limited Adaptive Histogram Equalization* (CLAHE) Metode ini bertujuan meningkatkan ketajaman visual dan memperjelas detail struktur paru-paru, sehingga pola patologis lebih mudah dikenali oleh model. Secara matematis, proses ini menggunakan pendekatan histogram lokal, dengan transformasi intensitas yang dinyatakan melalui persamaan (1).

$$P'(i) = \frac{n_i}{N} \times (L - 1) \quad (1)$$

Di mana $P'(i)$ adalah nilai intensitas hasil transformasi pada level ke i , n_i ialah jumlah piksel dengan intensitas ke i , N merupakan jumlah total piksel dalam satu *region* lokal, dan L merupakan jumlah level intensitas diskret, yang umumnya bernilai 256 pada citra 8-bit. Persamaan ini memastikan distribusi intensitas lebih merata pada masing-masing blok lokal citra, sehingga meningkatkan visibilitas struktur anatomi yang relevan dalam analisis radiografi paru-paru. Dengan dasar perhitungan tersebut, penerapan CLAHE pada penelitian ini menunjukkan peningkatan kontras pada masing-masing kelas citra, baik Normal maupun Pneumonia. Gambar 4 memperlihatkan perbandingan citra sebelum dan sesudah dilakukan CLAHE, di mana detail radiografis tampak lebih tajam setelah proses peningkatan kontras.



Gambar 4. Perbandingan citra setelah CLAHE

Setelah CLAHE, citra melalui tahapan augmentasi data menggunakan fungsi *ImageDataGenerator* dari pustaka *TensorFlow*. Augmentasi diterapkan secara dinamis selama proses pelatihan melalui transformasi seperti normalisasi dengan membagi nilai intensitas terhadap 255, $rescale = 1.0/255$, rotasi acak 20 derajat, pembalikan horizontal, juga *resize image* 64×64 piksel agar skala data lebih sesuai dengan kebutuhan model CNN, sekaligus meningkatkan kemampuan generalisasi model CNN. Dengan teknik ini, variasi data dapat diperluas secara sintetik tanpa perlu menambah jumlah *file* gambar secara permanen.

2.4 Pembagian Dataset

Dataset hasil pra-pemrosesan kemudian dibagi menjadi dua subset, yaitu data latih dan data validasi, dengan rasio 75% banding 25%. Pembagian ini bertujuan untuk memastikan bahwa model CNN dapat dilatih secara optimal sekaligus diuji konsistensinya pada data yang tidak ikut dilatih. Dari total 2.623 citra X-ray, sebanyak 1.968 citra digunakan sebagai data latih, sedangkan 655 citra lainnya dialokasikan sebagai data validasi. Rincian distribusi berdasarkan kelas ditunjukkan pada Tabel 1.


Tabel 1. Distribusi Data Pelatihan dan Validasi Setelah Pra-pemrosesan Data

| Kategori Kelas Data | Data Latih | Data Validasi | Total |
|---------------------|------------|---------------|-------|
| Normal | 1.016 | 338 | 1.354 |
| Pneumonia | 952 | 317 | 1.269 |
| Total | 1.968 | 655 | 2.623 |

2.5 Arsitektur dan Perancangan Model CNN

Struktur CNN terdiri dari beberapa *input layer*, *convolutional layer*, *pooling layer*, *dense layers*, dan *output layer*. Pada tahap awal, *input layer* menerima citra dalam bentuk *array* piksel yang merepresentasikan data visual mentah. Selanjutnya, citra ini diproses oleh *convolutional layer*, di mana filter atau *kernel* digunakan untuk mengekstraksi fitur

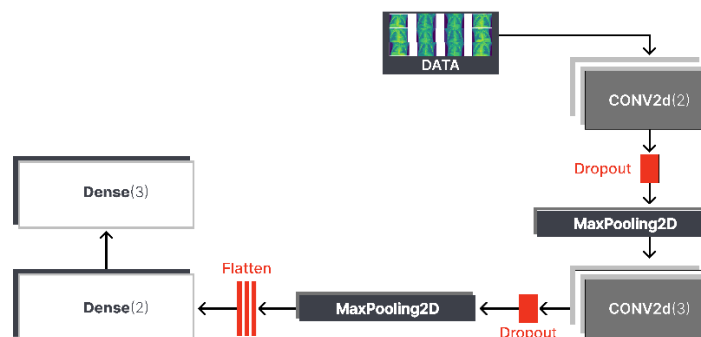
lokal seperti tepi, tekstur, dan pola penting lainnya [25]. Aktivasi non-linear seperti *ReLU* biasanya diterapkan setelah konvolusi untuk menambah kompleksitas representasi [26]. Setelahnya, *pooling layer* digunakan untuk mereduksi dimensi spasial dan mengurangi jumlah parameter, umumnya melalui metode *max pooling* [27]. Struktur umum arsitektur CNN dapat dilihat pada Gambar 5.



