

Perbandingan CNN Dan ResNet50 Dalam Klasifikasi Tuberkulosis Pada Citra X-Ray Paru

Muhammad Fathir Aulia*, Muhammad Ikhsan

Sains dan Teknologi, Ilmu Komputer, Universitas Islam Negeri Sumatera Utara, Medan, Indonesia

Email: ¹*muhammad0701223160@uinsu.ac.id, ²mhd.ikhsan@uinsu.ac.id

Email Penulis Korespondensi: muhammad0701223160@uinsu.ac.id

Submitted 30-01-2025; Accepted 19-02-2026; Published 25-02-2026

Abstrak

Tuberkulosis (TBC) masih menjadi masalah kesehatan global dan memerlukan skrining dini yang cepat serta konsisten. Pemeriksaan radiografi dada (chest X-ray) banyak digunakan karena praktis dan ekonomis, namun interpretasi manual sangat bergantung pada tenaga ahli sehingga berpotensi menimbulkan subjektivitas, kelelahan, dan keterlambatan diagnosis. Penelitian ini bertujuan membandingkan kinerja Convolutional Neural Network (CNN) dasar dan ResNet50 berbasis transfer learning dalam klasifikasi citra X-ray paru menjadi dua kelas, yaitu TBC dan Normal, serta menilai trade-off akurasi dan efisiensi komputasi. Dataset yang digunakan merupakan subset seimbang sebanyak 1.000 citra (500 TBC dan 500 Normal) yang dibagi menjadi 70% data latih, 15% validasi, dan 15% uji dengan seed tetap agar eksperimen reproduktibel. Preprocessing dilakukan melalui resize citra menjadi 224×224 piksel dan normalisasi nilai piksel, ResNet50 menggunakan skema preprocessing sesuai model pretrained. Evaluasi menggunakan confusion matrix serta metrik akurasi, presisi, recall, dan F1-score. Hasil pengujian menunjukkan CNN mencapai akurasi 98,00% dengan tiga kesalahan klasifikasi, sedangkan ResNet50 mencapai akurasi 99,33% dengan satu kesalahan klasifikasi serta metrik presisi, recall, dan F1-score rata-rata di atas 0,99. Dari sisi efisiensi, waktu pelatihan CNN sekitar 40,46 detik, sedangkan ResNet50 total sekitar 226,99 detik; pada uji robustness, waktu inferensi CNN sekitar ±100 ms/gambar dan ResNet50 sekitar ±1.900 ms/gambar. Temuan ini menunjukkan ResNet50 unggul dalam akurasi dan stabilitas generalisasi, sementara CNN lebih efisien untuk kebutuhan respons cepat dan sumber daya terbatas.

Kata Kunci: Tuberkulosis; Chest X-ray; Klasifikasi Citra; Convolutional Neural Network; ResNet50; Transfer Learning

Abstract

Tuberculosis (TB) remains a global health problem and requires rapid and consistent early screening. Chest X-rays are widely used because they are practical and economical, but manual interpretation is highly dependent on experts, which can lead to subjectivity, fatigue, and delayed diagnosis. This study aims to compare the performance of a basic Convolutional Neural Network (CNN) and a transfer learning-based ResNet50 in classifying lung X-ray images into two classes, namely TB and Normal, as well as to assess the trade-off between accuracy and computational efficiency. The dataset used is a balanced subset of 1,000 images (500 TB and 500 Normal) divided into 70% training data, 15% validation, and 15% testing with a fixed seed to ensure reproducible experiments. Preprocessing was performed by resizing the images to 224×224 pixels and normalizing the pixel values. ResNet50 used a preprocessing scheme in accordance with the pretrained model. Evaluation was performed using a confusion matrix and accuracy, precision, recall, and F1-score metrics. The test results show that CNN achieved an accuracy of 98.00% with three classification errors, while ResNet50 achieved an accuracy of 99.33% with one classification error and average precision, recall, and F1-score metrics above 0.99. In terms of efficiency, the CNN training time was approximately 40.46 seconds, while ResNet50 took a total of approximately 226.99 seconds. In the robustness test, the CNN inference time was approximately ±100 ms/image and ResNet50 was approximately ±1,900 ms/image. These findings indicate that ResNet50 excels in accuracy and generalization stability, while CNN is more efficient for fast response and limited resource requirements.

