

# IMPLEMENTASI CONVOLUTIONAL NEURAL NETWORK BERBASIS MOBILENETV2 UNTUK KLASIFIKASI PNEUMONIA MENGGUNAKAN CITRA X-RAY PARU-PARU

Evita Setyaningrum<sup>1\*</sup>, Bambang Wirawan<sup>2</sup>

<sup>1,2</sup>Universitas Muhadi Setiabudi; Jalan. P. Diponegoro KM 2 Pesantunan, Wanasari, Brebes ; Telp. (0283) 6199000/Fax. (0283) 6199001

---

**Keywords:**

Pneumonia, Chest X-ray, CNN, MobileNetV2, Transfer Learning.

**Corespondent Email:**

setyaningrumevita129@gmail.com

**Abstrak.** Pneumonia merupakan salah satu penyakit infeksi saluran pernapasan yang masih menjadi penyebab utama morbiditas dan mortalitas di dunia. Pemeriksaan citra X-ray dada merupakan metode yang umum digunakan dalam proses diagnosis pneumonia, namun interpretasinya sangat bergantung pada keahlian tenaga medis dan berpotensi menimbulkan kesalahan diagnosis. Penelitian ini bertujuan untuk mengimplementasikan metode Convolutional Neural Network (CNN) berbasis MobileNetV2 dalam mengklasifikasikan citra X-ray paru-paru menjadi kelas normal dan pneumonia. Dataset diperoleh dari platform Kaggle dan dibagi menjadi data latih, validasi, dan uji dengan proporsi masing-masing 80%, 10%, dan 10%. Proses pelatihan dilakukan menggunakan pendekatan transfer learning dan fine-tuning dengan optimizer AdamW serta teknik augmentasi data. Hasil pengujian menunjukkan bahwa model mencapai akurasi sebesar 97,47% pada data uji dengan nilai recall kelas pneumonia sebesar 99%. Hasil ini menunjukkan bahwa model yang diusulkan memiliki kemampuan generalisasi yang baik dan berpotensi digunakan sebagai sistem pendukung keputusan dalam diagnosis pneumonia berbasis citra X-ray.



Copyright © [JITET](#) (Jurnal Informatika dan Teknik Elektro Terapan). This article is an open access article distributed under terms and conditions of the Creative Commons Attribution (CC BY NC)

**Abstract.** *Pneumonia is one of the respiratory infectious diseases that remains a major cause of morbidity and mortality worldwide. Chest X-ray imaging is commonly used in the diagnosis of pneumonia; however, its interpretation heavily depends on the expertise of medical professionals and is prone to diagnostic errors. This study aims to implement a Convolutional Neural Network (CNN) method based on the MobileNetV2 architecture to classify chest X-ray images into normal and pneumonia classes. The dataset was obtained from the Kaggle platform and divided into training, validation, and testing sets with proportions of 80%, 10%, and 10%, respectively. The training process employed a transfer learning and fine-tuning approach using the AdamW optimizer along with data augmentation techniques. Experimental results show that the proposed model achieved an accuracy of 97.47% on the test dataset, with a pneumonia class recall of 99%. These results indicate that the proposed model demonstrates strong generalization capability and has the potential to be used as a decision support system for pneumonia diagnosis based on chest X-ray images.*

---

## 1. PENDAHULUAN

Pneumonia adalah penyakit infeksi yang terjadi secara tiba-tiba dan menyerang jaringan paru-paru. Ciri-ciri penyakit ini adalah

peradangan pada alveoli, yang mengakibatkan gangguan dalam proses pertukaran oksigen di dalam tubuh. Penyakit ini dapat dipicu oleh infeksi bakteri, virus, atau jamur. Pneumonia

dapat menyerang individu dari segala usia, namun risiko dan tingkat kematian akibat penyakit ini cenderung lebih tinggi pada anak-anak di bawah lima tahun serta orang lanjut usia. [1][2].

Menurut organisasi kesehatan dunia (WHO), pneumonia tetap merupakan salah satu penyebab utama kematian akibat infeksi di seluruh dunia. Hal ini menunjukkan bahwa penyakit ini masih menimbulkan masalah kesehatan yang serius dan memerlukan penanganan yang segera dan tepat. Deteksi dini pneumonia sangat krusial untuk mencegah komplikasi yang lebih parah dan meningkatkan kemungkinan kesembuhan pasien. [4].

