

Penerapan Convolutional Neural Network untuk Klasifikasi Penyakit Paru-Paru Berbasis Citra X-Ray Dada

Green Ferry Mandias^{1*}, Reynoldus Andrias Sahulata², Ivanna Junamel Manoppo³

¹ Universitas Klabat; green@unklab.ac.id

² Universitas Klabat; rey_sahulata@unklab.ac.id

³ Universitas Klabat; i.manoppo@unklab.ac.id

Abstrak: Penelitian ini bertujuan mengembangkan model Convolutional Neural Network (CNN) untuk mengklasifikasikan citra X-ray dada ke dalam tiga kategori, yaitu Lung Opacity, Normal, dan Viral Pneumonia. Model dikembangkan menggunakan dataset citra X-ray yang melalui tahap pra-pemrosesan meliputi normalisasi, augmentasi data, dan penyesuaian ukuran citra sebelum proses pelatihan. Evaluasi performa dilakukan menggunakan *confusion matrix*, *precision*, *recall*, *F1-score*, dan akurasi. Hasil penelitian menunjukkan bahwa model mencapai akurasi sebesar 89%, dengan performa terbaik pada kelas Viral Pneumonia yang memperoleh F1-score sebesar 95%. Meskipun masih ditemukan kesalahan klasifikasi antara kelas Lung Opacity dan Normal, model mampu menunjukkan kemampuan generalisasi yang baik dalam membedakan karakteristik visual ketiga kelas. Hasil penelitian menunjukkan bahwa arsitektur CNN yang diusulkan berpotensi digunakan sebagai baseline model untuk sistem computer-aided diagnosis (CAD) berbasis citra X-ray paru

Keywords: CNN; Klasifikasi Paru-Paru; X-Ray; Deep Learning

DOI: <https://doi.org/10.47134/jacis.v6i2.204>

*Correspondensi: Green Ferry Mandias

Email: green@unklab.ac.id

Receive: 30 Juni 2026

Accepted: 12 Juli 2026

Published: 14 Juli 2026



Copyright: © 2026 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license (<http://creativecommons.org/licenses/by/4.0/>).

Abstrak: This study proposes a Convolutional Neural Network (CNN) model for classifying chest X-ray images into three categories: Lung Opacity, Normal, and Viral Pneumonia. The model was developed using a chest X-ray dataset that underwent several preprocessing stages, including image normalization, data augmentation, and image resizing prior to the training process. Model performance was evaluated using a confusion matrix, precision, recall, F1-score, and accuracy metrics. The experimental results demonstrate that the proposed model achieved an overall accuracy of 89%, with the best performance obtained for the Viral Pneumonia class, achieving an F1-score of 95%. Although some misclassification occurred between the Lung Opacity and Normal classes due to their similar radiographic characteristics, the model exhibited good generalization capability in distinguishing the visual features of the three classes. These findings indicate that the proposed CNN architecture has the potential to serve as a baseline model for computer-aided diagnosis (CAD) systems based on chest X-ray imaging.

Keywords: CNN; Classification; X-Ray; Deep Learning

PENDAHULUAN

Penyakit paru-paru merupakan salah satu masalah Kesehatan terbesar di dunia yang mempengaruhi kualitas hidup Masyarakat saat ini. Menurut Kementerian Kesehatan, di Indonesia penyakit paru-paru merupakan masalah kesehatan yang paling utama, menyumbang 25,8% kematian akibat penyakit pernapasan [1]. Penyakit paru-paru seperti *pneumonia*, *tuberkulosis* (TB), *pneumotoraks*, dan *infiltrasi* memiliki gambar yang sering sulit dibedakan karena pola visual yang mirip pada pemeriksaan rontgen paru [2]. Salah satu penyebab kematian anak terbesar adalah pneumonia.

Diagnosis pneumonia menggunakan gambar CT-Scan dan X-ray [3], [4]. Gejala umum seperti batuk, demam, sesak nafas, dan kelainan pada jaringan paru-paru yang dapat dilihat pada pencitraan medis adalah tanda penyakit ini. Penyakit paru, terutama di Indonesia, masih menjadi perhatian utama di bidang kesehatan masyarakat [5], [6]. Sementara metode standar seperti RT-PCR memiliki keterbatasan sensitivitas dan tidak selalu tersedia secara merata, pemeriksaan klinis konvensional terkadang tidak cukup akurat [7]. Selain itu, subjektivitas dan resiko keterlambatan diagnosis dapat meningkat jika radiolog bergantung pada pemeriksaan manual [8]. Oleh karena itu, untuk meningkatkan keakuratan diagnosis penyakit paru, pengembangan teknik diagnosa yang cepat dan akurat sangat penting [9].