Gambar 5. Base Model CNN

Data dari hasil *pooling* kemudian diubah ke bentuk vektor satu dimensi melalui proses *flattening*, kemudian diproses oleh *dense layers*. Lapisan ini memiliki fungsi menggabungkan seluruh informasi fitur untuk melakukan klasifikasi secara menyeluruh. Pada tahap terakhir, *output layer* menghasilkan prediksi berdasarkan representasi fitur yang telah dipelajari oleh model.

Berdasarkan arsitektur CNN tersebut, penelitian ini merancang model CNN secara *sequential* menggunakan pustaka *Keras*, sebagaimana divisualisasikan pada Gambar 6. Model ini memiliki struktur awal lapisan konvolusi *Conv2D*, yang terdiri dari dua blok. Lapisan pertama menggunakan 32 filter dengan *kernel* 3x3 dan fungsi aktivasi *ReLU*, dan menerima input gambar 64x64 piksel dengan tiga kanal warna RGB. Untuk mencegah *overfitting*, ditambahkan lapisan *dropout* sebesar 0.1, dan kemudian dilakukan *max pooling* untuk mengurangi dimensi spasial.



Gambar 6. Perancangan Model CNN

Lapisan konvolusi dengan 64 filter dan kernel 3x3 di blok kedua diikuti oleh *dropout* sebesar 0.15 dan *max pooling*. Proses konvolusi kemudian diratakan melalui lapisan *flatten* sebelum masuk ke lapisan yang benar-benar terhubung. Lapisan *dense* pertama mengandung 128 neuron dengan aktivasi *ReLU*. Lapisan *output* berikutnya memiliki dua neuron dan fungsi aktivasi *softmax*, yang menghasilkan klasifikasi dua kelas. Model ini dikompilasi menggunakan *optimizer Adam* dengan *learning rate* 0.001 serta fungsi *loss categorical_crossentropy*. Struktur dan jumlah parameter model diterapkan untuk menjaga konsistensi arsitektur sebelum pelatihan.

2.6 Pelatihan dan Evaluasi Model

Proses pelatihan model dilakukan dengan memanfaatkan data latih dan validasi hasil augmentasi. Untuk mencegah *overfitting*, digunakan teknik *early stopping* yang dikonfigurasi untuk memantau nilai *val_loss* [28]. Pelatihan dihentikan secara otomatis apabila tidak terjadi penurunan *loss* pada data validasi selama tiga *epoch* berturut-turut. Mekanisme ini sekaligus menjaga agar model mempertahankan hasil terbaik selama proses pembelajaran. Selain itu, proses pelatihan dijalankan dengan maksimal 20 *epoch*. Dengan demikian, rancangan model tidak hanya teruji secara konseptual, tetapi juga terjamin integritasnya selama pelatihan.

Setelah hasil pelatihan selesai, model dievaluasi menggunakan data validasi untuk mengetahui seberapa baik sistem klasifikasi bekerja. Evaluasi dilakukan dengan beberapa metrik, seperti akurasi, *precision*, *recall*, dan *f1-score*, yang digunakan untuk mengevaluasi kinerja model. Selain itu, nilai *loss* dan akurasi selama proses pelatihan juga diamati dan divisualisasikan dalam grafik untuk mengetahui stabilitas model dari *epoch* ke *epoch* [29]. Visualisasi menggunakan *library Matplotlib* dan menampilkan perubahan kinerja model selama pelatihan. Pengamatan pola grafik digunakan untuk menganalisis kualitas pembelajaran model. Dengan pengamatan tersebut dapat ditemukannya potensi *overfitting* dan kegagalan konvergensi.

Untuk mengevaluasi hasil prediksi model, dilakukan perbandingan antara label prediksi dengan label sebenarnya. Hasil ini disajikan dalam bentuk *confusion matrix* yang menggambarkan jumlah prediksi yang termasuk dalam kategori *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN). Berdasarkan

nilai-nilai tersebut, metrik evaluasi seperti *precision*, *recall*, *f1-score*, dan akurasi kemudian dihitung menggunakan persamaan yang dirumuskan pada persamaan (2), (3), (4), dan (5).

$$Precision = \frac{TP}{TP+FP} \tag{2}$$

$$Recall = \frac{TP}{TP+FN} \tag{3}$$

$$F1 - Score = 2 \times \frac{Recall \times Precision}{Recall + Precision} \tag{4}$$

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \tag{5}$$

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

Gambar 7. Tabel *Confusion Matrix*

Pada Gambar 7 menunjukkan tabel *confusion matrix*, dimana tabel tersebut digunakan untuk menyatakan hasil klasifikasi dari prediksi data. Nilai TP dan TN menggambarkan seberapa akurat model dalam mengklasifikasikan data, sedangkan FP dan FN memberikan gambaran tentang kesalahan yang dibuat model.