Dalam sektor kesehatan, pemindaian, X-ray dada merupakan cara yang paling sering diterapkan untuk membantu dalam diagnosis pneumonia. Teknologi ini memberikan kemampuan kapada tenaga medis untuk mendapatkan representasi visual dari keadaan paru-paru, sehingga lebih mudah dalam mengidentifikasi tanda-tanda seperti infiltrasi, konsolidasi, atau opasitas yang mengidentifikasi adanya infeksi [5]. Namun, cara menganalisis hasil X-ray sangat tergantung pada keterampilan serta pengalaman dokter dan mutu dari gambar yang dihasilkan. Elemen-elemen ini dapat mengakibatkan kesalahan dalam menetapkan diagnosis, khususnya dalam kasus pneumonia yang tidak terlalu parah atau pada gambar yang kurang berkualitas [6].

Kemajuan dalam teknologi kecerdasan buatan, khususnya dalam area pembelajaran mendalam, telah membuka banyak kemungkinan untuk analisis gambar medis. Pendekatan ini memungkinkan mesin untuk secara otomatis mengidentifikasi pola-pola kompleks dari visual serta berfungsi sebagai alat bantu dalam proses pengembalian keputusan di sektor kesehatan [7][8]. Penerapan deep learning dalam analisis gambar medis juga dilaporkan dapat meningkatkan efisiensi dan ketepatan dalam mendiagnosa penyakit [9].

Salah satu teknik *deep learning* yang umum diterapkan dalam pengolahan citra adalah *Convolutional Neural Network* (CNN). CNN dapat secara otomatis dan berlapis mengambil ciri-ciri visual dari data asli, sehingga sangat efisien dalam membedakan gambar medis seperti X-ray paru [10]. Pemanfaatan CNN dalam jaringan cerdas serta sistem pendukung

keputusan yang didasarkan pada data telah banyak diterapkan di berbagai sektor teknik dan kesehatan [11], [12].

Penelitian sebelumnya menunjukkan bahwa CNN mampu memberikan hasil yang baik dalam mendekripsi pneumonia menggunakan gambar X-ray dengan akurasi di atas 90%[13]. Penelitian oleh Maulana *et al.* [14] yang menjadi referensi utama di sini melaporkan bahwa penggunaan CNN untuk mengklasifikasikan pneumonia berdasarkan gambar X-ray bisa mencapai akurasi sebesar 97%. Meskipun begitu, model yang diterapkan memerlukan banyak sumber daya komputasi, yang dapat menjadi penghalang saat digunakan dalam sistem yang tidak memiliki daya komputasi yang memadai.

MobileNetV2 merupakan salah satu model CNN yang dikembangkan untuk menjadi lebih efisien tetapi tetap mempertahankan kinerja yang optimal. Model ini mengimplementasikan teknik konvolusi terpisah mendalam dan blok residu terbalik, sehingga sejumlah parameter dan kebutuhan komputasi dapat diminimalkan [15]. Oleh sebab itu, studi ini memiliki tujuan untuk mengembangkan model klasifikasi pneumonia menggunakan CNN dengan struktur MobileNetV2 dan pendekatan *transfer learning* sebagai lanjutan dari penelitian yang sudah ada sebelumnya [16], dengan penekanan pada peningkatan efisiensi pengolahan tanpa mengorbankan ketepatan.

## 2. TINJAUAN PUSTAKA

CNN merupakan salah satu tipe arsitektur dalam pembelajaran mesin yang ditujukan secara spesifik untuk menganalisis data dalam bentuk gambar. Metode operasional CNN adalah dengan memanfaatkan lapisan konvolusi untuk mengidentifikasi dan mengekstrak fitur-fitur seperti garis, tekstur, dan pola visual dari gambar, setelah itu hal tersebut diproses lebih lanjut melalui lapisan pooling dan layer terhubung penuh guna melakukan pengklasifikasian [10]. Kelebihan dari CNN adalah dapat secara otomatis mendekripsi dan belajar dari fitur-fitur tersebut tanpa perlu dirancang dengan tangan [11].