Berkat kemajuan teknologi AI (Kecerdasan Buatan) khususnya Convolutional Neural Network (CNN), analisis otomatis citra medis menjadi lebih efisien dan akurat, tetapi meskipun keduanya sangat akurat, keduanya tidak selalu tersedia karena biaya yang mahal dan keterbatasan peralatan [10], [11]. Citra X-ray dada merupakan alat yang paling umum digunakan untuk pemeriksaan paru-paru [12]. Meskipun lebih murah, mudah diakses, dan cepat, citra X-ray telah menjadi alat penting dalam pemeriksaan paru-paru. Namun, tenaga medis membutuhkan ketelitian dan pengalaman dalam proses pembacaannya. Kesalahan diagnosis dapat disebabkan oleh gambar yang buruk, kelelahan dokter, atau kompleksitas pola penyakit. X-ray menjadi alat bantu diagnosis yang semakin populer selama pandemi karena dapat menunjukkan kondisi paru-paru secara visual dan membantu membedakan pola abnormal pada jaringan paru-paru [13]. Banyak upaya telah dilakukan untuk menggunakan komputasi pada gambar X-ray untuk menghasilkan metode diagnosis yang lebih cepat dan akurat.

Penelitian sebelumnya telah menunjukkan bahwa berbagai arsitektur *deep learning* mampu memberikan kinerja yang baik dalam klasifikasi penyakit paru berbasis citra X-ray. Penelitian pada [14] mengkaji pengelompokan empat jenis penyakit paru menggunakan pendekatan dimensi fraktal dan algoritma Fuzzy C-Means, dengan akurasi mencapai 86%. Selanjutnya, penelitian pada [15], mengembangkan metode segmentasi citra paru menggunakan arsitektur EfficientNet sebagai dasar peningkatan kualitas proses analisis citra.


Untuk tugas klasifikasi empat kategori penyakit, yaitu Pneumonia, COVID-19, Normal, dan Tuberkulosis (TBC), Muhammad *et al* [16], mengombinasikan Convolutional Neural Network (CNN) dengan teknik *RGB Equalization* dan berhasil memperoleh akurasi sebesar 91%. Hasil yang lebih tinggi dilaporkan oleh Razief *et al* [17], yang menerapkan arsitektur MobileNet dengan metode prapemrosesan *Contrast Limited Adaptive Histogram Equalization* (CLAHE) sehingga mencapai akurasi sebesar 94.687%.

Selain itu, studi literatur yang komprehensif pada [18] menyimpulkan bahwa pendekatan *transfer learning* merupakan metode yang paling banyak digunakan dan terbukti efektif dalam meningkatkan performa klasifikasi penyakit paru berbasis citra X-ray. Temuan tersebut sejalan dengan penelitian sebelumnya [19], yang menunjukkan bahwa CNN memiliki kemampuan yang sangat baik dalam mengekstraksi karakteristik visual yang kompleks dari citra medis. Oleh karena itu, berbagai penelitian telah memanfaatkan beragam arsitektur CNN, seperti ResNet, MobileNet, DenseNet, dan VGG-16, untuk mengklasifikasikan penyakit paru dan COVID-19 [9], [20].

Meskipun berbagai penelitian sebelumnya telah menerapkan arsitektur *deep learning* seperti ResNet, DenseNet, dan MobileNet dengan pendekatan *transfer learning* untuk klasifikasi penyakit paru berbasis citra X-ray, sebagian besar metode tersebut masih bergantung pada model *pre-trained* yang kompleks dan membutuhkan sumber daya komputasi tinggi. Selain itu, belum banyak penelitian yang secara khusus mengevaluasi performa model CNN sederhana sebagai baseline pada skenario klasifikasi tiga kelas (Normal, *Lung Opacity*, dan *Viral Pneumonia*) dengan analisis kesalahan antar kelas yang memiliki kemiripan visual tinggi. Oleh karena itu, penelitian ini berfokus pada pengembangan model CNN dengan *pipeline preprocessing* terstandarisasi untuk mengidentifikasi performa dasar serta karakteristik kesalahan klasifikasi pada dataset X-ray paru. Kontribusi utama penelitian ini adalah penyediaan *baseline* CNN yang efisien, analisis kesalahan antar kelas, serta evaluasi performa pada dataset publik sebagai dasar pengembangan model yang lebih kompleks di masa mendatang.