3. HASIL DAN PEMBAHASAN


3.1 Hasil dan Analisis Pengujian

Pengujian model CNN dilakukan melalui dua pendekatan, yaitu CNN tanpa CLAHE dan CNN dengan CLAHE. Analisis performa dilakukan berdasarkan metrik evaluasi berupa akurasi, *precision*, *recall*, dan *f1-score*, serta disertai dengan visualisasi grafik akurasi dan *loss*, *confusion matrix*, dan sampel prediksi. Hasil evaluasi kedua model dirangkum pada Tabel 2, yang menampilkan perbandingan nilai akurasi, *precision*, *recall*, dan *f1-score* pada kelas Normal dan Pneumonia.


Tabel 2. Hasil Evaluasi Model

| Model | Accuracy (%) | Precision (%) | Normal | | Pneumonia | | |
|------------------|--------------|---------------|------------|--------------|---------------|------------|--------------|
| | | | Recall (%) | F1-Score (%) | Precision (%) | Recall (%) | F1-Score (%) |
| CNN Tanpa CLAHE | 0.96 | 0.95 | 0.97 | 0.96 | 0.97 | 0.95 | 0.96 |
| CNN dengan CLAHE | 0.99 | 0.99 | 1.00 | 1.00 | 1.00 | 0.99 | 1.00 |

Hasil numerik yang ditunjukkan pada tabel ini memperlihatkan adanya perbedaan signifikan antara kedua pendekatan. Model CNN tanpa CLAHE memperoleh akurasi sebesar 96,18%, dengan *precision* 95%, *recall* 97%, dan *f1-score* 96% pada kelas Normal, serta *precision* 97%, *recall* 95%, dan *f1-score* 96% pada kelas Pneumonia. Hasil ini menunjukkan bahwa model cukup seimbang dalam mengenali kedua kelas, meskipun masih terdapat kesalahan klasifikasi minor. Sementara itu, model CNN dengan CLAHE mencapai akurasi yang lebih tinggi, yakni 99,69%. Pada kelas Normal, metrik *precision*, *recall*, dan *f1-score* masing-masing mencapai 99%, 100%, dan 100%, sedangkan pada kelas Pneumonia diperoleh *precision* 100%, *recall* 99%, dan *f1-score* 100%. Peningkatan ini mengindikasikan bahwa penerapan CLAHE mampu meningkatkan sensitivitas dan spesifisitas model secara menyeluruh dalam membedakan pola radiologis citra.




Gambar 8. Grafik Akurasi (a) dan Loss (b) pada Model CNN Tanpa CLAHE



Gambar 9. Grafik Akurasi (a) dan Loss (b) pada Model CNN dengan CLAHE


Analisis lebih lanjut melalui grafik akurasi dan loss yang disajikan pada Gambar 8 untuk CNN tanpa CLAHE dan Gambar 9 untuk CNN dengan CLAHE juga menunjukkan perbedaan pola pelatihan di antara kedua model. Pada model tanpa CLAHE, akurasi meningkat secara stabil dari 51,26% hingga mencapai 95,08%, dengan *validation accuracy* tertinggi sebesar 96,18% pada epoch ke-6. Penurunan *loss* terjadi secara konsisten tanpa indikasi *overfitting*, menandakan proses pelatihan berlangsung stabil. Sebaliknya, pada model dengan CLAHE, akurasi meningkat lebih cepat, dimulai dari 60,46% dan mencapai 97,19% pada *training*. *Validation accuracy* bahkan langsung berada di atas 98% sejak *epoch* pertama dan mencapai puncaknya 99,69% pada epoch ke-5. Grafik *loss* juga menurun tajam dan konsisten, menunjukkan bahwa CLAHE tidak hanya mempercepat proses pembelajaran tetapi juga memperkuat kemampuan generalisasi model.



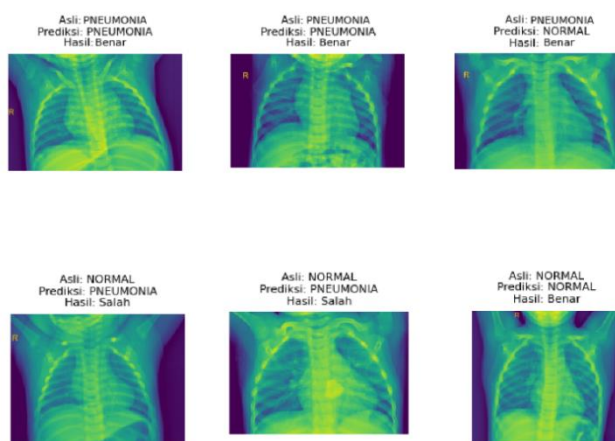
Gambar 10. Confusion Matrix Model CNN Tanpa CLAHE (a) dan dengan CLAHE (b)