*Transfer learning* adalah teknik pembelajaran yang menggunakan model yang sudah dilatih sebelumnya pada dataset yang sangat besar, seperti *ImageNet*, untuk diterapkan pada masalah baru yang memiliki

dataset lebih sedikit. Metode ini amat bermanfaat di sektor citra medis karena keterbatasan jumlah data serta tantangan dalam proses pemberian label pada data [16].

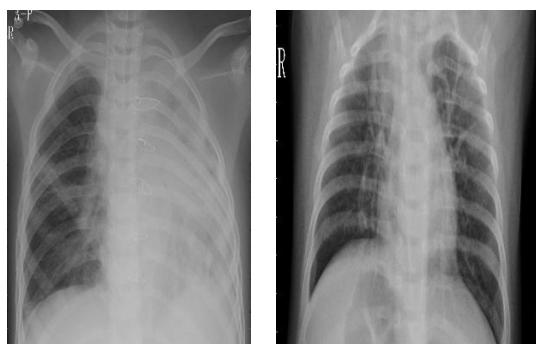
MobileNetV2 merupakan versi yang telah ditinggalkan dari arsitektur MobileNet yang dirancang khusus untuk pengolahan gambar di perangkat dengan kemampuan sumber daya yang terbatas. Desain ini mengimplementasikan blok residual yang terbalik serta *bottleneck linear*, yang tidak hanya meningkatkan efisiensi dalam komputasi tetapi juga memperbaiki pelatihan melalui aliran gradien [15]. Beberapa studi menunjukkan bahwa MobileNetV2 dapat memberikan kinerja yang memuaskan dalam berbagai aplikasi analisis citra medis, termasuk dalam pengenalan penyakit pneumonia melalui gambar X-ray [13], [14].

Penilaian efektivitas model klasifikasi citra medis umumnya menggunakan beberapa ukuran, seperti tingkat akurasi, *precision*, *recall*, *F1-score*, dan juga *confusion matrix* [12]. Dalam situasi pneumonia, nilai recall untuk kategori positif sangat krusial karena berkaitan langsung dengan kemampuan model dalam mendeteksi penyakit pneumonia dengan akurat dan mengurangi risiko kesalahan yang dikenal sebagai false negative [14].

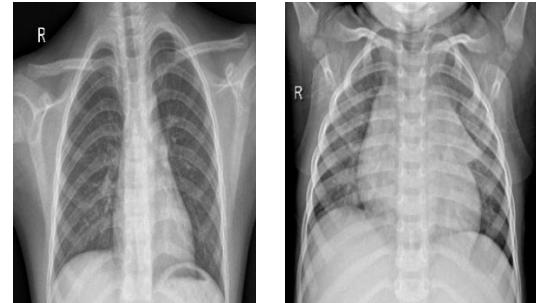
### 3. METODE PENELITIAN

#### 3.1. Dataset

Dataset yang digunakan didapat dari platform Kaggle dan berisi gambar X-ray paru-paru dengan dua jenis, yaitu NORMAL dan PNEUMONIA. Dataset itu terbagi menjadi tiga bagian, yaitu data latih sebesar 80%, data validasi 10%, dan data uji 10%. Pembagian ini dilakukan untuk memastikan bahwa proses pelatihan, pengujian, dan validasi berlangsung dengan cara yang adil dan objektif.



Gambar 1. X-ray Dada Terdampak Pneumonia.

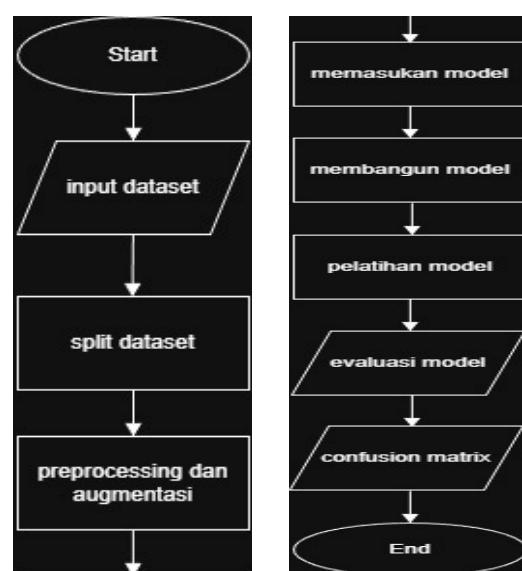


Gambar 2. X-ray dada tidak terdampak Pneumonia.

