

Analisis Perbandingan Kinerja Convolutional Neural Network dan Transfer Learning EfficientNet-B0 dalam Deteksi Pneumonia pada Citra Rontgen Paru-Paru

Comparative Performance Analysis of Convolutional Neural Network and EfficientNet-B0 Transfer Learning for Pneumonia Detection in Chest X-Ray Images

¹Aditya Pratama Werdana*, ²Amali, ³M.Syaibani Anwar

^{1,2,3}Program Studi Teknik Informatika, Fakultas Teknik, Universitas Pelita Bangsa

^{1,2,3}Jl. Inspeksi Kalimalang Tegal Danas, Cikarang Pusat, Bekasi, Jawa Barat 17530, Indonesia

*e-mail: adityawerdana5@gmail.com, amali@pelitabangsa.ac.id,
syaebani.Anwar@pelitabangsa.ac.id

(received: 26 June 2026, revised: 13 July 2026, accepted: 15 July 2026)

Abstrak

Pneumonia adalah infeksi paru-paru akut yang menjadi penyebab utama kematian anak balita di Indonesia. Diagnosis pneumonia biasanya dilakukan melalui analisis citra rontgen dada (*chest X-ray*) oleh radiolog, namun proses ini masih dipengaruhi subjektivitas dan keterbatasan tenaga ahli. Penelitian ini bertujuan mengembangkan sistem deteksi pneumonia berbasis *Convolutional Neural Network* (CNN) dengan membandingkan empat variasi model, yakni CNN dengan *Color Jitter* (Model 1), CNN dengan *Color Jitter* dan *Layers Augmentation* (Model 2), CNN dengan *Batch Normalization* dan *Color Jitter* (Model 3), serta *transfer learning* menggunakan EfficientNet-B0 (Model 4). *Dataset* yang dipakai adalah *Chest X-Ray Images* (Pneumonia) dari Kaggle sebanyak 5.856 citra, dibagi 70% *training*, 15% *validation*, dan 15% *testing*. Hasil penelitian menunjukkan Model 4 berbasis EfficientNet-B0 *transfer learning* unggul dengan akurasi 96,92%, *precision* 97,67%, *recall* 98,13%, serta *F1-score* 97,90%. Model ini meningkatkan akurasi 1,93% dibandingkan *baseline* CNN konvensional (Model 1) sebesar 94,99%. *Layers Augmentation* pada Model 2 juga efektif mengurangi *False Negative* dari 21 menjadi 10 kasus. Penelitian ini membuktikan efektivitas *transfer learning* EfficientNet-B0 untuk klasifikasi citra medis dan potensinya sebagai sistem pendukung diagnosis pneumonia di fasilitas kesehatan, bukan sebagai pengganti diagnosis klinis yang dilakukan oleh tenaga medis profesional.

Kata kunci: *chest x-ray, convolutional neural network, EfficientNet-B0, pneumonia, transfer learning*

Abstract

Pneumonia is an acute lung infection and remains one of the leading causes of mortality among children under five in Indonesia. Pneumonia is commonly diagnosed through the analysis of chest X-ray (CXR) images by radiologists; however, this process is still subject to human variability and the limited availability of medical specialists. This study aims to develop a Convolutional Neural Network (CNN)-based pneumonia detection system by comparing four model variants: CNN with Color Jitter (Model 1), CNN with Color Jitter and Layer Augmentation (Model 2), CNN with Batch Normalization and Color Jitter (Model 3), and EfficientNet-B0 transfer learning (Model 4). The experiments were conducted using the Chest X-Ray Images (Pneumonia) dataset from Kaggle, comprising 5,856 images, which were divided into 70% for training, 15% for validation, and 15% for testing. The experimental results demonstrate that the EfficientNet-B0 transfer learning model achieved the best performance, with an accuracy of 96.92%, precision of 97.67%, recall of 98.13%, and an F1-score of 97.90%. This model improved classification accuracy by 1.93%

<http://sistemasi.ftik.unisi.ac.id>

compared with the conventional CNN baseline (Model 1), which achieved an accuracy of 94.99%. Furthermore, the incorporation of Layer Augmentation in Model 2 effectively reduced the number of false negatives from 21 to 10 cases. These findings demonstrate the effectiveness of EfficientNet-B0 transfer learning for medical image classification and highlight its potential as a clinical decision support tool for pneumonia diagnosis in healthcare settings, rather than as a replacement for clinical diagnosis performed by qualified medical professionals.

Keywords: chest x-ray, convolutional neural network, EfficientNet-B0, pneumonia, transfer learning

1 Pendahuluan

Pneumonia merupakan penyakit infeksi akut pada paru-paru yang disebabkan oleh berbagai mikroorganisme seperti bakteri, virus, jamur, dan parasit, yang menimbulkan peradangan pada jaringan parenkim terutama di kantung udara (alveoli) sehingga dapat menyebabkan gangguan pernapasan. Sebuah penelitian yang memanfaatkan metode Mask R-CNN dengan backbone ResNet-50 serta penerapan CLAHE untuk peningkatan kualitas citra melaporkan kemampuan deteksi pneumonia dengan akurasi 76%, *precision* 62%, dan *sensitivity* 67% [1]. Di sisi lain, pendekatan CNN yang memanfaatkan fitur *Prewitt Operator* dan arsitektur EfficientNet dengan optimizer Adamax menghasilkan kinerja pelatihan yang lebih tinggi dengan akurasi mencapai 96,59% [2].