Keywords: Tuberculosis; Chest X-ray; Image Classification; Convolutional Neural Network; ResNet50; Transfer Learning;

1. PENDAHULUAN

Tuberkulosis (TBC) masih menjadi salah satu penyakit infeksi menular yang menimbulkan beban kesehatan global hingga saat ini. Penyakit ini disebabkan oleh bakteri *Mycobacterium tuberculosis* yang umumnya menyerang jaringan paru-paru[1]. Data *World Health Organization* (WHO) menunjukkan bahwa jumlah kasus baru TBC di dunia masih berada pada angka lebih dari sepuluh juta kasus setiap tahunnya, dengan tingkat kematian melebihi satu juta jiwa[2], terutama di negara berkembang yang memiliki kepadatan penduduk tinggi serta keterbatasan fasilitas layanan kesehatan[3]. Kondisi tersebut menegaskan bahwa upaya deteksi dini dan skrining secara luas merupakan langkah krusial untuk menekan laju penularan sekaligus meningkatkan keberhasilan terapi pasien.

Pemeriksaan radiografi dada (*chest X-ray*) menjadi salah satu metode utama dalam proses *skrining* TBC karena relatif cepat, ekonomis, dan mudah diakses oleh fasilitas kesehatan. Meskipun demikian, proses interpretasi citra *X-ray* masih sangat bergantung pada keahlian tenaga medis dan radiolog. Ketergantungan ini berpotensi menimbulkan subjektivitas penilaian, kelelahan kerja, serta keterbatasan kapasitas layanan, khususnya di wilayah dengan jumlah tenaga ahli yang terbatas. Beban kerja yang tinggi juga dapat berdampak pada keterlambatan diagnosis dan meningkatnya risiko kesalahan interpretasi, sehingga diperlukan pendekatan otomatis yang mampu memberikan analisis citra secara lebih objektif, konsisten, dan efisien.

Perkembangan teknologi kecerdasan buatan, khususnya deep learning[4], memberikan peluang besar dalam pengolahan dan analisis citra medis[5]. *Convolutional Neural Network* (CNN) dikenal sebagai salah satu arsitektur yang efektif dalam mengekstraksi fitur visual secara otomatis[6] dan telah banyak digunakan dalam berbagai aplikasi klasifikasi citra medis. CNN dasar sering dimanfaatkan sebagai model *baseline* karena strukturnya sederhana dan mudah

diimplementasikan. Namun, ketika jaringan semakin dalam, CNN dasar dapat menghadapi keterbatasan dalam menangkap pola fitur kompleks[7] serta berpotensi mengalami permasalahan seperti *vanishing gradient* dan penurunan kemampuan generalisasi[8].

Sebagai pengembangan dari CNN konvensional, *Residual Network* (ResNet) diperkenalkan dengan konsep *skip connection*[9] yang memungkinkan aliran gradien tetap stabil pada jaringan yang sangat dalam[10]. ResNet50 merupakan salah satu[11] varian yang banyak digunakan dan sering dikombinasikan dengan pendekatan *transfer learning*[12] menggunakan bobot *pretrained* dari dataset berskala besar seperti ImageNet[13]. Pemanfaatan bobot awal ini memungkinkan model memperoleh representasi fitur yang lebih baik serta mempercepat proses pelatihan, khususnya ketika jumlah data medis relatif terbatas[14].

Dalam lima tahun terakhir, sejumlah penelitian telah mengkaji penerapan *deep learning* untuk klasifikasi penyakit paru. Liu dan Huang (2020) membandingkan beberapa arsitektur CNN dalam mendeteksi TBC dan melaporkan bahwa model yang lebih dalam cenderung memberikan performa lebih baik, meskipun keterbatasan ukuran *dataset* menjadi tantangan dalam generalisasi[15]. Nuriansyah et al. (2024) mengevaluasi performa model *pretrained* seperti ResNet50 dan VGG16 pada klasifikasi penyakit paru dan menemukan keunggulan ResNet50 dalam akurasi, namun fokus penelitian masih mencakup berbagai jenis penyakit sehingga analisis khusus terhadap TBC belum optimal[16].