#### 3.2. Alur Penelitian

Diagram penelitian ini dapat dilihat pada gambar 3. Proses penelitian dimulai dengan pengumpulan dataset gambar X-ray paru-paru yang mencakup dua kategori, yaitu normal dan pneumonia. Dataset tersebut kemudian dibagi menjadi tiga bagian utama yaitu data latih, data validasi, dan data uji.

MobileNetV2 diterapkan dan dibangun dengan layer klasifikasi. Model yang telah dibangun tersebut selanjutnya dilatih menggunakan data latih dan secara berkala diuji untuk validitasnya. Langkah terakhir adalah evaluasi model dengan menggunakan confusion matrix untuk mengevaluasi hasil klasifikasi sebelum penelitian dianggap selesai.



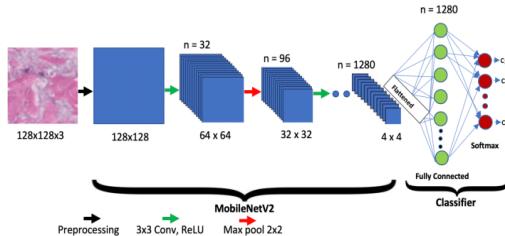
Gambar 3. Diagram Alur Klasifikasi Pneumonia.

### 3.3. Pra-pemrosesan dan Augmentasi

Semua gambar diubah ukurannya menjadi 224x224 piksel agar sesuai dengan parameter input dari MobileNetV2. Proses normalisasi dilakukan untuk mengatur nilai piksel agar berada dalam rentang tertentu. Disamping itu, augmentasi data diterapkan melalui teknik rotasi, flip horizontal, zoom, dan penyesuaian kontras demi meningkatkan variasi data serta mengurangi kemungkinan terjadinya overfitting.

### 3.4. Arsitektur Model

Model yang diterapkan adalah MobileNetV2, memanfaatkan bobot yang telah dilatih sebelumnya dari basis data ImageNet untuk pengambilan fitur. Lapisan terakhir dimodifikasi dengan menggunakan *Global Average Pooling*, *Dropout*, dan lapisan *Dense* yang menerapkan fungsi aktivasi softmax.



Gambar 4. Arsitektur CNN MobileNetV2

### 3.5. Pelatihan Model

Proses pelatihan dilakukan dalam dua tahap, yakni ekstraksi fitur dan penyesuaian tambahan. Penggunaan optimizer AdamW bertujuan untuk meningkatkan stabilitas dan kemampuan model dalam beradaptasi. Model terbaik dengan menggunakan *ModelCheckpoint*, dan pelatihan dihentikan secara otomatis dengan metode *Early Stopping*.

### 3.6. Evaluasi

Evaluasi model dilakukan dengan menggunakan *precision*, *recall*, *F1-score*, serta *confusion matrix*.

## 4. HASIL DAN PEMBAHASAN

### 4.1. Hasil pelatihan model

Proses pelatihan model dilakukan dengan menggunakan arsitektur MobileNetV2, dengan pendekatan transfer learning dan fine-tuning. Model dilatih selama maksimal 15 epoch, dengan menerapkan mekanisme *Early Stopping*

dan Model *Checkpoint* untuk mencegah terjadinya overfitting dan menyimpan bobot model terbaik berdasarkan nilai akurasi validasi. Sebagai optimizer digunakan AdamW dengan learning rate awal  $1 \times 10^{-4}$ , kemudian diturunkan secara adaptif menjadi  $1 \times 10^{-5}$  pada tahap fine-tuning.