Dalam praktik klinis, pneumonia biasanya ditegakkan melalui pembacaan citra rontgen dada (*chest X-ray*), yang menjadi metode deteksi paling banyak digunakan karena alatnya tersedia luas dan biaya pemeriksaannya relatif murah. Penerapan arsitektur ResNet50 dengan optimizer SGD-M pada *dataset* berisi 3.183 citra *X-ray* dilaporkan memberikan akurasi pelatihan 95,43% dan akurasi pengujian 92,25% [3]. Sementara itu, studi lain yang mengombinasikan CNN dengan ekstraksi tepi Sobel pada 2.217 citra rontgen paru-paru memperoleh akurasi sekitar 91,54% dengan *precision* 91% dan *recall* 92,8% [4].

Kemajuan teknologi *deep learning* menyediakan peluang besar untuk pengembangan sistem diagnosis penyakit berbasis citra medis, antara lain melalui teknik pengolahan citra digital yang terbukti mampu meningkatkan kinerja klasifikasi. Penggunaan *histogram equalization* pada citra rontgen dilaporkan dapat menaikkan akurasi deteksi dari 73% menjadi 78% [5]. Penelitian lain yang menerapkan CNN dengan fungsi aktivasi *ReLU* dan optimizer Adam pada *dataset* 5.840 citra dari Kaggle menunjukkan akurasi pengujian sekitar 89,58% [6]. Teknik prapemrosesan lanjutan seperti CLAHE yang dipadukan dengan arsitektur EfficientNet juga terbukti efektif untuk klasifikasi penyakit paru-paru dengan akurasi sekitar 97%, *F1-score* 0,97, *recall* 0,98, dan *precision* 0,96 [7]. Selain itu, pendekatan *transfer learning* menggunakan arsitektur ResNet50V2 untuk klasifikasi pneumonia menunjukkan performa yang sangat baik dengan akurasi 97%, *precision* 96,1%, dan *recall* 98%, melampaui kinerja model VGG16 yang hanya mencapai akurasi sekitar 92% [8].

Meskipun berbagai pendekatan tersebut menunjukkan hasil yang menjanjikan, rentang akurasi yang dilaporkan masih cukup lebar, yaitu sekitar 76% hingga 97%. Hal ini mengindikasikan bahwa pemilihan arsitektur jaringan, strategi augmentasi data, metode prapemrosesan, serta pengaturan parameter pelatihan sangat menentukan kualitas sistem deteksi pneumonia. Sebagian besar penelitian terdahulu juga belum melakukan perbandingan sistematis antara model CNN konvensional dengan berbagai kombinasi augmentasi data dan pendekatan *transfer learning* EfficientNet-B0 pada *dataset* yang sama, sehingga efektivitas relatif masing-masing pendekatan masih perlu dikaji lebih lanjut.

Berdasarkan uraian tersebut, penelitian ini difokuskan pada evaluasi komparatif beberapa konfigurasi *Convolutional Neural Network* (CNN) dan pendekatan *transfer learning* EfficientNet-B0 dalam mendeteksi pneumonia pada citra rontgen paru-paru. Tujuan penelitian ini adalah merancang dan membandingkan empat konfigurasi model untuk menganalisis pengaruh variasi teknik augmentasi data dan arsitektur model terhadap kinerja klasifikasi, sehingga diperoleh model dengan performa optimal dan stabil sebagai dasar pengembangan sistem pendukung analisis citra medis. Manfaat penelitian ini meliputi penyediaan rujukan akademis mengenai dampak teknik augmentasi dan *transfer learning*, serta rekomendasi model terbaik yang dapat menjadi dasar pengembangan sistem pendukung keputusan klinis untuk deteksi dini pneumonia.

2 Tinjauan Literatur

Penerapan *Convolutional Neural Network* (CNN) untuk klasifikasi pneumonia pada citra *X-ray* dada telah menjadi fokus berbagai penelitian dengan beragam strategi. Sejumlah studi mengombinasikan CNN dengan algoritma lain seperti *Extreme Gradient Boosting* untuk meningkatkan ketepatan klasifikasi [9], sementara optimasi model CNN berbasis *transfer learning* dilaporkan mampu memperbaiki akurasi deteksi pneumonia secara signifikan [10]. Arsitektur yang lebih dalam seperti DenseNet201 dimanfaatkan untuk menangkap fitur kompleks pada citra paru [11], sedangkan metode klasik seperti *Naive Bayes* masih digunakan sebagai pembanding meskipun cenderung kalah dari pendekatan *deep learning* [12]. Efektivitas *transfer learning* pada citra *X-ray* paru juga telah ditegaskan melalui perbandingan dengan pelatihan dari awal [13]. Secara umum, penelitian terdahulu memperlihatkan rentang akurasi yang lebar, yaitu sekitar 76% hingga 97%, dan model yang memadukan *transfer learning* dengan prapemrosesan citra yang tepat cenderung memberikan hasil yang lebih unggul.