METODE

Penelitian ini dilaksanakan melalui serangkaian tahapan sistematis yang mencakup pengumpulan dataset, pra-pemrosesan citra, augmentasi data, perancangan arsitektur CNN, proses pelatihan, serta evaluasi kinerja model. Setiap tahapan dirancang agar model dapat mempelajari pola visual pada citra X-ray dan melakukan klasifikasi penyakit paru secara optimal. Gambar 1 menunjukkan rangkaian metode penelitian.



Gambar 1. Metode Penelitian

Dataset

Dataset yang digunakan berasal dari Kaggle, yaitu *Curated Chest X-Ray Image Dataset for COVID-19 and Other Lung Diseases*. Dataset ini terdiri dari citra X-ray dada untuk tiga kelas, yaitu Lung Opacity, Normal, dan Viral Pneumonia. Jumlah data masing-masing kelas adalah: Lung Opacity: 225 citra, Normal: 250 citra dan Viral Pneumonia: 220 citra. Total data yang digunakan 695 citra. Dataset dibagi menjadi 70% data latih, 20% data validasi, dan 10% data uji secara acak untuk memastikan proses pelatihan dan evaluasi berjalan objektif. Karakteristik dataset berupa citra X-ray dada dengan variasi kualitas dan tingkat kemiripan tinggi antar kelas, khususnya antara Lung Opacity dan Normal.

Pra-Pemrosesan Citra

Tahap pra-pemrosesan dilakukan untuk menyiapkan data agar sesuai dengan kebutuhan arsitektur CNN serta meningkatkan kualitas proses pembelajaran model. Tahapan yang dilakukan meliputi:

1) Resizing

Pada tahapan ini seluruh citra X-ray diseragamkan ukurannya menjadi 224×224 piksel agar sesuai dengan input pada arsitektur CNN yang digunakan

2) Normalisasi Pixel

Nilai intensitas piksel dinormalisasi ke rentang 0 hingga 1. Proses ini bertujuan untuk mempercepat konvergensi selama pelatihan serta meningkatkan stabilitas proses optimasi model.

3) Konversi Warna

Seluruh citra dipastikan berada dalam format yang sesuai dengan kebutuhan model, baik grayscale maupun RGB, tergantung pada konfigurasi arsitektur CNN yang digunakan.

Arsitektur CNN

Penelitian ini menggunakan model *Convolutional Neural Network* (CNN) berbasis arsitektur *sequential* untuk klasifikasi citra X-ray dada ke dalam tiga kelas: *Lung Opacity*, *Normal*, dan *Viral Pneumonia*. Input citra berukuran $224 \times 224 \times 3$ dengan proses normalisasi nilai piksel.

Arsitektur CNN terdiri dari tiga blok konvolusi dengan konfigurasi sebagai berikut:

- 1) Conv2D 32 filter (3×3) + ReLU + MaxPooling (2×2)
- 2) Conv2D 64 filter (3×3) + ReLU + MaxPooling (2×2)
- 3) Conv2D 128 filter (3×3) + ReLU + MaxPooling (2×2)

Hasil ekstraksi fitur kemudian diratakan menggunakan *Flatten layer* dan diteruskan ke *fully connected layer* dengan 128 neuron serta aktivasi ReLU. Untuk mengurangi overfitting digunakan *dropout* sebesar 0.5.

Lapisan keluaran menggunakan *Dense layer* dengan 3 neuron dan aktivasi *softmax* untuk menghasilkan probabilitas masing-masing kelas.

Pemilihan kernel 3×3 , ReLU, dan max pooling didasarkan pada efektivitasnya dalam ekstraksi fitur lokal citra medis serta efisiensi komputasi. Arsitektur ini digunakan sebagai model baseline CNN tanpa ketergantungan pada transfer learning.

Augmentasi Data

Untuk meningkatkan variasi data dan mengurangi risiko overfitting, dilakukan augmentasi pada data latih dengan beberapa teknik transformasi citra secara acak. Teknik augmentasi yang digunakan meliputi:

- 1) Rotasi
- 2) Flip horizontal
- 3) Flip vertikal
- 4) Zoom
- 5) Shear
- 6) Shift lebar dan tinggi

Penerapan augmentasi data ini bertujuan untuk memperkaya variasi representasi citra sehingga model mampu mengenali pola penyakit paru dalam berbagai kondisi transformasi visual, serta meningkatkan kemampuan generalisasi model terhadap data baru.