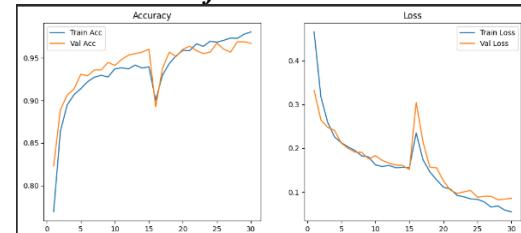
Dari hasil pelatihan yang terlihat pada log pelatihan, model menunjukkan peningkatan konsisten pada setiap epoch.

Pada awal pelatihan, akurasi validasi berkisar antara 91–93%. Dengan bertambahnya epoch dan penerapan fine-tuning, akurasi validasi terus meningkat hingga mencapai nilai tertinggi yaitu 96,88% pada epoch ke-13. Setelah itu, tidak ada peningkatan signifikan pada akurasi validasi, sehingga proses pelatihan dihentikan otomatis oleh mekanisme Early Stopping.

Penerapan Model *Checkpoint* memastikan bobot model terbaik disimpan pada epoch dengan performa validasi paling baik.

Hal ini terlihat dari pesan "saving model to best\_mobilenetv2\_chestxray.keras" yang muncul pada beberapa epoch ketika akurasi validasi meningkat. Strategi ini efektif dalam mencegah penurunan kualitas performa akibat pelatihan yang berlebihan (*overfitting*).

### 4.2. Analisis Grafik Akurasi dan Loss



Gambar 5. Grafik akurasi dan loss model pelatihan MobileNetV2.

Grafik akurasi dan loss menunjukkan proses pelatihan yang stabil dan berjalan dengan baik. Kurva akurasi pada data latih dan data validasi meningkat secara seiring waktu. Pada awal pelatihan, terdapat perbedaan antara akurasi data latih dan data validasi, namun perbedaan tersebut semakin berkurang seiring berjalannya epoch. Hal ini menunjukkan bahwa model mampu belajar dari data latih serta memiliki kemampuan untuk menggeneralisasi pada data baru yang belum dilihat sebelumnya.

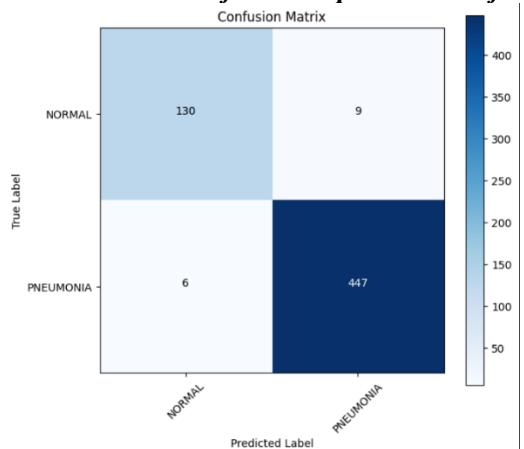
Kurva loss menunjukkan tren penurunan yang terus-menerus.

Nilai loss pada data latih awalnya berada di atas 0,4, lalu secara perlahan menurun hingga mencapai kisaran 0,05–0,08 di akhir pelatihan. Nilai loss pada data validasi juga mengalami penurunan, meskipun ada sedikit variasi pada beberapa epoch. Variasi tersebut dapat dikurangi dengan menyesuaikan learning rate, sehingga proses pelatihan kembali stabil.

Secara keseluruhan, pola grafik akurasi dan loss menunjukkan bahwa model sudah mencapai kondisi yang stabil dan tidak mengalami *overfitting* yang terlalu besar.

Dukungan ini juga terlihat dari kesamaan nilai antara akurasi dan loss pada data latih dan data validasi.

#### 4.3. Evaluasi Kinerja Model pada Data Uji



Gambar 6. Confusion Matrix Klasifikasi Pneumonia.

Evaluasi akhir dilakukan dengan menggunakan data uji yang tidak terlibat dalam proses pelatihan maupun validasi. Hasil evaluasi menunjukkan bahwa model mencapai akurasi sebesar 97,47% dan nilai loss sebesar 0,0409. Angka ini menunjukkan bahwa model memiliki kemampuan klasifikasi yang sangat baik terhadap data baru.

Dari laporan classification, kelas NORMAL memiliki nilai precision 0,96, recall 0,94, dan F1-score 0,95.