Teknik augmentasi data merupakan komponen penting untuk mengatasi keterbatasan jumlah sampel sekaligus menekan *overfitting*. Transformasi geometris seperti rotasi, translasi, *zoom*, dan *horizontal flip* banyak digunakan untuk memperkaya variasi data pelatihan dan meningkatkan kemampuan generalisasi model pada klasifikasi pneumonia [14], [15]. *Color Jitter* memodifikasi parameter warna seperti kecerahan, kontras, dan saturasi sehingga model menjadi lebih tahan terhadap variasi kondisi pencahayaan dan karakteristik sensor [16], sedangkan *Layers Augmentation* menambahkan transformasi spasial, struktural, serta augmentasi berbasis *noise* yang memperluas keragaman representasi fitur citra [17].

Dari sisi arsitektur, berbagai konfigurasi telah diuji untuk klasifikasi pneumonia, mulai dari CNN konvensional [18] hingga arsitektur berbasis DenseNet [19], dengan penerapan *Batch Normalization* yang umum diadopsi untuk menjaga kestabilan distribusi aktivasi sehingga mempercepat konvergensi pelatihan dan mengurangi *overfitting*. Perbandingan langsung antara ResNet-50 dan EfficientNet-B0 menunjukkan bahwa EfficientNet-B0 memberikan keseimbangan akurasi dan efisiensi komputasi yang lebih baik berkat metode *compound scaling* yang menyeimbangkan kedalaman, lebar, dan resolusi jaringan [20]. Selain itu, kombinasi augmentasi data dan *dropout* pada arsitektur ringan seperti MobileNetV3 terbukti meningkatkan akurasi klasifikasi citra medis [21], sementara studi komprehensif terhadap beragam arsitektur jaringan menegaskan bahwa pemilihan arsitektur sangat memengaruhi performa deteksi pneumonia [22].

Pendekatan *transfer learning* secara konsisten terbukti meningkatkan akurasi sekaligus menekan *overfitting* pada *dataset* medis yang terbatas, sebagaimana ditunjukkan oleh perbandingan ResNet-50 dan VGG-16 pada citra *X-ray* paru [23] serta penerapan *deep learning* yang dilengkapi interpretasi model untuk deteksi penyakit paru [24]. Berdasarkan keseluruhan tinjauan tersebut, terdapat beberapa celah yang menjadi dasar kebaruan penelitian ini. Pertama, sebagian besar studi terdahulu menguji satu arsitektur atau satu skema prapemrosesan secara terpisah, sehingga kontribusi spesifik dari tiap teknik augmentasi terhadap performa tidak dapat diukur secara terisolasi; penelitian ini justru menerapkan desain komparatif bertingkat (*ablation*) yang menambahkan satu komponen pada setiap konfigurasi secara berurutan, yaitu *Color Jitter*, kemudian *Layers Augmentation*, lalu *Batch Normalization*, sehingga pengaruh masing-masing teknik dapat dikuantifikasi secara terisolasi dan terkontrol. Kedua, seluruh konfigurasi dibandingkan pada *dataset*, ukuran input, pembagian data, serta parameter pelatihan yang identik, sehingga perbedaan performa benar-benar merepresentasikan perbedaan konfigurasi dan bukan faktor eksternal, suatu kondisi yang jarang dijaga secara ketat pada penelitian sebelumnya. Ketiga, evaluasi tidak dibatasi pada akurasi semata, tetapi turut menekankan dimensi klinis berupa penurunan *False Negative* yang berkaitan langsung dengan keselamatan pasien karena merepresentasikan kasus pneumonia yang gagal terdeteksi. Dengan demikian, kebaruan penelitian ini terletak pada evaluasi komparatif EfficientNet-B0 secara spesifik untuk klasifikasi pneumonia pada citra *X-ray* dada yang sekaligus menyeimbangkan akurasi, efisiensi komputasi, dan relevansi klinis, serta menghasilkan rekomendasi konfigurasi optimal yang teruji secara sistematis dan dapat direplikasi.

3 Metode Penelitian

Penelitian ini menerapkan pendekatan deduktif-kuantitatif dengan desain eksperimen komputasional komparatif. Empat konfigurasi model dikembangkan, dilatih, dan dievaluasi secara sistematis dalam kondisi terkendali untuk menentukan konfigurasi paling optimal dalam mendeteksi pneumonia. Variabel independen mencakup arsitektur model (CNN konvensional dan EfficientNet-B0), skema augmentasi data (*Color Jitter* dan *Layers Augmentation*), serta penggunaan *Batch Normalization*. Variabel dependen berupa kinerja klasifikasi yang diukur melalui akurasi, *precision*, *recall*, dan *F1-score*, sedangkan variabel kontrol meliputi *dataset*, ukuran input citra, proporsi pembagian data, jumlah *epoch*, dan *batch size*. Tahapan penelitian disusun berurutan mulai dari studi literatur, pengumpulan *dataset*, prapemrosesan, augmentasi, pembagian *dataset*, pembangunan dan pelatihan model, evaluasi, hingga analisis komparatif dan penarikan kesimpulan, sebagaimana ditunjukkan pada Gambar 1.