Penelitian oleh Berliani et al. (2023) menunjukkan bahwa ResNet50 memiliki stabilitas performa yang lebih baik dibandingkan VGG16 pada klasifikasi citra X-ray multi-kelas, meskipun dari sisi inferensi VGG16 lebih cepat[17]. Sharma et al. (2024) mengusulkan pendekatan kombinasi segmentasi menggunakan UNet dan klasifikasi menggunakan Xception untuk meningkatkan akurasi deteksi TBC, tetapi pendekatan tersebut memerlukan kompleksitas komputasi yang tinggi[18]. Rahman et al. (2020) mengintegrasikan segmentasi dan klasifikasi berbasis ResNet50 dan InceptionV3 untuk meningkatkan akurasi deteksi, namun kebutuhan sumber daya komputasi menjadi tantangan dalam implementasi praktis[19].

Berdasarkan tinjauan penelitian terdahulu, dapat disimpulkan bahwa sebagian besar studi lebih menekankan penggunaan arsitektur *pretrained* dan peningkatan performa melalui kompleksitas model atau penambahan tahapan pemrosesan seperti segmentasi dan visualisasi[20]. Namun, penelitian yang secara langsung membandingkan CNN dasar sebagai model *baseline* dengan ResNet50 berbasis *transfer learning* pada dataset yang sama dan skema pelatihan yang identik masih relatif terbatas, khususnya dalam konteks klasifikasi TBC. Selain itu, aspek efisiensi komputasi, seperti waktu pelatihan dan waktu inferensi, sering kali belum dianalisis secara kuantitatif sebagai bagian dari evaluasi kinerja model.

Dengan demikian, gap penelitian terletak pada kebutuhan evaluasi komprehensif yang tidak hanya menilai akurasi klasifikasi, tetapi juga mempertimbangkan stabilitas pelatihan serta efisiensi komputasi antara CNN dasar dan ResNet50. Melalui penggunaan *dataset* yang seimbang, *preprocessing* yang konsisten, serta pengaturan eksperimen yang reproduktibel, penelitian ini diharapkan mampu memberikan gambaran objektif mengenai trade-off antara kompleksitas model dan performa praktis dalam penerapan sistem *skrining* TBC berbasis kecerdasan buatan.

Tujuan penelitian ini adalah membandingkan kinerja CNN dasar dan ResNet50 berbasis *transfer learning* dalam mengklasifikasikan citra X-ray paru menjadi dua kelas, yaitu TBC dan Normal. Evaluasi dilakukan menggunakan metrik akurasi, presisi, recall, dan F1-score, disertai analisis waktu pelatihan dan waktu inferensi. Hasil penelitian diharapkan dapat menjadi referensi dalam pemilihan model yang paling sesuai dengan kebutuhan aplikasi, baik untuk lingkungan dengan keterbatasan sumber daya komputasi maupun untuk sistem yang menuntut tingkat akurasi tinggi dalam mendukung proses *skrining* awal tuberkulosis.


2. METODOLOGI PENELITIAN

2.1 Jenis Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen komputasional[21] untuk membandingkan performa CNN dasar dan ResNet50 dalam klasifikasi tuberkulosis pada citra X-ray paru. Kedua model diuji menggunakan dataset serta tahapan pra-proses yang sama guna memastikan perbandingan yang objektif, dengan evaluasi performa berdasarkan metrik akurasi, presisi, recall, dan F1-score. Pendekatan ini memberikan bukti empiris yang terukur untuk menentukan model yang paling efektif dalam klasifikasi citra medis.

2.2 Kerangka Penelitian

Kerangka penelitian ini disusun untuk memberikan gambaran sistematis mengenai alur kerja penelitian mulai dari tahap awal hingga tahap evaluasi akhir. Adapun tahapan yang akan dilakukan pada penelitian ini dapat diuraikan pada Gambar 1.



Gambar 1. Kerangka Penelitian

2.3 Rencana Pembahasan

2.3.1 Pengumpulan Data

Dataset penelitian bersumber dari Mendeley Data berjudul “Tuberculosis Chest X-Ray Images” yang berisi 2.494 citra *X-ray* pasien TBC dan 514 citra paru normal dari sebuah rumah sakit di Pakistan, dengan seluruh citra telah diseragamkan ukurannya. Dari total 3.008 citra, dipilih secara acak 1.000 citra yang seimbang antara kelas TBC dan Normal (masing-masing 500 citra) untuk menghindari bias data, kemudian dibagi menjadi 70% data pelatihan, 15% validasi, dan 15% pengujian. Pembagian ini memungkinkan proses pembelajaran, pemantauan, dan evaluasi model CNN dan ResNet50 dilakukan secara objektif dan akurat.