Pelatihan Model

Proses pelatihannya dilakukan menggunakan data latih yang telah di augmentasi. Pada setiap epoch, nilai akurasi dan loss untuk data latih maupun validasi dipantau untuk melihat perkembangan proses pembelajaran. Dari hasil pelatihan, diperoleh peningkatan akurasi yang konsisten dan penurunan nilai loss yang stabil, menandakan bahwa tanpa mengalami overfitting yang signifikan model mampu memahami pola citra secara bertahap.

Evaluasi Model

Dengan beberapa metrik, evaluasi model dilakukan menggunakan data pengujian (tes set) yaitu:


- 1) Precision. Mengukur Tingkat ketepatan prediksi model pada suatu kelas. Precision menunjukkan rasio antara data yang benar-benar positif dibandingkan seluruh data prediksi sebagai positif. Tinggi precision berarti model tidak sering melakukan kesalahan *false positive*.

- 2) Recall. Mengukur kemampuan model dalam memperkirakan semua data yang benar-benar merupakan bagian dari satu kelas. Recall tinggi menunjukkan model memiliki kemampuan dalam meminimal *false negative*.
- 3) F1-score. F1-score adalah rata-rata harmonis antara precision dan recall. Metrik ini memberikan representasi yang lebih seimbang terhadap performa model, terutama Apabila distribusi data antarkelas tidak seimbang.
- 4) Confusion Matrik. Digunakan untuk melihat jumlah prediksi benar dan salah untuk setiap kelas, sehingga memudahkan analisis kesalahan dan performa spesifik per kelas.

HASIL DAN PEMBAHASAN

Performa Pelatihan Model

Penelitian ini menghasilkan model Convolutional Neural Network (CNN) yang digunakan untuk mengklasifikasikan citra X-ray dada ke dalam tiga kategori, yaitu Lung Opacity, Normal, dan Viral Pneumonia. Model dilatih selama 15 *epoch* menggunakan data pelatihan, kemudian dievaluasi menggunakan data validasi dan data uji untuk mengukur kemampuan generalisasi model terhadap citra yang belum pernah diamati sebelumnya. Evaluasi dilakukan melalui analisis kurva akurasi, *loss*, *confusion matrix*, serta metrik *precision*, *recall*, dan *F1-score*.




Gambar 2. Grafik Akurasi Training dan Validasi

Gambar 2 memperlihatkan perkembangan akurasi selama proses pelatihan. Akurasi *training* meningkat secara bertahap dari sekitar 81% pada *epoch* pertama menjadi sekitar 91% pada *epoch* terakhir. Sementara itu, akurasi *validation* berada pada rentang 86%–89% dengan fluktuasi yang relatif kecil.

Selisih akurasi antara data *training* dan *validation* yang tidak terlalu besar menunjukkan bahwa model memiliki kemampuan generalisasi yang baik. Kondisi tersebut mengindikasikan bahwa model tidak hanya mempelajari karakteristik data pelatihan (*memorization*), tetapi juga mampu mempertahankan performa pada data yang belum pernah digunakan selama proses pelatihan. Dengan demikian, tidak ditemukan indikasi *overfitting* yang signifikan pada model yang diusulkan.

Selain itu, peningkatan akurasi yang berlangsung secara bertahap menunjukkan bahwa proses pembelajaran berlangsung stabil. Hal ini mengindikasikan bahwa arsitektur CNN mampu mengekstraksi fitur visual penting dari citra X-ray, seperti pola tekstur, batas jaringan paru, dan area opasitas, sehingga representasi fitur yang dihasilkan semakin baik pada setiap *epoch*.



Gambar 3. Loss Training dan Validation


Gambar 3 menunjukkan perubahan nilai *loss* selama proses pelatihan. Nilai *training loss* mengalami penurunan secara konsisten dari sekitar 0,48 menjadi 0,23, sedangkan *validation loss* juga cenderung menurun meskipun terdapat fluktuasi pada beberapa *epoch*.

Fluktuasi pada *validation loss* merupakan fenomena yang umum dijumpai dalam proses pelatihan model *deep learning*, terutama ketika model mulai beradaptasi terhadap variasi karakteristik data validasi. Meskipun demikian, tidak terlihat adanya peningkatan *loss* yang terus-menerus ataupun divergensi yang signifikan antara kurva *training* dan *validation*. Hal ini menunjukkan bahwa proses optimasi berjalan dengan baik dan model mampu mempertahankan performa yang stabil selama proses pelatihan.