Gambar 1 Tahapan dan alur penelitian

3.1 Dataset dan Sumber Data

Dataset yang digunakan adalah *Chest X-Ray Images* (Pneumonia) yang dipublikasikan oleh Paul Mooney pada platform Kaggle, bersumber dari Guangzhou Women and Children's Medical Center dan telah dikurasi serta divalidasi oleh tenaga medis profesional [25], [26]. *Dataset* terdiri atas 5.856 citra rontgen dada yang terbagi menjadi kelas Normal sebanyak 1.583 citra (27,03%) dan kelas Pneumonia sebanyak 4.273 citra (72,97%). Ketidakseimbangan kelas ini mencerminkan kondisi klinis

nyata di mana pemeriksaan rontgen dada umumnya dilakukan pada pasien dengan dugaan pneumonia. Distribusi kelas *dataset* disajikan pada Tabel 1.


Table 1 Distribusi kelas dataset

Kelas	Jumlah Citra	Persentase
Normal	1.583	27,03%
Pneumonia	4.273	72,97%
Total	5.856	100%

Dataset dibagi menjadi tiga subset menggunakan metode *stratified split* agar proporsi tiap kelas konsisten, yaitu 70% data *training* untuk melatih model, 15% data *validation* untuk memantau performa dan mencegah *overfitting*, serta 15% data *testing* untuk mengevaluasi performa akhir pada data yang belum pernah dilihat. Pembagian ini menghasilkan 4.099 citra *training*, 879 citra *validation*, dan 878 citra *testing*.

3.2 Prapemrosesan dan Augmentasi Data

Tahap prapemrosesan dilakukan untuk menyiapkan citra sesuai format input model. Seluruh citra diubah ukurannya menjadi dimensi standar 224×224 piksel menggunakan interpolasi bilinear, kemudian nilai pikselnya dinormalisasi dengan membagi terhadap 255 sehingga berada pada rentang 0–1 untuk mempercepat konvergensi dan menjaga stabilitas numerik. Citra grayscale dikonversi ke format RGB tiga channel sehingga menghasilkan dimensi akhir 224×224×3 yang kompatibel dengan arsitektur model [27], [28]. Augmentasi data diterapkan untuk memperkaya variasi data pelatihan melalui *Color Jitter* (kecerahan, kontras, dan saturasi $\pm 0,2$) yang mensimulasikan variasi pencahayaan, serta *Layers Augmentation* berupa rotasi $\pm 20^\circ$, *horizontal flip* dengan probabilitas 50%, dan *zoom* 0,8–1,2× yang mensimulasikan variasi posisi pasien. Contoh hasil augmentasi ditunjukkan pada Gambar 2.



Gambar 2 Contoh hasil augmentasi data (original vs augmented)

3.3 Arsitektur dan Pelatihan Model

Empat konfigurasi model dirancang untuk perbandingan. Model 1 menggunakan CNN konvensional dengan tiga blok *convolutional layer* (32, 64, dan 128 filter), *max pooling*, dua *dense layer* (256 dan 128 unit), dan *dropout* 0,5, disertai augmentasi *Color Jitter*. Model 2 memiliki arsitektur identik dengan Model 1 namun menambahkan *Layers Augmentation*. Model 3 menambahkan *Batch Normalization* setelah setiap *convolutional layer* dengan *Color Jitter*. Model 4 memanfaatkan EfficientNet-B0 yang telah dipelajari pada ImageNet, dengan lapisan *pretrained* dibekukan dan ditambah *Global Average Pooling*, *dense layer* 256 unit beraktivasi *ReLU*, *dropout* 0,5, serta lapisan output beraktivasi *sigmoid*. Konfigurasi augmentasi tiap model dirangkum pada Tabel 2.

Tabel 2 Konfigurasi augmentasi pada setiap model

Model	Color Jitter	Layers Aug.
Model 1: CNN + Color Jitter	Ya	Tidak

Model	Color Jitter	Layers Aug.
Model 2: CNN + Color Jitter + Layers	Ya	Ya
Model 3: CNN + BatchNorm + Color Jitter	Ya	Tidak
Model 4: EfficientNet-B0 Transfer Learning	Ya	Ya

Seluruh model dilatih menggunakan optimizer Adam dan fungsi *loss Binary Crossentropy* dengan *batch size* 32. *Learning rate* disesuaikan untuk tiap konfigurasi, yaitu 0,005 untuk Model 1, 0,001 untuk Model 2, 0,01 untuk Model 3, dan 0,0001 untuk *fine-tuning* Model 4 agar bobot *pretrained* tidak rusak. *Callback Early Stopping* dengan *patience* 5 *epoch* dan *ReduceLROnPlateau* diterapkan untuk menghentikan pelatihan ketika *validation loss* tidak membaik serta menurunkan *learning rate* secara otomatis saat performa stagnan.

3.4 Teknik Evaluasi

Evaluasi performa dilakukan pada data *testing* menggunakan *confusion matrix* yang terdiri atas *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN). Pada konteks medis, *False Negative* menjadi perhatian utama karena merepresentasikan kasus pneumonia yang tidak terdeteksi. Berdasarkan *confusion matrix* tersebut dihitung empat persamaan (1-4) metrik evaluasi, yaitu

$$1. \text{Accuracy} = \frac{TP+TN}{TP+FP+FN+TN} \quad (1)$$

$$2. \text{Precision} = \frac{TP}{TP+FP} \quad (2)$$

$$3. \text{Recall} = \frac{TP}{TP+FN} \quad (3)$$

$$4. \text{F1-Score} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (4)$$

Penggunaan keempat metrik ini penting karena akurasi semata kurang memadai pada *dataset* yang tidak seimbang [29], [30]. Hasil tiap model selanjutnya dianalisis secara komparatif untuk menentukan konfigurasi paling optimal.