Hasil klasifikasi lebih lanjut divisualisasikan melalui confusion matrix pada Gambar 10a untuk CNN tanpa CLAHE dan Gambar 10b untuk CNN dengan CLAHE, yang memperlihatkan detail distribusi prediksi benar dan salah. Pada CNN tanpa CLAHE, model menghasilkan 329 *true negative* dan 301 *true positive*, dengan kesalahan berupa 9 *false positive* dan 16 *false negative*. Kesalahan klasifikasi ini relatif kecil, namun tetap berimplikasi penting dalam konteks diagnosis klinis karena dapat menyebabkan *underdiagnosis* maupun *overdiagnosis*. Pada CNN dengan

CLAHE, performa meningkat signifikan dengan capaian 338 *true negative* dan 315 *true positive*, hanya menyisakan 2 *false negative* dan tanpa adanya *false positive*. Hal ini menegaskan bahwa CLAHE berhasil menekan tingkat kesalahan klasifikasi, khususnya dalam meningkatkan sensitivitas terhadap deteksi Pneumonia.



Gambar 11. Sampel Prediksi Tiap Kelas Tanpa CLAHE



Gambar 12. Sampel Prediksi Tiap Kelas dengan CLAHE

Untuk memperlihatkan keterbatasan dan kekuatan model secara lebih nyata, hasil prediksi ditampilkan pada Gambar 11 untuk CNN tanpa CLAHE dan Gambar 12 untuk CNN dengan CLAHE. Pada CNN tanpa CLAHE, kesalahan klasifikasi terjadi ketika citra Pneumonia menyerupai paru-paru normal tanpa infiltrasi jelas, atau citra Normal menampilkan pola kontras yang menyerupai infeksi, sehingga membingungkan model. Sebaliknya, pada CNN dengan CLAHE, sebagian besar citra berhasil diklasifikasikan dengan benar, meskipun masih terdapat sedikit kesalahan akibat kemiripan pola visual yang sangat halus. Peningkatan kontras yang dihasilkan CLAHE membantu mempertegas struktur anatomi paru-paru sehingga model lebih efektif dalam mengekstraksi fitur pembeda dan memberikan hasil klasifikasi yang lebih akurat. Dengan demikian, hasil pengujian ini secara konsisten menunjukkan bahwa penerapan CLAHE mampu meningkatkan kualitas klasifikasi CNN dalam mendeteksi Pneumonia berdasarkan citra X-ray dada.

3.2 Pembahasan dan Hasil

Hasil pengujian menunjukkan adanya perbedaan performa yang cukup signifikan antara model CNN tanpa CLAHE dan model CNN dengan CLAHE. Pada model tanpa CLAHE, meskipun akurasi sudah mencapai lebih dari 96%, masih terdapat sejumlah kesalahan klasifikasi yang dapat diamati melalui *confusion matrix* maupun sampel prediksi. Kesalahan ini umumnya terjadi pada citra Pneumonia yang tampak menyerupai paru-paru normal tanpa infiltrasi yang jelas, sehingga model cenderung salah mengklasifikasikannya sebagai Normal, *false negative*. Kondisi serupa juga terjadi pada sebagian citra Normal yang memiliki pola kontras menyerupai infeksi, sehingga memicu prediksi keliru sebagai Pneumonia, *false positive*. Jenis kesalahan ini mengindikasikan bahwa model kesulitan mengenali pola radiologis yang halus apabila kualitas kontras citra terbatas.

Penerapan CLAHE secara signifikan memperbaiki permasalahan tersebut. Dengan meningkatkan kontras lokal pada citra X-ray, CLAHE membuat detail radiologis seperti infiltrasi, opasitas, dan batas anatomi paru-paru lebih jelas

terlihat. Hal ini membantu model dalam mengekstraksi fitur yang relevan sehingga pola visual yang sebelumnya samar dapat dipisahkan dengan lebih tegas. Dampaknya terlihat pada berkurangnya jumlah *false negative* maupun *false positive*, model dengan CLAHE hampir mendekati performa sempurna dengan akurasi 99,69% dan tidak menghasilkan kesalahan prediksi pada kelas Normal.

Perbedaan jenis kesalahan juga penting dicermati. Tanpa CLAHE, kesalahan model lebih sering terjadi pada kasus Pneumonia ringan atau citra dengan kualitas pencahayaan rendah, di mana tanda-tanda infeksi tidak begitu kontras. Setelah penerapan CLAHE, citra-citra tersebut mengalami peningkatan visibilitas sehingga infiltrasi atau bercak abnormal lebih mudah dikenali oleh model. Demikian pula, citra Normal yang sebelumnya salah terklasifikasi karena memiliki pola kontras samar menjadi lebih jelas strukturnya, sehingga risiko *false positive* dapat ditekan.

Secara keseluruhan, pembahasan ini menunjukkan bahwa efektivitas CLAHE terletak pada kemampuannya menormalkan distribusi intensitas lokal dan mempertegas fitur penting pada citra X-ray. Dengan demikian, CLAHE bukan hanya meningkatkan akurasi numerik model, tetapi juga berkontribusi langsung dalam mengurangi jenis kesalahan klasifikasi yang paling krusial dalam konteks diagnosis klinis, yaitu salah mendeteksi Pneumonia sebagai Normal atau sebaliknya.