Sementara itu, kategori pneumonia menunjukkan hasil yang lebih unggul dengan tingkat presisi 0,98, recall 0,99, dan F1-score 0,98. Tingginya angka recall pada kategori pneumonia menunjukkan bahwa alat model ini dapat mendeteksi hampir semua kasus pneumonia dengan akurasi yang tinggi.

Analisis dari matriks menunjukkan bahwa dari 592 gambar yang diuji, sebanyak 447

gambar pneumonia berhasil diidentifikasi dengan benar, sedangkan hanya 6 gambar pneumonia yang diidentifikasi salah sebagai normal.

Disisi lain, ada 9 gambar normal yang diidentifikasi dengan keliru sebagai pneumonia. Total kesalahan ini relatif rendah jika dibandingkan dengan keseluruhan data yang diuji, yang menunjukkan model ini memiliki kinerja yang sangat handal.

Dalam dunia medis, kesalahan false negative (pneumonia yang diidentifikasi sebagai normal) adalah kesalahan yang sangat berbahaya, sebab itu, tingkat recall 99% pada kategori pneumonia menjadi salah satu kekuatan dari model ini karena dapat mengurangi risiko dari kesalahan tersebut.

#### 4.4. Evaluasi Kinerja Model pada Data Uji

Model yang diterapkan dalam studi ini memiliki total sekitar 2,26 juta parameter, dimana sebagian besar berasal dari bobot MobileNetV2 yang telah dilatih sebelumnya. Angka parameter ini jauh lebih rendah jika dibandingkan dengan model CNN tradisional seperti VGG atau ResNet yang biasanya memiliki puluhan juta parameter. Dengan ukuran model yang lebih kecil dan memerlukan memori sekitar 9 MB, MobileNetV2 sangat efisien untuk digunakan pada sistem yang memiliki keterbatasan dalam sumber daya.

Keunggulan komputasi ini menjadikan model ini lebih praktis untuk diterapkan dalam berbagai aplikasi seperti sistem berbasis web, sistem dukungan keputusan medis, atau perangkat komputasi tepi. Oleh karena itu, penelitian ini tidak hanya berfokus pada peningkatan akurasi, tetapi juga mempertimbangkan aspek praktis dan penerapannya di dunia nyata.

#### 4.5. Perbandingan dengan Penelitian Terdahulu

Dibandingkan dengan kajian yang menjadi rujukan utama, yaitu studi oleh Maulana et all., yang memperoleh tingkat akurasi 97% dengan CNN standar, temuan penelitian ini menunjukkan peningkatan yang kecil namun jelas dengan akurasi mencapai 97,47%. Walaupun selisih akurasi tidak terlalu mencolok, model yang dikembangkan menunjukkan manfaat penting dalam hal

efisiensi komputasi karena memanfaatkan arsitektur CNN yang lebih ringan.

Beberapa penelitian lain mencatat tingkat akurasi antara 94–96% dalam pengklasifikasian pneumonia menggunakan gambar X-ray dengan pendekatan CNN dan transfer learning. Dengan demikian, hasil dari penelitian ini termasuk dalam kategori performa menarik dan kompetitif, serta mengindikasikan bahwa arsitektur MobileNetV2 dapat memberikan keseimbangan yang optimal antara akurasi dan efisiensi.

#### **4.6. Implikasi Klinis dan Keterbatasan Penelitian**

Dari segi klinis, model yang ditawarkan bisa digunakan sebagai bantuan dalam menentukan diagnosis, membantu para tenaga medis mendeteksi pneumonia secara lebih cepat dan lebih objektif. Tingkat recall yang tinggi menunjukkan bahwa model ini bisa menjadi alat skrining awal yang dapat dipercaya. Namun, penelitian ini masih memiliki beberapa kekurangan.

Namun, penelitian ini masih memiliki beberapa kelemahan. Dataset yang digunakan hanya terdiri dari dua kategori, yaitu normal dan pneumonia, sehingga belum mewakili kondisi yang lebih rumit dalam bidang medis. Selain itu, data yang digunakan berasal dari satu sumber dataset publik, sehingga variasi gambar masih terbatas. Untuk penelitian berikutnya, diusulkan menggunakan dataset dari berbagai sumber, mengembangkan klasifikasi dengan lebih banyak kategori, serta melakukan validasi secara langsung di lingkungan klinis.