4 Hasil dan Pembahasan


4.1 Hasil Pelatihan Model

Keempat model dilatih dengan konfigurasi yang telah ditetapkan dan dipantau melalui *learning curve*. Model 1 berhenti pada *epoch* ke-13 dengan *training accuracy* 98,10% dan *validation accuracy* 95,22%, menunjukkan gap 2,88% yang mengindikasikan sedikit *overfitting* namun masih wajar. Model 2 dilatih selama 16 *epoch* dengan *validation loss* yang lebih stabil dan gap hanya 0,45% (*training accuracy* 96,58% dan *validation accuracy* 96,13%), membuktikan bahwa *Layers Augmentation* meningkatkan generalisasi. Model 3 hanya bertahan 7 *epoch* dengan fluktuasi *validation accuracy* yang tinggi (75%–92%) akibat *learning rate* 0,01 yang terlalu besar sehingga optimasi menjadi tidak stabil, menghasilkan *validation accuracy* 92,61%. Model 4 konvergen paling baik selama 19 *epoch* dengan *training accuracy* 99,93% dan *validation accuracy* 97,38%, ditandai kurva yang halus tanpa fluktuasi signifikan berkat pemanfaatan fitur ImageNet dan *learning rate* yang tepat. Ringkasan hasil pelatihan disajikan pada Tabel 3, sedangkan *learning curve* keempat model ditampilkan pada Gambar 3.

Table 3 Ringkasan hasil pelatihan keempat model

Model	Train Acc.	Val Acc.	Epoch
Model 1: CNN + CJ	98,10%	95,22%	13
Model 2: CNN + CJ + Layers	96,58%	96,13%	16
Model 3: CNN + BN + CJ	–	92,61%	7
Model 4: EfficientNet-B0	99,93%	97,38%	19


Keterangan: CJ = Color Jitter, BN = Batch Normalization



Gambar 3 Learning curve keempat model

4.2 Hasil Pengujian dan Evaluasi

Pengujian dilakukan menggunakan 878 citra *testing* (237 Normal dan 641 Pneumonia) yang belum pernah dilihat model selama pelatihan. *Confusion matrix* keempat model ditampilkan pada Gambar 4. Model 1 menghasilkan TN=214, FP=23, FN=21, dan TP=620. Model 2 menurunkan *False Negative* dari 21 menjadi 10 (TN=211, FP=26, FN=10, TP=631), menandakan *Layers Augmentation* membantu model mengenali variasi pola pneumonia yang sebelumnya terlewat. Model 3 memiliki *False Positive* tertinggi (TN=178, FP=59, FN=17, TP=624) sehingga banyak pasien Normal salah diklasifikasikan sebagai Pneumonia. Model 4 menampilkan keseimbangan terbaik dengan *True Negative* tertinggi dan *False Positive* terendah (TN=222, FP=15, FN=12, TP=629). Ringkasan *confusion matrix* disajikan pada Tabel 4.



Gambar 4 Confusion matrix keempat model

<http://sistemasi.ftik.unisi.ac.id>

Table 4 Ringkasan *confusion matrix* keempat model

Model	TP	TN	FP	FN
Model 1	620	214	23	21
Model 2	631	211	26	10
Model 3	624	178	59	17
Model 4	629	222	15	12

Berdasarkan *confusion matrix* tersebut dihitung metrik evaluasi sebagaimana disajikan pada Tabel 5. Model 4 mencapai performa terbaik pada hampir seluruh metrik dengan akurasi 96,92%, *precision* 97,67%, *recall* 98,13%, dan *F1-score* 97,90%. Model 2 menempati posisi kedua dengan *recall* tertinggi sebesar 98,44% yang mengindikasikan kemampuan deteksi pneumonia paling sensitif, sedangkan Model 3 memperoleh performa terendah dengan akurasi 91,34%.

Table 5 Perbandingan metrik evaluasi keempat model

Model	Accuracy	Precision	Recall	F1-Score
Model 1: CNN + CJ	94,99%	96,42%	96,72%	96,57%
Model 2: CNN + CJ + Layers	95,90%	96,04%	98,44%	97,22%
Model 3: CNN + BN + CJ	91,34%	91,37%	97,35%	94,26%
Model 4: EfficientNet-B0	96,92%	97,67%	98,13%	97,90%

4.3 Analisis Perbandingan Performa Antarmodel

Hasil eksperimen menunjukkan urutan peringkat performa Model 4 > Model 2 > Model 1 > Model 3. Penambahan *Layers Augmentation* pada Model 2 meningkatkan akurasi 0,91% (dari 94,99% menjadi 95,90%) dan melonjakkan *recall* dari 96,72% menjadi 98,44%, dengan penurunan *False Negative* dari 21 menjadi 10. Hal ini menegaskan bahwa variasi geometris membantu model menangkap pola pneumonia yang sebelumnya terlewat. Sebaliknya, Model 3 yang menerapkan *Batch Normalization* justru memperoleh performa terlemah akibat *learning rate* 0,01 yang terlalu besar sehingga optimasi tidak stabil; temuan ini memperlihatkan bahwa pemilihan hyperparameter sama krusialnya dengan pemilihan arsitektur. Keunggulan Model 4 berbasis EfficientNet-B0 dapat dikaitkan dengan kemampuannya memanfaatkan representasi fitur dari ImageNet serta metode *compound scaling* yang menyeimbangkan kedalaman, lebar, dan resolusi jaringan. Keseimbangan *precision* (97,67%) dan *recall* (98,13%) yang nyaris setara menunjukkan model tidak bias terhadap salah satu kelas, sehingga sesuai untuk konteks medis yang menuntut sensitivitas tinggi sekaligus alarm palsu yang rendah.