2.3.2 Preprocessing Data


Preprocessing dilakukan untuk memastikan seluruh citra memiliki format yang seragam sebelum digunakan pada model. Proses ini mencakup *resize* citra menjadi 224×224 piksel agar sesuai dengan kebutuhan CNN dan ResNet50, serta normalisasi nilai piksel ke rentang 0–1 untuk meningkatkan *stabilitas* proses pelatihan. Selain itu, seperti rotasi kecil, *flipping* horizontal, *zoom*, dan penyesuaian *brightness* diterapkan untuk menambah keragaman citra dan mengurangi risiko *overfitting*. Seluruh tahapan *preprocessing* diterapkan secara konsisten pada kedua model agar proses perbandingan tetap objektif.

2.3.3 Perancangan Model CNN

Model CNN dasar dikembangkan melalui beberapa lapisan konvolusi bertahap dengan aktivasi ReLU untuk mengekstraksi fitur visual awal pada citra *X-ray*, seperti tepi dan tekstur, yang diikuti oleh *max pooling* guna mengurangi dimensi spasial dan risiko *overfitting*. Fitur yang dihasilkan kemudian diratakan menggunakan *flatten layer* dan diproses melalui lapisan *fully connected* dengan tambahan dropout untuk meningkatkan generalisasi, sementara lapisan *output* menggunakan satu *neuron* beraktivasi sigmoid untuk klasifikasi dua kelas, yaitu TBC dan Normal. Model ini dilatih sepenuhnya dari awal menggunakan optimizer Adam dengan parameter pelatihan tertentu, tanpa memanfaatkan bobot *pretrained*, sehingga kinerjanya sangat bergantung pada kualitas data dan proses pelatihan, serta digunakan sebagai model *baseline* untuk membandingkan peningkatan performa ResNet50 berbasis transfer learning.



Copyright © 2026 The **Muhammad Fathir Aulia**, Page 149
This Journal is licensed under a Creative Commons Attribution 4.0 International License



Gambar 3. Flowchart Model Resnet50

2.3.5 Training Model

Proses pelatihan dilakukan dengan memberikan data latih yang telah diproses sebelumnya kepada model. Pada tahap ini, CNN dan ResNet50 belajar mengenali pola citra melalui mekanisme *backpropagation*, yaitu pembaruan bobot berdasarkan nilai *loss*. Pelatihan berlangsung selama beberapa *epoch* hingga model mencapai performa yang stabil dan mampu membangun representasi fitur yang optimal dari data.

2.3.6 Validasi Model

Selama proses pelatihan, digunakan data validasi untuk menilai kemampuan model pada data yang tidak dilibatkan dalam proses belajar. Validasi membantu memantau risiko *overfitting* dan memastikan pelatihan tetap stabil melalui indikator seperti *training loss*, *validation loss*, dan akurasi. Jika ditemukan ketidakseimbangan performa, parameter pelatihan dapat disesuaikan. Setelah tahap training dan validasi selesai, model terbaik dipilih untuk pengujian akhir.

2.3.7 Testing Model

Tahap *testing* model dilakukan sebagai bagian dari perbandingan CNN dasar dan ResNet50 dalam klasifikasi *tuberkulosis* (TBC) pada citra X-ray paru-paru. Pada tahap ini, kedua model yang telah melalui proses pelatihan dan validasi diuji menggunakan data uji sebesar 15% dari total dataset untuk melakukan proses klasifikasi citra ke dalam dua kelas, yaitu TBC dan Normal. Pengujian dilakukan tanpa pembaruan bobot jaringan, sehingga mencerminkan kemampuan generalisasi masing-masing arsitektur dalam mengklasifikasikan citra X-ray paru-paru.


2.3.8 Evaluasi Performa

Evaluasi performa dilakukan menggunakan data uji untuk menilai kemampuan model dalam mengklasifikasikan citra *X-ray* paru-paru yang belum pernah digunakan pada proses pelatihan. Pada tahap ini, hasil klasifikasi CNN dan ResNet50 dibandingkan dengan label asli melalui *confusion matrix* untuk memperoleh metrik akurasi, presisi, recall, dan F1-score. Analisis ini juga membantu mengidentifikasi jenis kesalahan yang muncul. Setelah seluruh metrik dihitung, performa kedua model dibandingkan untuk menentukan arsitektur yang lebih efektif serta menilai kontribusi *transfer learning* terhadap peningkatan akurasi klasifikasi.