3.3 Perbandingan dengan Penelitian Terdahulu

Hasil penelitian ini membuktikan bahwa penerapan CLAHE dengan *hyperparameter clipLimit 2.0* dan *tileGridSize 8×8* mampu meningkatkan performa model CNN dalam klasifikasi citra X-ray pneumonia. Model CNN yang diimplementasikan dalam penelitian ini terdiri atas delapan lapisan, *convolutional layer*, *pooling layer*, *fully connected layer*, dan *dropout*, serta dilatih menggunakan *optimizer Adam* dengan fungsi *loss binary cross-entropy*. Akurasi model meningkat dari CNN tanpa CLAHE, yaitu 96,18% menjadi 99,69% dengan tambahan metode CLAHE. Efektivitas pelatihan berlangsung stabil melalui penerapan *early stopping* dan augmentasi data yang terdiri dari normalisasi, rotasi, *flipping*, dan *resizing*, sehingga meskipun jumlah *epoch* maksimum ditetapkan 20, proses pelatihan berhenti lebih awal setelah konvergensi tercapai.

Jika dibandingkan dengan penelitian sebelumnya, hasil ini menunjukkan perbedaan yang signifikan. Penelitian yang dilakukan oleh Surya Adi Widiarto, Wahyu Andi Saputra, dan Atika Ratna Dewi menggunakan CLAHE dengan *clipLimit* hanya sebesar 1.0 dan *tileGridSize 8×8*, untuk arsitektur CNN menggunakan dua hingga tiga lapisan konvolusi. Meskipun akurasi mencapai 95,21%, model tersebut membutuhkan pelatihan hingga 180 *epoch* sehingga kurang efisien. Penelitian Harshvardhan GM, Mahendra Kumar Gourisaria Siddharth Swarup Rautaray, dan Manjusha Pandey menggunakan CNN tanpa peningkatan kontras, menghasilkan akurasi 93,00%, yang menunjukkan ketergantungan pada kualitas citra asli dan pada pelatihannya tidak menggunakan *hyperparameter optimizer*. Fairouz Hussein, Ala Mughaid, Shadi AlZu'bi, Subhieh M. El-Salhi, Belal Abuhaija, Laith Abualigah, dan Amir H. Gandomi mencapai akurasi penelitian sebesar 96,40% dengan menggunakan CNN, sembilan hingga sepuluh lapisan dengan mengandalkan tuning manual serta menggunakan penerapan CLAHE, akan tetapi kontrol parameternya tidak ditekankan sehingga dapat berpotensi menimbulkan *noise* pada area homogen. Sementara itu, Cathryn Usman, Saeed Ur Rehman, Anwar Ali, Adil Mehmood Khan, dan Baseer Ahmad memperoleh akurasi 79,00% tanpa tahap pra-pemrosesan data pada *dataset* RSNA, yang menunjukkan rendahnya kemampuan generalisasi model. Patrick Szepesi dan László Szilágyi mencapai akurasi 97,20% dengan menggunakan *dropout* pada CNN, namun tanpa CLAHE, sehingga performa model tetap bergantung pada kualitas asli citra. Perbandingan hasil penelitian terdahulu dengan metode yang diusulkan dalam penelitian secara ringkas ditampilkan pada Tabel 3, mencakup metode, teknik pra-pemrosesan, dataset, capaian akurasi, dan catatan penelitian.

Tabel 3. Perbandingan Hasil Penelitian Terkait Klasifikasi Pneumonia Menggunakan CNN

| Peneliti (Tahun) | Metode / Model | Teknik Pra-pemrosesan | Dataset | Akurasi (%) | Catatan |
|--|----------------|-----------------------|---|-------------|---|
| Surya Adi Widiarto, Wahyu Andi Saputra, Atika Ratna Dewi (2023) | CNN | CLAHE | Citra X-ray Toraks Publik | 0.95 | Arsitektur dengan 2 – 3 lapisan, konfigurasi CLAHE statis, membutuhkan <i>epoch</i> tinggi sehingga kurang efisien. |
| Harshvardhan GM, Mahendra Kumar Gourisaria Siddharth Swarup Rautaray, Manjusha Pandey (2022) | CNN | Tanpa CLAHE | Dataset X-ray Pneumonia Guangzhou Women and Children's Medical Center | 0.93 | Tanpa peningkatan kontras, hasil cukup baik namun sangat tergantung pada kualitas citra asli. |
| Fairouz Hussein, Ala Mughaid, Shadi AlZu'bi, Subhieh M. El-Salhi, Belal Abuhaija, Laith | CNN | CLAHE | Kompilasi Dataset Publik Citra X-ray Penyakit Paru | 0.96 | Dengan menggunakan CLAHE detail anatomi meningkat, akan tetapi jika parameter CLAHE tidak disesuaikan dengan |