### **5. KESIMPULAN**

- Model CNN berbasis MobileNetV2 dengan pendekatan *transfer learning* berhasil mengklasifikasikan citra X-ray paru-paru dengan akurasi 97,47% dan *recall* kelas pneumonia sebesar 99%, sehingga efektif untuk deteksi pneumonia.
- Kelebihan metode yang diusulkan terletak pada efisiensi komputasi, jumlah parameter yang relatif kecil, serta stabilitas pelatihan yang diperoleh melalui augmentasi data, optimizer AdamW, dan mekanisme *early stopping*.

- Keterbatasan penelitian ini adalah penggunaan dataset dua kelas dari satu sumber, sehingga variasi data klinis masih terbatas dan belum mencakup kondisi paru-paru yang lebih kompleks.
- Penelitian selanjutnya dapat dikembangkan dengan dataset multi-sumber, klasifikasi multi-kelas, serta integrasi model ke dalam sistem pendukung keputusan berbasis web atau perangkat edbutatge.

### **UCAPAN TERIMA KASIH**

Ucapan terima kasih disampaikan kepada **Universitas Muhammadiyah Setiabudi** atas dukungan fasilitas dan lingkungan akademik yang mendukung pelaksanaan penelitian ini. Terima kasih juga disampaikan kepada seluruh pihak yang telah memberikan bantuan, masukan, serta dukungan selama proses penelitian dan penyusunan artikel. Selain itu, apresiasi diberikan kepada pengelola dataset yang tersedia secara terbuka di platform Kaggle sehingga penelitian ini dapat terlaksana dengan baik.

### **DAFTAR PUSTAKA**

- Y. S. dan A. W. R. Hidayat, “Analisis Faktor Risiko Pneumonia pada Lansia,” *Jurnal Ilmu Kesehatan Masyarakat*, vol. 12, no. 1, pp. 45–53, 2021, Accessed: Jan. 19, 2026. [Online]. Available: <https://jikm.upnvj.ac.id/index.php/home/article/view/512>
- A. K. Sari dan D. Puspitasari, “Pneumonia sebagai Penyebab Kematian Balita di Indonesia,” *Jurnal Kesehatan Masyarakat*, vol. 16, no. 22, pp. 89–97, 2021, Accessed: Jan. 19, 2026. [Online]. Available: <https://journal.unnes.ac.id/sju/index.php/kemas/article/view/41235>
- World Health Organization, “Pneumonia,” WHO Fact Sheet. Accessed: Jan. 19, 2026. [Online]. Available: <https://www.who.int/news-room/detail/pneumonia>
- E. K. dan R. A. A. Setyawan, “Penerapan Deep Learning pada Pengolahan Citra Medis untuk Mendukung Diagnosis Penyakit,” *JITET (Jurnal Ilmiah Teknik Elektro Terapan)*, vol. 11, no. 2, pp. 85–92, 2022, Accessed: Jan. 19, 2026. [Online]. Available: <https://jitet.polinema.ac.id/index.php/jitet/article/view/312>