3. HASIL DAN PEMBAHASAN

3.1 Dataset

Dataset yang digunakan dalam penelitian ini adalah dataset *tbparu* yang bersumber dari repositori publik Mendeley Data, berupa citra X-ray paru-paru dengan dua kelas, yaitu tuberkulosis (TBC) dan Normal. Dataset asli terdiri dari 2.494 citra TBC dan 514 citra paru normal yang dikumpulkan dari rumah sakit lokal di Pakistan, dengan seluruh citra telah diseragamkan dimensinya serta disusun dalam struktur folder berbasis kelas agar mudah diproses sistem. Dari dataset tersebut, digunakan subset sebanyak 1.000 citra yang dipilih dan seimbang (500 TBC dan 500 Normal) untuk menghindari bias model, kemudian dibagi secara acak dengan seed tetap ke dalam data pelatihan (70%), validasi (15%), dan pengujian (15%). Citra dalam dataset memiliki variasi resolusi, kontras, dan pencahayaan yang mencerminkan kondisi nyata data medis, sehingga menuntut model mampu melakukan generalisasi dengan baik.



Gambar 4. Sampel *Dataset* Rontgen Paru Normal

Gambar 4 menampilkan visualisasi beberapa sampel citra rontgen paru normal yang digunakan dalam penelitian ini sebagai representasi kelas normal.

Gambar 5 menampilkan visualisasi beberapa sampel citra rontgen paru dengan indikasi tuberkulosis (TBC) yang digunakan dalam penelitian ini sebagai representasi kelas TBC.



Gambar 5. Sampel *Dataset* Rontgen Paru TBC


3.2 Hasil Preprocessing

Tahap *preprocessing* dilakukan untuk memastikan seluruh citra memiliki format yang seragam dan siap digunakan oleh model CNN dasar dan ResNet50. Preprocessing mencakup proses *resize* citra menjadi 224×224 piksel, normalisasi nilai piksel ke rentang 0–1, serta penyesuaian format kanal warna agar sesuai dengan kebutuhan *input* model. Seluruh proses *preprocessing* dilakukan secara otomatis melalui *pipeline* pemrosesan data pada sistem sehingga konsistensi data dapat terjaga. Tujuan utama *preprocessing* adalah meningkatkan stabilitas proses pelatihan, mempercepat komputasi, serta mengurangi pengaruh perbedaan skala intensitas dan kualitas citra. Dalam penelitian ini tidak diterapkan teknik augmentasi data, sehingga model dilatih menggunakan citra asli hasil normalisasi tanpa manipulasi tambahan. Seluruh tahapan *preprocessing* diterapkan secara konsisten pada kedua model untuk menjaga objektivitas perbandingan kinerja.

3.2.1 Preprocessing pada Model CNN

Pada model CNN dasar, seluruh citra hasil *preprocessing* digunakan sebagai *input* langsung tanpa menggunakan bobot pra-latih (*training from scratch*). Normalisasi nilai piksel membantu mempercepat konvergensi proses pelatihan, sedangkan penyamaan ukuran citra memastikan kesesuaian dimensi *input* terhadap arsitektur jaringan.


Hasil *preprocessing* divisualisasikan dalam bentuk citra sebelum dan sesudah normalisasi untuk menunjukkan bahwa struktur utama paru-paru tetap terjaga meskipun ukuran dan skala piksel telah diseragamkan. Hal ini memastikan bahwa CNN mampu mempelajari pola tekstur, kontur, dan karakteristik visual paru secara optimal. Berikut hasil *preprocessing* CNN ditampilkan pada Gambar 6.



Gambar 6. Hasil *Preprocessing* CNN

3.2.2 Preprocessing pada Model ResNet50

Pada model ResNet50, *preprocessing* disesuaikan dengan standar *input* arsitektur *pretrained*, khususnya dalam aspek ukuran citra dan normalisasi nilai piksel. Penyesuaian ini bertujuan agar bobot *pretrained* yang berasal dari *dataset* ImageNet dapat bekerja secara optimal ketika diterapkan pada citra X-ray paru-paru. Visualisasi hasil *preprocessing* menunjukkan bahwa struktur anatomis paru tetap terjaga sehingga fitur visual penting masih dapat dikenali oleh jaringan residual. Konsistensi *preprocessing* antara CNN dasar dan ResNet50 memastikan bahwa perbandingan performa dilakukan secara adil dan objektif. Berikut hasil *preprocessing* ResNet50 ditampilkan pada Gambar 7.