Secara keseluruhan, hasil pelatihan menunjukkan bahwa model telah mencapai konvergensi dengan baik sehingga layak digunakan pada tahap evaluasi menggunakan data uji.

Evaluasi Menggunakan Confusion Matrix

Evaluasi performa model dilakukan menggunakan *confusion matrix* dan metrik evaluasi berupa *precision*, *recall*, serta *F1-score*. Pendekatan ini memberikan gambaran yang lebih komprehensif mengenai kemampuan model dibandingkan hanya menggunakan nilai akurasi, karena mampu menunjukkan distribusi kesalahan klasifikasi pada masing-masing kelas.



Gambar 4 Confusion Matrix

Berdasarkan Gambar 4, model menunjukkan performa terbaik pada kelas Viral Pneumonia dengan 212 prediksi benar dari 220 data uji atau sekitar 96,4%. Tingginya tingkat keberhasilan tersebut mengindikasikan bahwa karakteristik visual Viral Pneumonia memiliki pola yang relatif khas sehingga lebih mudah dipelajari oleh CNN.

Pada kelas Normal, model berhasil mengklasifikasikan 219 dari 250 citra secara benar (87,6%), sedangkan 20 citra diprediksi sebagai Lung Opacity dan 11 citra sebagai Viral Pneumonia. Sementara itu, pada kelas Lung Opacity, model berhasil mengklasifikasikan 186 dari 225 citra secara benar (82,7%), dengan kesalahan terbesar berupa 38 citra yang diprediksi sebagai Normal.

Kesalahan klasifikasi yang dominan antara Lung Opacity dan Normal menunjukkan bahwa kedua kelas memiliki karakteristik radiologis yang saling beririsan, terutama pada kasus opasitas ringan yang hanya menunjukkan perubahan densitas kecil pada citra X-ray. Kondisi tersebut menyebabkan CNN menghasilkan representasi fitur yang masih memiliki tingkat kemiripan sehingga meningkatkan kemungkinan terjadinya kesalahan klasifikasi.

Sebaliknya, jumlah kesalahan prediksi antara Lung Opacity dan Viral Pneumonia relatif kecil. Hal ini menunjukkan bahwa model mampu membedakan karakteristik visual kedua penyakit tersebut dengan cukup baik.

Tabel 1. Hasil Evaluasi Model CNN

Kelas	Precision	Recall	F1-score	Support
Lung_Opacity	0.89	0.83	0.86	225
Normal	0.83	0.88	0.85	250
Viral Pneumonia	0.95	0.96	0.95	220

Hasil evaluasi menggunakan *precision*, *recall*, dan *F1-score* disajikan pada Tabel 1. Nilai *F1-score* pada seluruh kelas berada pada rentang 0,85–0,95, menunjukkan bahwa model mampu menjaga keseimbangan antara ketepatan prediksi (*precision*) dan kemampuan mendeteksi seluruh sampel pada masing-masing kelas (*recall*).

Pada kelas Lung Opacity, diperoleh *precision* sebesar 0,89 dan *recall* sebesar 0,83. Perbedaan kedua metrik tersebut menunjukkan bahwa model relatif konservatif ketika memberikan prediksi Lung Opacity. Ketika model memprediksi suatu citra sebagai Lung Opacity, prediksi tersebut umumnya benar. Namun demikian, masih terdapat sejumlah citra Lung Opacity yang diklasifikasikan sebagai Normal sehingga menurunkan nilai *recall*.

Pada kelas Normal, model memperoleh *precision* sebesar 0,83 dan *recall* sebesar 0,88. Nilai *recall* yang lebih tinggi menunjukkan bahwa sebagian besar citra normal berhasil dikenali. Akan tetapi, nilai *precision* yang lebih rendah mengindikasikan masih terdapat citra dari kelas lain yang diprediksi sebagai Normal. Hasil tersebut konsisten dengan *confusion matrix* yang menunjukkan bahwa sebagian besar kesalahan klasifikasi terjadi antara kelas Normal dan Lung Opacity.

Performa terbaik diperoleh pada kelas Viral Pneumonia dengan *precision* sebesar 0,95, *recall* sebesar 0,96, dan *F1-score* sebesar 0,95. Hasil tersebut menunjukkan bahwa model mampu mengenali pola visual Viral Pneumonia secara konsisten dengan tingkat kesalahan yang sangat rendah.