| Peneliti (Tahun) | Metode / Model | Teknik Pra-pemrosesan | Dataset | Akurasi (%) | Catatan |
|---|----------------|-----------------------|---|-------------|--|
| Abualigah, Amir H. Gandomi (2022) | | | | | karakteristik citra, risiko munculnya <i>noise</i> tetap ada. |
| Cathryn Usman, Saeed Ur Rehman, Anwar Ali, Adil Mehmood Khan, Baseer Ahmad (2025) | CNN | Tanpa CLAHE | RSNA Pneumonia <i>Detection Challenge</i> , NIH <i>Clinical Centre Chest X-ray Images</i> , | 0.79 | Tanpa pra-pemrosesan data dan Augmentasi, akurasi rendah serta generalisasi model terbatas. |
| Patrick Szepesi, László Szilágyi (2022) | CNN | Tanpa CLAHE | <i>Pneumonia (Kaggle)</i> , Guangzhou <i>Women and Children's Medical Center Chest X-ray Images</i> , | 0.97 | <i>Dropout</i> di layer konvolusi efektif mengurangi <i>overfitting</i> . Hasil klasifikasi sangat tinggi, namun tanpa peningkatan CLAHE, model tetap bergantung pada kualitas asli citra. |
| Rancangan Model yang Diusulkan pada Penelitian | CNN | Tanpa CLAHE | <i>Pneumonia (Kaggle)</i> , Guangzhou <i>Women and Children's Medical Center Chest X-ray Images</i> , | 0.96 | Pembuktian kuat bahwa CLAHE meningkatkan kualitas kontras dan performa CNN secara signifikan pada seluruh metrik evaluasi klasifikasi. |
| | | CLAHE | <i>Pneumonia (Kaggle)</i> , Guangzhou <i>Women and Children's Medical Center Chest X-ray Images</i> , | 0.99 | |

Hal ini mengindikasikan bahwa rancangan model yang diusulkan dalam penelitian ini, yang menggabungkan penerapan CLAHE dengan *clipLimit* 2.0 dan CNN dengan delapan *layer* yang melalui tahap augmentasi, optimalisasi *Adam*, pelatihan 20 *epoch* dan juga *early stopping* terbukti lebih unggul dari sisi performa akurasi dan efisiensi. Pendekatan ini tidak hanya menunjukkan peningkatan hasil evaluasi, tetapi juga membuktikan bahwa peningkatan kualitas kontras citra dapat dicapai tanpa memerlukan arsitektur model yang kompleks.

4. KESIMPULAN

Penelitian ini menunjukkan bahwa penerapan metode *Contrast Limited Adaptive Histogram Equalization*, CLAHE, pada tahapan pra-pemrosesan data citra terbukti memberikan kontribusi signifikan dalam meningkatkan performa model *Convolutional Neural Network*, CNN, dalam klasifikasi citra X-ray dada untuk deteksi pneumonia. Berdasarkan hasil evaluasi, model CNN tanpa CLAHE memperoleh akurasi sebesar 96,18%, sedangkan model dengan CLAHE mencapai akurasi yang lebih tinggi, yaitu 99,69%. Selain peningkatan akurasi, nilai *precision*, *recall*, dan *f1-score* juga meningkat secara konsisten, menunjukkan bahwa kinerja model yang lebih stabil dan andal dalam mengenali pola patologis pada citra X-ray dada. Hal ini menunjukkan bahwa efektivitas klasifikasi tidak hanya dipengaruhi oleh kompleksitas arsitektur model *deep learning*, tetapi juga sangat bergantung pada kualitas input citra yang ditingkatkan melalui tahapan pra-pemrosesan data yang tepat. CLAHE mampu meningkatkan kontras visual tanpa menimbulkan *noise* berlebih, sehingga memperkuat proses ekstraksi fitur oleh model. Dengan menghasilkan citra yang lebih tajam dan representatif secara struktural, proses pelatihan menjadi lebih efisien. Dengan demikian, penggunaan CLAHE dapat direkomendasikan sebagai penerapan yang efisien yang baik untuk meningkatkan akurasi deteksi pneumonia, khususnya pada model *deep learning* yang diimplementasikan dalam lingkungan dengan keterbatasan sumber daya komputasi.