Gambar 7. Hasil *Preprocessing* ResNet50

3.3 Implementasi dan Konfigurasi Model

3.3.1 Arsitektur CNN Dasar

Model CNN dasar digunakan sebagai *baseline* dan dilatih sepenuhnya dari awal tanpa bobot *pretrained*, dengan arsitektur tiga blok konvolusi berurutan yang terdiri dari Conv2D, aktivasi ReLU, dan *max pooling* untuk mengekstraksi fitur citra X-ray paru. Jumlah *filter* meningkat bertahap dari 32, 64, hingga 128, kemudian *feature map* diratakan dan diproses melalui *fully connected layer* berisi 128 *neuron* dengan *dropout*, serta satu *neuron* beraktivasi sigmoid pada lapisan *output* untuk klasifikasi TBC dan Normal. Berdasarkan ringkasan model, CNN memiliki total 12.938.561 parameter yang seluruhnya bersifat *trainable*, menunjukkan kapasitas representasi yang tinggi namun memerlukan pelatihan yang stabil agar terhindar dari *overfitting*.

Layer (type)	Output shape	Param #
conv2d (conv2d)	(None, 32, 32, 32)	896
re_lu (ReLU)	(None, 32, 32, 32)	0
max_pooling2d (MaxPooling2D)	(None, 16, 16, 32)	0
conv2d_1 (conv2d)	(None, 16, 16, 64)	16,496
re_lu_1 (ReLU)	(None, 16, 16, 64)	0
max_pooling2d_1 (MaxPooling2D)	(None, 8, 8, 64)	0
conv2d_2 (conv2d)	(None, 8, 8, 128)	73,856
re_lu_2 (ReLU)	(None, 8, 8, 128)	0
max_pooling2d_2 (MaxPooling2D)	(None, 4, 4, 128)	0
flatten (Flatten)	(None, 16384)	0
dense (Dense)	(None, 128)	12,645,184
re_lu_3 (ReLU)	(None, 128)	0
dropout (Dropout)	(None, 128)	0
dense_1 (Dense)	(None, 1)	128

Total params: 12,938,561 (49.36 MB)
Trainable params: 12,938,561 (49.36 MB)
Non-trainable params: 0 (0.00 B)

Gambar 8. Arsitektur Model CNN

3.3.2 Arsitektur ResNet50 Berbasis *Transfer Learning*

Model ResNet50 menggunakan pendekatan *transfer learning* dengan memanfaatkan bobot *pretrained* dari dataset ImageNet sebagai dasar ekstraksi fitur. Arsitektur ResNet50 terdiri dari jaringan residual dengan 50 lapisan yang dilengkapi mekanisme *skip connection*, sehingga mampu menjaga stabilitas aliran gradien pada jaringan dalam.

Layer (type)	Output shape	Param #
input_layer_2 (InputLayer)	(None, 224, 224, 3)	0
resnet50 (functional)	(None, 7, 7, 2048)	23,587,712
global_average_pooling2d (GlobalAveragePooling2D)	(None, 2048)	0
dropout_1 (Dropout)	(None, 2048)	0
dense_2 (Dense)	(None, 1)	2,049

Total params: 23,589,761 (89.99 MB)
Trainable params: 23,589,761 (89.99 MB)
Non-trainable params: 23,587,712 (89.98 MB)

Gambar 9. Arsitektur Model ResNet50

Pada tahap awal, seluruh lapisan *backbone* ResNet50 dibekukan untuk mempertahankan bobot *pretrained*, sementara bagian *classifier* dimodifikasi dengan menambahkan *Global Average Pooling*, *Dropout*, dan satu lapisan dense beraktivasi sigmoid untuk klasifikasi dua kelas. Selanjutnya, *fine-tuning* dilakukan dengan membuka sebagian lapisan atas *backbone* agar model dapat menyesuaikan fitur dengan karakteristik citra X-ray paru, sehingga pengetahuan umum dari ImageNet tetap terjaga sekaligus adaptif terhadap domain medis. Berdasarkan ringkasan model, ResNet50 memiliki total 23.589.761 parameter, dengan hanya 2.049 parameter yang dilatih pada tahap awal, menjadikannya lebih efisien dibandingkan CNN dasar, khususnya pada kondisi dataset terbatas.