Pembahasan

Secara keseluruhan, model Convolutional Neural Network (CNN) yang dikembangkan berhasil mencapai akurasi pengujian sebesar 89%, dengan nilai *F1-score* di atas 0,85 pada seluruh kelas. Hasil tersebut menunjukkan bahwa model memiliki kemampuan yang baik dalam mengekstraksi fitur-fitur penting dari citra X-ray dada untuk membedakan tiga kategori penyakit paru, yaitu Lung Opacity, Normal, dan Viral Pneumonia. Kemampuan CNN dalam mempelajari representasi fitur secara hierarkis, mulai dari tepi (*edges*), tekstur, hingga pola patologis yang lebih kompleks, menjadi salah satu faktor utama yang mendukung keberhasilan klasifikasi citra medis berbasis X-ray [21].

Meskipun demikian, performa model belum merata pada seluruh kelas. Berdasarkan hasil *confusion matrix* dan metrik evaluasi, kesalahan klasifikasi masih didominasi oleh pertukaran prediksi antara kelas Lung Opacity dan Normal. Fenomena ini menunjukkan bahwa kedua kelas memiliki karakteristik radiologis yang saling beririsan, terutama pada kasus Lung Opacity dengan tingkat keparahan ringan yang hanya menampilkan perubahan densitas paru secara halus. Akibatnya, model mengalami kesulitan dalam membangun representasi fitur yang benar-benar diskriminatif. Kondisi serupa juga telah dilaporkan pada

penelitian sebelumnya, yang menyatakan bahwa kemiripan karakteristik visual antara citra Normal dan Lung Opacity merupakan salah satu tantangan utama dalam klasifikasi otomatis penyakit paru berbasis citra X-ray [22].

Jika dibandingkan dengan penelitian sebelumnya, akurasi sebesar 89% yang diperoleh pada penelitian ini lebih tinggi dibandingkan pendekatan berbasis dimensi fraktal dan Fuzzy C-Means yang mencapai 86% [14] Namun demikian, performa tersebut masih sedikit berada di bawah beberapa pendekatan berbasis *transfer learning*, seperti CNN dengan teknik RGB Equalization yang mencapai akurasi 91% [16] maupun MobileNet yang dipadukan dengan CLAHE dengan akurasi 94,687% [17]. Perbedaan tersebut diduga dipengaruhi oleh kemampuan model *transfer learning* dalam memanfaatkan representasi fitur yang telah dipelajari dari dataset berskala besar (*pre-trained models*), sehingga mampu menghasilkan kemampuan diskriminasi yang lebih tinggi dibandingkan CNN yang dilatih dari awal (*training from scratch*). Temuan ini juga sejalan dengan berbagai studi terkini yang menyimpulkan bahwa pendekatan *transfer learning* secara umum memberikan peningkatan performa pada klasifikasi citra X-ray karena mampu mempercepat proses konvergensi sekaligus meningkatkan kemampuan generalisasi model [22].

Meskipun demikian, penelitian ini menunjukkan bahwa arsitektur CNN yang relatif sederhana tetap mampu menghasilkan performa yang kompetitif dengan kompleksitas komputasi yang lebih rendah. Hal ini menjadi keunggulan tersendiri, terutama untuk implementasi pada sistem computer-aided diagnosis (CAD) di fasilitas pelayanan kesehatan yang memiliki keterbatasan sumber daya komputasi. Dengan demikian, model yang diusulkan berpotensi digunakan sebagai baseline model yang efisien sebelum dikembangkan lebih lanjut menggunakan arsitektur yang lebih kompleks.

Penelitian ini masih memiliki beberapa keterbatasan. Model hanya mengevaluasi tiga kategori penyakit paru dan menggunakan arsitektur CNN dasar tanpa memanfaatkan mekanisme *attention*, *ensemble learning*, maupun *transfer learning*. Selain itu, evaluasi masih terbatas pada satu dataset sehingga kemampuan generalisasi model terhadap data dari institusi atau perangkat radiografi yang berbeda belum dapat dipastikan. Oleh karena itu, penelitian selanjutnya dapat mengembangkan model menggunakan arsitektur yang lebih mutakhir, seperti DenseNet, EfficientNet, MobileNet, atau Vision Transformer, serta mengombinasikannya dengan teknik augmentasi data, optimasi hiperparameter, dan validasi pada dataset multisentra untuk meningkatkan kemampuan klasifikasi, khususnya pada kelas-kelas yang memiliki karakteristik visual serupa.