4.4 Perbandingan dengan Penelitian Terdahulu

Tabel 6 membandingkan hasil penelitian ini dengan studi terdahulu pada domain serupa. Akurasi 96,92% yang dicapai bersaing dengan penelitian terbaik sebelumnya. Walaupun akurasinya sedikit lebih rendah dibandingkan Anwar dkk. (97%), *F1-score* penelitian ini lebih tinggi yaitu 97,90%, yang menandakan keseimbangan *precision* dan *recall* yang lebih baik. Dibandingkan penelitian berbasis CNN konvensional seperti Maysanjaya (89,58%) dan Afkar dkk. (92,25%), pendekatan *transfer learning* EfficientNet-B0 jelas memberikan hasil yang lebih baik.

Table 6 Perbandingan dengan penelitian terdahulu

Peneliti	Metode	Akurasi	F1-Score
Adzkia dkk. (2022)	Mask R-CNN + ResNet-50	76%	–
Maysanjaya (2020)	CNN + ReLU + Adam	89,58%	–
Afkar dkk. (2025)	CNN ResNet50 + SGD-M	92,25%	92%
Raihan dkk. (2025)	CNN EfficientNet + Prewitt	96,59%	–
Anwar dkk. (2025)	CNN ResNet50V2 + TL	97%	97,05%

Peneliti	Metode	Akurasi	F1-Score
Penelitian Ini	EfficientNet-B0 + TL	96,92%	97,90%

Meskipun memberikan hasil yang baik, penelitian ini memiliki beberapa keterbatasan. *Dataset* berasal dari satu institusi medis sehingga generalisasi model terhadap citra dari institusi lain memerlukan validasi lebih lanjut. Model masih bersifat klasifikasi biner (Normal vs Pneumonia) tanpa membedakan jenis pneumonia bakteri atau virus, eksplorasi hyperparameter belum dilakukan secara komprehensif, dan rasio kelas 27:73 berpotensi menimbulkan bias terhadap kelas mayoritas. Selain itu, model belum divalidasi secara klinis pada lingkungan nyata sehingga belum dimaksudkan untuk menggantikan peran tenaga medis.

5 Kesimpulan

Penelitian ini berhasil mengembangkan dan membandingkan empat konfigurasi model untuk deteksi pneumonia pada citra rontgen dada berbasis *Convolutional Neural Network*, yaitu CNN dengan *Color Jitter*, CNN dengan *Color Jitter* dan *Layers Augmentation*, CNN dengan *Batch Normalization* dan *Color Jitter*, serta *transfer learning* EfficientNet-B0. Hasil evaluasi menunjukkan bahwa Model 4 berbasis EfficientNet-B0 menjadi yang terbaik dengan akurasi 96,92%, *precision* 97,67%, *recall* 98,13%, dan *F1-score* 97,90%, dengan peringkat performa Model 4 > Model 2 > Model 1 > Model 3. Dibandingkan *baseline* CNN konvensional (Model 1) sebesar 94,99%, Model 4 meningkatkan akurasi sebesar 1,93%. Penerapan *Layers Augmentation* terbukti efektif menekan *False Negative* dari 21 menjadi 10 kasus, sementara performa Model 3 yang kurang optimal menegaskan pentingnya pemilihan *learning rate* yang tepat. Temuan ini mengonfirmasi efektivitas *transfer learning* EfficientNet-B0 untuk klasifikasi citra medis dan potensinya sebagai sistem pendukung analisis citra rontgen, namun tetap memerlukan validasi klinis lanjutan dan tidak dimaksudkan menggantikan diagnosis tenaga medis profesional. Penelitian selanjutnya disarankan menggunakan *dataset* multi-institusi, mengembangkan model *multiclass* untuk membedakan jenis pneumonia, menerapkan optimasi hyperparameter dan penanganan data tidak seimbang, serta mengeksplorasi arsitektur *deep learning* terbaru seperti *Vision Transformer* dan pendekatan ensemble.