REFERENCES

- [1] S. M. Waruwu, L. A. Zega, L. Harefa, F. K. Ndraha, and N. K. Lase, "Analisis Bahan Ajar Anatomi Fisiologi Tubuh Manusia (Karya Daniel Suranta Ginting, Et Al)," *Indo-MathEdu Intellectuals J.*, vol. 5, no. 3, pp. 4074–4086, 2024, doi: 10.54373/imej.v5i3.1462.
- [2] S. Hooli, C. King, E. D. McCollum, et al., "In-hospital Mortality Risk Stratification in Children Under 5 Years Old with Pneumonia with or without Pulse Oximetry: A Secondary Analysis of the Pneumonia Research Partnership to Assess WHO Recommendations," *International Journal of Infectious Diseases*, vol. 129, pp. 240–250, 2023, doi: 10.1016/j.ijid.2023.02.025.
- [3] International Vaccine Access Center, "Tracking Progress Toward Pneumonia and Diarrhea Control," *Johns Hopkins Bloomberg School of Public Health*, Baltimore, MD, USA, Nov. 2024. [Online]. Available: <https://publichealth.jhu.edu/ivac/2024/tracking-progress-toward-pneumonia-and-diarrhea-control>
- [4] M. Atnang, Samsidar, and S. B. Mustamin, "Pemanfaatan Teknologi Telemedicine untuk Peningkatan Diagnosis Pneumonia Anak di Daerah Terpencil," *Jurnal Teknologi dan Sains Modern*, vol. 2, no. 1, pp. 48–57, 2025, [Online]. Available: <https://journal.scitechgrup.com/index.php/jtsm/article/view/314>
- [5] M. Mukhtar, "Cakupan Imunisasi Dasar Bayi Sebelum dan Saat Pandemi COVID-19 di Kecamatan Kota Juang Kabupaten