SIMPULAN

Berdasarkan hasil penelitian, model Convolutional Neural Network (CNN) berhasil mengklasifikasikan citra X-ray paru ke dalam tiga kategori, yaitu Lung Opacity, Normal, dan Viral Pneumonia, dengan akurasi pengujian sebesar 89%. Hasil evaluasi menggunakan

confusion matrix, *precision*, *recall*, dan *F1-score* menunjukkan bahwa model memiliki performa yang baik pada seluruh kelas, dengan hasil terbaik pada kelas Viral Pneumonia. Temuan ini menunjukkan bahwa CNN mampu mengekstraksi fitur-fitur penting dari citra X-ray sehingga efektif digunakan sebagai metode klasifikasi penyakit paru.

Meskipun demikian, model masih mengalami kesalahan klasifikasi antara kelas Lung Opacity dan Normal akibat kemiripan karakteristik visual pada kedua kelas tersebut. Secara keseluruhan, model yang diusulkan memiliki potensi sebagai baseline model dalam sistem *computer-aided diagnosis* berbasis citra X-ray. Penelitian selanjutnya dapat difokuskan pada penerapan arsitektur *deep learning* yang lebih mutakhir, optimasi hiperparameter, serta penggunaan dataset yang lebih beragam untuk meningkatkan kemampuan generalisasi model

DAFTAR PUSTAKA

- [1] D. R. Aldiansyah and M. Soleh, "Analisa Performa Arsitektur Model Convolutional Neural Network Dengan Variasi Jumlah Hidden Layer Untuk Klasifikasi Tuberculosis Pada Citra X-Ray," *J. Fasilkom*, vol. 14, no. 3, pp. 729–734, 2024, doi: 10.37859/jf.v14i3.7949.
- [2] A. N. D. Afkar, A. Rachmad, and E. M. S. Rochman, "Klasifikasi Pneumonia Dengan Metode Convolutional Neural Network," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 9, no. 4, pp. 5821–5828, 2025, doi: 10.36040/jati.v9i4.13938.
- [3] M. Adzkia, F. Arland, and A. W. Setiawan, "Deteksi Pneumonia Menggunakan Citra Sinar-X Paru Berbasis Residual Network," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 9, no. 2, pp. 373–380, 2022, doi: 10.25126/jtiik.202295626.
- [4] T. Arifin and N. H. Surya, "Klasifikasi X - Ray Pneumonia dengan Metode Konvolusi Neural Network menggunakan Arsitektur VGG X-Ray," *Sitemasi J. Sist. Inf.*, vol. 11, no. 3, pp. 560–566, 2022, doi: 10.32520/stmsi.v11i3.1597.
- [5] P. Rahmadewi, J. Y. K. Harahap, and E. Indra, "Algoritma Deep Learning untuk Pengklasifikasian Penyakit Radang Paru-Paru pada Citra Chest X-Ray dengan Convolutional Neural Network," *J. Teknologi Inform. dan Komput. MH. Thamrin*, vol. 9, no. 1, pp. 14–23, 2023, doi: 10.37012/jtik.v9i1.1371.
- [6] I. Jawaz and R. Rahmadewi, "Sistem Deteksi Pneumonia Paru-Paru dengan Pengolahan Citra Digital dan Machine Learning," *Electron J. Ilm. Tek. Elektro*, vol. 5, no. 1, pp. 138–146, 2024, doi: 10.33019/electron.v5i1.114.
- [7] B. S. Nusantara and M. Akbar, "Klasifikasi Penyakit Tuberculosis Berdasarkan Citra Rontgen Thorax Menggunakan Multi-Scale Convolutional Neural Network," *Sudo J. Tek. Inform.*, vol. 3, no. 1, p. 8, 2024, doi: 10.56211/sudo.v3i1.483.
- [8] G. T. Indrawan, A. Nilogiri, and H. A. Al-Faruq, "Diagnosis COVID-19 Berdasarkan Citra X-ray Paru-Paru Menggunakan Metode Convolutional Neural Network," *J. Smart Teknol.*, vol. 3, no. 4, pp. 340–349, 2022.