Referensi

- [1] M. Adzkie, F. Arland, dan A. W. Setiawan, "Deteksi *Pneumonia* menggunakan Citra Sinar-X Paru berbasis *Residual Network*," Jurnal Teknologi Informasi dan Ilmu Komputer, Vol. 9, No. 2, hlm. 373–380, 2022, DOI: 10.25126/jtiik.202295626.
- [2] Raihan, C. Nurul Alam, dan W. Budiawan Zulfikar, "Deteksi *Pneumonia* pada Citra Akhir X-Ray Dada menggunakan *Convolutional Neural Networks* berbasis Fitur Prewitt Operator," INTERNAL (Information System Journal), Vol. 8, No. 1, hlm. 24–36, 2025, DOI: 10.32627.
- [3] A. N. D. Afkar, A. Rachmad, dan E. M. S. Rochman, "Klasifikasi *Pneumonia* dengan Metode *Convolutional Neural Network*," JATI (Jurnal Mahasiswa Teknik Informatika), Vol. 9, No. 4, hlm. 5821–5828, Agu. 2025.
- [4] J. Yopento, E. Ernawati, dan F. F. Coastera, "Identifikasi *Pneumonia* pada Citra X-Ray Paru-Paru menggunakan Metode *Convolutional Neural Network (CNN)* berdasarkan Ekstraksi Fitur Sobel," Rekursif: Jurnal Informatika, Vol. 10, No. 1, hlm. 40–47, 2022. [Daring]. Tersedia pada: <http://ejournal.unib.ac.id/index.php/rekursif>
- [5] I. Jawaz dan R. Rahmadewi, "Sistem Deteksi *Pneumonia* Paru-Paru dengan Pengolahan Citra Digital dan *Machine Learning*," ELECTRON: Jurnal Ilmiah Teknik Elektro, Vol. 5, No. 1, hlm. 1–9, 2024, DOI: 10.33019/electron.v5i1.114.
- [6] I. M. D. Maysanjaya, "Klasifikasi *Pneumonia* pada Citra X-rays Paru-paru dengan *Convolutional Neural Network*," Jurnal Nasional Teknik Elektro dan Teknologi Informasi, Vol. 9, No. 2, hlm. 190–195, 2020, DOI: 10.22146/jnteti.v9i2.66.
- [7] A. D. Azzumzumi, M. Hanafi, dan W. M. P. Dhuhita, "Klasifikasi Penyakit Paru-Paru berdasarkan Peningkatan Kualitas Kontras dan *EfficientNet* menggunakan Gambar X-Ray," Teknika, Vol. 13, No. 2, hlm. 293–300, Jul. 2024, DOI: 10.34148/teknika.v13i2.881.

- [8] M. A. Anwar, Y. A. Gerhana, dan U. Syaripudin, "Implementasi Model *CNN ResNet50V2* untuk Klasifikasi *Pneumonia* pada Citra X-Ray," *SMATIKA Jurnal*, Vol. 15, No. 01, hlm. 126–135, Jun. 2025, DOI: 10.32664/smatika.v15i01.1538.
- [9] A. E. Putra, K. Kartini, dan A. P. Sari, "Metode *Convolutional Neural Network* dan *Extreme Gradient Boost* untuk mengklasifikasi Penyakit *Pneumonia*," *JASIEK*, Vol. 6, No. 1, hlm. 33–40, Jul. 2024, DOI: 10.26905/jasiek.v6i1.11464.
- [10] R. K. Pasha dan K. Budiman, "Optimasi Model *CNN* berbasis *Transfer Learning* untuk Klasifikasi *Pneumonia* pada Citra X-Ray Dada," *SMATIKA Jurnal*, Vol. 15, No. 01, hlm. 167–178, Jun. 2025, DOI: 10.32664/smatika.v15i01.1985.
- [11] E. Karyadiputra, A. Setiawan, dan N. Hijriana, "Deteksi *Pneumonia* dari Citra X-Ray menggunakan *CNN DenseNet201*," *Technologia: Jurnal Ilmiah*, Vol. 17, No. 1, hlm. 57, Jan. 2026, DOI: 10.31602/tji.v17i1.20940.
- [12] F. A. Ariansyah, Kartini, dan H. Maulana, "Klasifikasi *Pneumonia* pada Citra X-Ray Paru-Paru menggunakan *Algoritma Naive Bayes*," *JUTIM (Jurnal Teknik Informatika Musirawas)*, Vol. 9, No. 1, hlm. 1–14, Jun. 2024.
- [13] A. S. Wiratama, M. Rifqi, dan S. Maesaroh, "Efektivitas *Transfer Learning* dalam Pendeteksian Penyakit *Pneumonia* melalui Citra X-Ray Paru Manusia," *Jurnal Ilmiah Sains dan Teknologi*, Vol. 7, No. 1, hlm. 43–52, 2023, DOI: 10.47080/saintek.v7i1.2551.
- [14] I. Kurniawati, R. Akbar, Y. A. Kusuma, dan I. F. Kusumawati, "Identifikasi *Pneumonia* pada Balita melalui Citra X-Ray menggunakan Metode *Convolutional Neural Network (CNN)*," *Journal of Manufacturing in Industrial Engineering & Technology*, Vol. 3, No. 1, hlm. 10–23, Jun. 2024, DOI: 10.30651/mine-tech.v3i1.23391.
- [15] A. A. Hipzi, G. W. Wiriasto, dan I. M. B. Suksmadana, "Klasifikasi *Pneumonia* pada Augmentasi Citra X-Ray Paru-Paru menggunakan Metode *Convolutional Neural Network (CNN)*," Skripsi, Universitas Mataram, Mataram, Indonesia, 2023. [Daring]. Tersedia pada: <http://eprints.unram.ac.id/id/eprint/39247>
- [16] S. Zini, A. Gomez-Villa, M. Buzzelli, B. Twardowski, A. D. Bagdanov, dan J. van de Weijer, "Planckian Jitter: Countering the Color-Crippling Effects of Color Jitter on Self-Supervised Training," Feb. 2023. [Daring]. Tersedia pada: <http://arxiv.org/abs/2202.07993>
- [17] B. Zheng, D.-W. Zhou, H.-J. Ye, dan D.-C. Zhan, "Multi-layer Rehearsal Feature Augmentation for Class-Incremental Learning," dalam *Proceedings of the 41st International Conference on Machine Learning (ICML)*, PMLR, Vol. 235, hlm. 61649–61663, 2024.
- [18] A. R. Pratama dan A. F. Cobantoro, "Klasifikasi Citra *Pneumonia* menggunakan Arsitektur *Convolutional Neural Network (CNN)*," *Jurnal Ilmiah NERO*, Vol. 8, No. 2, 2023, DOI: 10.21107/nero.v8i2.18992.
- [19] M. Firdaus dan A. Herliawan, "Model *Machine Learning CNN* berbasis *DenseNet* untuk Identifikasi *Pneumonia* melalui Citra Sinar-X," *Jurnal Riset Teknik Komputer*, Vol. 2, No. 2, hlm. 113–121, Jul. 2025, DOI: 10.69714/q8v70k68.
- [20] K. Kansal, T. B. Chandra, dan A. Singh, "ResNet-50 vs. EfficientNet-B0: Multi-Centric Classification of Various Lung Abnormalities using Deep Learning," dalam *Procedia Computer Science*, Elsevier B.V., 2024, hlm. 70–80, DOI: 10.1016/j.procs.2024.04.007.
- [21] A. M. Rifa'i, A. T. Zy, W. Hadikristanto, Amali, dan S. Butsianto, "Leveraging Data Augmentation and Dropout Layer in MobileNetV3 for Accurate Skin Cancer Detection on ISIC Dataset," dalam *2024 8th International Conference on Information Technology, Information Systems and Electrical Engineering (ICITISEE)*, 2024, hlm. 591–596, DOI: 10.1109/ICITISEE63424.2024.10730105.
- [22] W. Akbar dkk., "Pneumonia Detection: A Comprehensive Study of Diverse Neural Network Architectures using Chest X-Rays," *International Journal of Applied Mathematics and Computer Science*, Vol. 34, No. 4, hlm. 679–699, Sep. 2024, DOI: 10.61822/amcs-2024-0045.
- [23] T. Berliani, E. Rahardja, dan L. Septiana, "Perbandingan Kemampuan Klasifikasi Citra X-ray Paru-paru menggunakan *Transfer Learning ResNet-50* dan *VGG-16*," *Journal of Medicine and Health*, Vol. 5, No. 2, hlm. 123–135, Agu. 2023, DOI: 10.28932/jmh.v5i2.6116.
- [24] S. Muliani, B. S. Negara, M. Irsyad, dan I. Iskandar, "Application of Shapley Additive Explanations (SHAP) in Deep Learning for Lung Disease Detection using X-ray Images,"