- [5] L. Pratiwi dan N. Setiawan, "Analisis Kesalahan Diagnosis Pneumonia Menggunakan Citra X-Ray Dada," *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, vol. 9, no. 4, pp. 821–830, 2022, Accessed: Jan. 19, 2026. [Online]. Available: <https://jtiik.ub.ac.id/index.php/jtiik/article/view/4821>
- [6] I. Firmansyah dan D. Purnomo, "Perbandingan Arsitektur CNN pada Klasifikasi Pneumonia Berbasis X-Ray," *Jurnal Informatika Mulawarman*, vol. 17, no. 2, pp. 95–103, 2022, Accessed: Jan. 19, 2026. [Online]. Available: <https://ejournals.unmul.ac.id/index.php/JIM/article/view/8035>
- [7] A. Setiawan dan B. Santoso, "Sistem Pendukung Keputusan Berbasis Deep Learning pada Bidang Kesehatan," *Jurnal Teknologi Informasi dan Terapan*, vol. 9, no. 2, pp. 140–147, 2021, Accessed: Jan. 19, 2026. [Online]. Available: <https://jurnal.polibatam.ac.id/index.php/JTIT/article/view/2986>
- [8] E. N. dan R. G. D. Wahyudi, "Implementasi Sistem Cerdas Berbasis Data pada Diagnosis Penyakit," *Jurnal Media Informatika Budidarma*, vol. 6, no. 4, pp. 2140–2147, 2022, Accessed: Jan. 19, 2026. [Online]. Available: <https://ejurnal.stmik-budidarma.ac.id/index.php/mib/article/view/4287>
- [9] R. R. dan A. N. M. Maulana, "Klasifikasi Pneumonia Menggunakan Convolutional Neural Network pada Citra X-Ray Paru-Paru," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 6, no. 3, pp. 456–463, 2022, Accessed: Jan. 19, 2026. [Online]. Available: <https://jurnal.iaii.or.id/index.php/RESTI/article/view/4091>
- [10] Y. A. Nugroho dan I. Kurniawan, "Implementasi Convolutional Neural Network untuk Klasifikasi Citra Medis," *Jurnal Nasional Teknik Elektro dan Teknologi Informasi (JNTETI)*, vol. 10, no. 3, pp. 256–263, 2021, Accessed: Jan. 19, 2026. [Online]. Available: <https://jnteti.te.ugm.ac.id/index.php/JNTETI/article/view/899>
- [11] A. Setiawan dan M. A. Hakim, "Penerapan Deep Learning pada Pengolahan Citra Medis," *Jurnal Teknik Elektro*, vol. 14, no. 2, pp. 101–108, 2021, Accessed: Jan. 19, 2026. [Online]. Available: <https://ejournal.undip.ac.id/index.php/teknikelektrik/article/view/35991>
- [12] S. Lestari dan M. A. Hakim, "Evaluasi Kinerja Model Klasifikasi Menggunakan Confusion Matrix," *Jurnal RESTI*, vol. 5, no. 6, pp. 1032–1039, 2021, Accessed: Jan. 19, 2026. [Online]. Available: <https://jurnal.iaii.or.id/index.php/RESTI/article/view/3389>
- [13] N. A. Rahmawati dan A. Fauzi, "Deteksi Pneumonia Menggunakan MobileNetV2 dan Transfer Learning," *Jurnal Informatika Polinema*, vol. 8, no. 1, pp. 1–8, 2021, Accessed: Jan. 19, 2026. [Online]. Available: <https://jip.polinema.ac.id/ojs/index.php/jip/article/view/354>
- [14] F. Ramadhan dan A. H. Pratama, "Analisis Precision dan Recall pada Klasifikasi Penyakit Paru," *Jurnal Informatika Universitas Pamulang*, vol. 7, no. 3, pp. 489–496, 2022, Accessed: Jan. 19, 2026. [Online]. Available: <https://openjournal.unpam.ac.id/index.php/informatika/article/view/19125>
- [15] A. Prakoso dan M. F. Rizal, "Penerapan MobileNetV2 untuk Klasifikasi Citra Medis Berbasis Deep Learning," *Jurnal Teknologi dan Sistem Komputer*, vol. 10, no. 2, pp. 73–80, 2022, Accessed: Jan. 19, 2026. [Online]. Available: <https://jtsiskom.undip.ac.id/index.php/jtsiskom/article/view/15621>
- [16] H. T. dan F. U. s://jtsiskom.undip.ac.id/index.php/jtsiskom/article/view/15621 [16] R. S. Putra, "Transfer Learning pada Klasifikasi Citra Medis Menggunakan CNN," *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 6, no. 5, pp. 2411–2419, 2022, Accessed: Jan. 19, 2026. [Online]. Available: <https://jptik.ub.ac.id/index.php/jptik/article/view/11052>
- [17] M. Maulana, R. Ramadhan, dan A. Nugroho, "Klasifikasi Pneumonia Menggunakan Convolutional Neural Network pada Citra X-Ray Paru-Paru," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 6, no. 3, pp. 456–463, 2022. URL: <https://jurnal.iaii.or.id/index.php/RESTI/article/view/4091>