- [9] M. N. Fadlurrahman, A. E. Minarno, and Y. Azhar, "Klasifikasi COVID-19 Menggunakan Algoritma CNN," *REPOSITOR*, vol. 5, no. 2, pp. 699–708, 2023, doi: 10.22219/repositor.v5i2.32060.
- [10] M. Mamalakis *et al.*, "Computerized Medical Imaging and Graphics DenResCov-19 : A deep transfer learning network for robust automatic classification of COVID-19 , pneumonia , and tuberculosis from X-rays," *Comput. Med. Imaging Graph.*, vol. 94, no. October, p. 102008, 2021, doi: 10.1016/j.compmedimag.2021.102008.
- [11] B. Nugroho and E. Y. Puspaningrum, "Kinerja Metode CNN untuk Klasifikasi Pneumonia dengan Variasi Ukuran Citra Input," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 8, no. 3, pp. 533–538, 2021, doi: 10.25126/jtiik.202184515.
- [12] A. M. Tahir, Y. Qiblawey, A. Khandakar, T. Rahman, U. Khurshid, and F. Musharavati, "Deep Learning for Reliable Classification of COVID - 19 , MERS, and SARS from Chest X - ray Images," *Cognit. Comput.*, no. September, pp. 1752–1772, 2022, doi: 10.1007/s12559-021-09955-1.
- [13] D. Kusuma and D. B. Rarasati, "Klasifikasi Penyakit Paru-Paru Dengan Citra X-Ray Menggunakan Metode Convolutional Neural Netwotk," *J. Ilm. Sains dan Teknol. Univ. Banten Jaya*, vol. 9, no. 2, pp. 152–165, 2025, doi: 10.47080/saintek.v9i2.3528.
- [14] F. N. Azizah and D. Juniati, "Analisis Jenis Penyakit Paru-Paru Berdasarkan Chest X-Ray Menggunakan Metode Fuzzy C-Means," *MATH unesa*, vol. 09, no. 02, pp. 322–331, 2021.
- [15] M. Hussein, A. E. Minarno, and Y. Azhar, "Segmentasi Citra X-ray Paru dengan Deep Learning," *REPOSITOR*, vol. 5, no. 1, pp. 581–590, 2023, doi: 10.22219/repositor.v5i1.32034.
- [16] M. A. Alghozali, J. R. Triosaputra, and A. Kayan, "Klasifikasi Penyakit Pneumonia Citra Digital X-Ray Menggunakan Metode Convolutional Neural Network dan RGB Equalization," *Pros. Semin. Nas. Teknol. dan Sains*, vol. 3, pp. 229–236, 2024, doi: 10.29407/stains.v3i1.4290.
- [17] R. M. Diar, R. Y. N. Fu'Adah, and K. Usman, "Klasifikasi Penyakit Paru-Paru Berbasis Pengolahan Citra X Ray Menggunakan Convolutional Neural Network," *E-Proceeding Eng.*, vol. 9, no. 2, pp. 476–484, 2022.
- [18] C. R. Leonard, I. Nurtanio, and A. Bustamin, "Systematic Literature Review : Deep Learning Pada Citra Sinar-X Paru Untuk Klasifikasi Penyakit," *Techno.COM*, vol. 23, no. 3, pp. 512–531, 2024, doi: 10.62411/tc.v23i3.10961.
- [19] P. M. De Sousa *et al.*, "COVID-19 classification in X-ray chest images using a new convolutional neural network : CNN-COVID," *Res. Biomed. Eng.*, vol. 38, no. March, pp. 87–97, 2022, doi: 10.1007/s42600-020-00120-5.
- [20] P. Syifa, S. Safwandi, and Z. Fitri, "Sistem Pakar Diagnosis Penyakit Paru menggunakan Metode Convolutional Neural Network dan Rule Based System," *RABIT J. Teknol. dan Sist. Inf. Univrab*, vol. 10, no. 2, pp. 1380–1392, 2025, doi: 10.36341/rabit.v10i2.6548.
- [21] A. A. Nasser and M. A. Akhloufi, "A Review of Recent Advances in Deep Learning

- Models for Chest Disease Detection Using Radiography," *diagnostics*, vol. 13, no. January, 2023, doi: 10.3390/diagnostics13010159.
- [22] D. Meedeniya, H. Kumarasinghe, S. Kolonne, and C. Fernando, "Chest X-Ray Analysis Empowered With Deep Learning: A Systematic Review," *Appl. Soft Comput.*, vol. 126, no. January, 2022, doi: 10.1016/j.asoc.2022.109319.