- Journal of Artificial Intelligence and Software Engineering, Vol. 5, No. 2, hlm. 709–719, 2025, DOI: 10.30811/jaise.v5i2.7044.
- [25] S. Sharma dan K. Guleria, "A Deep Learning based Model for the Detection of Pneumonia from Chest X-Ray Images using VGG-16 and Neural Networks," dalam *Procedia Computer Science*, Elsevier B.V., 2022, hlm. 357–366, DOI: 10.1016/j.procs.2023.01.018.
- [26] H. Bhatt dan M. Shah, "A Convolutional Neural Network Ensemble Model for Pneumonia Detection using Chest X-Ray Images," *Healthcare Analytics*, Vol. 3, Nov. 2023, DOI: 10.1016/j.health.2023.100176.
- [27] M. A. Alghozali, J. R. Triosaputra, dan A. Kayan, "Klasifikasi Penyakit *Pneumonia* Citra Digital X-Ray menggunakan Metode *Convolutional Neural Network* dan *RGB Equalization*," dalam *Seminar Nasional Teknologi & Sains (STAINS)*, Vol. 3, No. 1, 2024, DOI: 10.29407/stains.v3i1.4290.
- [28] R. A. Nindia Putra, "Optimasi Klasifikasi Penyakit *Pneumonia* pada Citra X-Ray menggunakan Metode *KNN* dengan Ekstraksi Fitur *Haralick* dan *Local Binary Pattern*," Skripsi, Universitas Pembangunan Nasional Veteran Jawa Timur, Surabaya, Indonesia, 2025.
- [29] D. Lusiyanti, S. Musdalifah, A. Sahari, dan I. Al Fajri, "Evaluasi Kinerja Algoritma *Machine Learning* pada Dataset Skala Besar," *MathVision: Jurnal Matematika*, Vol. 7, No. 1, hlm. 84–92, Mar. 2025, doi: 10.55719/mv.v7i1.1661.
- [30] A. Ramadhani dan S. Royal, "Sistem Estimasi Pencapaian Target Profit menggunakan Model Regresi berbasis *Machine Learning*," 2022. [Daring]. Tersedia pada: <http://jurnal.goretanpena.com/index.php/JSSR>