- Bireuen,” *J. Kedokt. Syiah Kuala*, vol. 22, no. 1, pp. 60–67, 2022, doi: 10.24815/jks.v22i1.23096.
- [6] Ma’sum, P. Sarnianto, and N. Andayani, “Analisis Efektivitas Biaya Pengobatan Pneumonia Anak Berdasarkan Clinical Pathway di RSUD Kabupaten Tangerang,” *Jurnal Mandala Pharmacoon Indonesia*, vol. 9, no. 2, pp. 604–612, 2023, doi: 10.35311/jmpi.v9i2.429.
- [7] N. Nurhaeni, S. E. Prastya, A. Hidayat, dan F. N. Anisa, “Pemodelan Sistem Deteksi Parasit Malaria pada Citra Mikroskopis Sel Darah Menggunakan Metode Deep Learning,” *SMATIKA Jurnal: STIKI Informatika Jurnal*, vol. 14, no. 2, pp. 409–416, 2024, doi: 10.32664/smatika.v14i02.1475.
- [8] L. Pinto-Coelho, “How Artificial Intelligence Is Shaping Medical Imaging Technology: A Survey of Innovations and Applications,” *Bioengineering*, vol. 10, no. 12, 2023, doi: 10.3390/bioengineering10121435.
- [9] D. Gunawan and H. Setiawan, “Convolutional Neural Network dalam Citra Medis,” *KONSTELASI Konvergensi Teknol. dan Sist. Inf.*, vol. 2, no. 2, pp. 376–390, 2022, doi: 10.24002/konstelasi.v2i2.5367.
- [10] A. D. Azzumzumi, M. Hanafi, and W. M. P. Dhuhita, “Klasifikasi Penyakit Paru-Paru Berdasarkan Peningkatan Kualitas Kontras dan EfficientNet Menggunakan Gambar X-Ray,” *Teknika*, vol. 13, no. 2, pp. 293–300, 2024, doi: 10.34148/teknika.v13i2.881.
- [11] S. Sriani and A. Nabila, “Implementasi Deep Learning Untuk Mengidentifikasi Umur Manusia Menggunakan Convolutional Neural Network (CNN),” *J. Inform. dan Tek. Elektro Terap.*, vol. 12, no. 3, pp. 1836–1843, 2024, doi: 10.23960/jitet.v12i3.4457.
- [12] S. Solihat, S. Widodo, and D. P. Sari, “Analisis Perbandingan Optimizer pada Pelatihan Model Convolutional Neural Network untuk Kasus Klasifikasi Hewan Primata,” *J. Media Inform. Budidarma*, vol. 8, no. 1, p. 459, 2024, doi: 10.30865/mib.v8i1.7274.
- [13] T. Tsuji, Y. Hirata, K. Kusunose, M. Sata, S. Kumagai, K. Shiraishi, and J. Kotoku, “Classification of Chest X-Ray Images by Incorporation of Medical Domain Knowledge Into Operation Branch Networks,” *BMC Medical Imaging*, vol. 23, art. 62, 2023, doi: 10.1186/s12880-023-01019-0.
- [14] H. Gm, M. K. Gourisaria, S. S. Rautaray, and M. Pandey, “Pneumonia Detection Using CNN Through Chest X-Ray,” *Journal of Engineering Science and Technology*, vol. 16, no. 1, pp. 861–876, 2021.
- [15] C. Usman, S. U. Rehman, A. Ali, A. M. Khan, and B. Ahmad, “Pneumonia Disease Detection Using Chest X-Rays and Machine Learning,” *Algorithms*, vol. 18, no. 2, 2025, doi: 10.3390/a18020082.
- [16] P. Szepesi and L. Szilágyi, “Detection of pneumonia using convolutional neural networks and deep learning,” *Biocybern. Biomed. Eng.*, vol. 42, no. 3, pp. 1012–1022, 2022, doi: 10.1016/j.bbe.2022.08.001.
- [17] N. Wiliani, T. Khawa, and S. Ramli, “Peningkatan Kontras Pada Preprocessing Gambar Permukaan Solar Panel dengan Histogram,” *Innov. Technol.*, vol. 2, no. 1, pp. 1–8, 2025.
- [18] J. Hidayat and A. Fitriani, “Perbandingan Metode Power Law Dengan Contrast Limited Adaptive Histogram Equalization (Clahe) Pada Perbaikan Kualitas Citra Satelit,” *J. Tek. Elektro*, vol. 8, no. 1, 2025.
- [19] W. Juslan and A. H. Muhammad, “Evaluasi Kinerja Metode Peningkatan Kontras (CLAHE & HE) pada Klasifikasi Ras Kucing menggunakan VGG16,” *Edumatic J. Pendidik. Inform.*, vol. 9, no. 1, pp. 246–255, 2025, doi: 10.29408/edumatic.v9i1.29578.
- [20] M. R. Pratama, S. Z. Hidayat, A. R. Nuruddin, H. W. Niamaputri, and K. Kunci, “Optimasi Peningkatan Kontras Gambar Menggunakan Interval-Valued Intuitionistic Fuzzy Sets dan Contrast Limited Adaptive Histogram Equalization (CLAHE),” vol. 4, no. 1, pp. 307–317, 2025, doi: 10.31284/p.semtik.2025-1.6884.
- [21] A. F. Nurjannah, A. S. D. Kurniasari, Z. Sari, and Y. Azhar, “Pneumonia Image Classification Using CNN With Max Pooling and Average Pooling,” *J. RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 6, no. 2, pp. 330–338, 2022, doi: 10.29207/resti.v6i2.4001.
- [22] S. A. Widiarto, W. A. Saputra, and A. R. Dewi, “Klasifikasi Citra X-Ray Toraks Dengan Menggunakan Contrast Limited Adaptive Histogram Equalization Dan Convolutional Neural Network (Studi Kasus: Pneumonia),” *JIPi (Jurnal Ilm. Penelit. dan Pembelajaran Inform.)*, vol. 6, no. 2, pp. 348–359, 2021, doi: 10.29100/jipi.v6i2.2102.
- [23] F. Hussein *et al.*, “Hybrid CLAHE-CNN Deep Neural Networks for Classifying Lung Diseases from X-ray Acquisitions,” *Electron.*, vol. 11, no. 19, pp. 1–18, 2022, doi: 10.3390/electronics11193075.
- [24] N. W. S. Saraswati, D. A. P. R. Dewi, and P. Pirozmand, “Comparative Analysis of SVM and CNN for Pneumonia Detection in Chest X-Ray,” *Lontar Komputer: Jurnal Ilmiah Teknologi Informasi*, vol. 15, no. 1, pp. 38–50, 2024, doi: 10.24843/LKJITI.2024.v15.i01.p04.
- [25] R. B. J. Simanjuntak, Y. Fu’Adah, R. Magdalena, S. Saidah, A. B. Wiratama, and I. Da’Wan Salim Ubaidah, “Cataract Classification Based on Fundus Images Using Convolutional Neural Network,” *Int. J. Informatics Vis.*, vol. 6, no. 1, pp. 33–38, 2022, doi: 10.30630/joiv.6.1.856.
- [26] S. A. Hakim *et al.*, “Klasifikasi Citra Generasi Artificial Intelligence menggunakan Metode Fine Tuning pada Residual Network,” *J. Teknol. Inf. dan Ilmu Komput.*, vol. 11, no. 3, pp. 655–666, 2024, doi: 10.25126/jtiik.1138118.
- [27] R. Nirthika, S. Manivannan, A. Ramanan, and R. Wang, “Pooling in Convolutional Neural Networks for Medical Image Analysis: A Survey and an Empirical Study,” *Neural Computing and Applications*, vol. 34, pp. 5321–5347, 2022, doi: 10.1007/s00521-022-06953-8.
- [28] B. R. Ermawan and N. Cahyono, “Optimasi Metode Klasifikasi Menggunakan Fasttext Dan Grid Search Pada Analisis Sentimen Ulasan Aplikasi Seabank,” *JIKO (Jurnal Inform. dan Komputer)*, vol. 9, no. 1, p. 226, 2025, doi: 10.26798/jiko.v9i1.1523.
- [29] S. Sharma, S. Gupta, D. Gupta, J. Rashid, S. Juneja, J. Kim, and M. M. Elarabawy, “Performance Evaluation of the Deep Learning Based Convolutional Neural Network Approach for the Recognition of Chest X-Ray Images,” *Frontiers in Oncology*, vol. 12, 2022, doi: 10.3389/fonc.2022.932496.