3.3.3 Parameter Pelatihan dan Hyperparameter

Parameter pelatihan dan hyperparameter ditetapkan secara konsisten untuk memastikan perbandingan performa antara CNN dasar dan ResNet50 berlangsung secara objektif. Beberapa konfigurasi utama yang digunakan dalam penelitian ini meliputi:


- Optimizer: Adam
- Learning Rate CNN: 1×10^{-4}
- Learning Rate ResNet50 (Transfer Learning): 1×10^{-4}
- Learning Rate ResNet50 (Fine-Tuning): 1×10^{-5}
- Batch Size: (sesuai konfigurasi sistem)
- Epoch Maksimum: 20 epoch per tahap pelatihan
- Loss Function: Binary Crossentropy
- Callback: Early Stopping dan Reduce Learning Rate on Plateau
- Dropout Rate: 0,3

3.4 Hasil Pelatihan dan Validasi Model

Tahap pelatihan dan validasi dilakukan untuk mengevaluasi kemampuan model CNN dasar dan ResNet50 dalam mempelajari pola citra X-ray paru-paru serta menilai kestabilan proses pembelajaran.

3.4.1 Analisis Training dan Validation CNN

Berdasarkan grafik pelatihan CNN murni Gambar 10, terlihat bahwa nilai *training loss* mengalami penurunan yang konsisten sejak *epoch* awal, dari sekitar 0,66 hingga mendekati 0,04 pada *epoch* akhir. Penurunan ini menunjukkan bahwa model mampu mempelajari pola data pelatihan dengan baik dan proses optimisasi berjalan secara stabil.




Gambar 10. Plot Kurva CNN


Nilai validation loss menunjukkan kecenderungan menurun dengan sedikit fluktuasi, menandakan model masih mampu melakukan generalisasi meskipun dipengaruhi keterbatasan data dan kompleksitas citra medis. Training accuracy meningkat tajam dari sekitar 61% hingga mendekati 98%, sementara validation accuracy stabil pada kisaran 91%–96% setelah epoch ke-5, dengan selisih kecil yang mengindikasikan overfitting ringan namun masih wajar. Waktu pelatihan sekitar 40,46 detik menunjukkan CNN dasar cukup efisien secara komputasi, cepat mencapai konvergensi, dan layak digunakan sebagai model baseline meskipun dilatih tanpa bobot pretrained.

3.4.2 Analisis Training dan Validation ResNet50

Hasil pelatihan ResNet50 dilakukan dalam dua tahap, yaitu tahap *transfer learning* (Stage-1) dan *fine-tuning* (Stage-2).



Gambar 11. Plot Kurva ResNet50 Tahap *Transfer Learning*



Gambar 12. Plot Kurva ResNet50 Tahap *Fine-Tuning*

Pada tahap *transfer learning* Gambar 11, *training* dan *validation loss* menurun secara bertahap, menunjukkan bahwa *classifier* di atas *backbone pretrained* mampu beradaptasi dengan citra X-ray paru, dengan *training accuracy* meningkat dari sekitar 55% menjadi lebih dari 93% dan *validation accuracy* mendekati 94%. Selanjutnya, pada tahap *fine-tuning* Gambar 12, performa meningkat lebih signifikan, ditandai oleh penurunan tajam *training loss* hingga mendekati nol dan *validation loss* yang stabil pada kisaran 0,03–0,04, serta *training accuracy* mendekati 100% dan *validation accuracy* meningkat hingga sekitar 98–99%, yang menegaskan efektivitas penyesuaian fitur tingkat tinggi terhadap karakteristik citra medis.

3.4.3 Analisis Stabilitas Pelatihan


Analisis stabilitas pelatihan menunjukkan bahwa CNN dasar mengalami fluktuasi kecil pada *validation loss* dan *accuracy*, menandakan sensitivitas terhadap variasi data, namun selisih kinerja *training* dan *validation* masih wajar sehingga tidak menunjukkan *overfitting* yang signifikan. Sebaliknya, ResNet50 menampilkan pola pelatihan yang lebih konsisten, terutama pada tahap *fine-tuning*, dengan penurunan *loss* yang stabil dan jarak performa yang kecil antara data *training* dan *validation*, mencerminkan kemampuan generalisasi yang lebih baik. Dari sisi komputasi, CNN lebih cepat dilatih, sedangkan ResNet50 unggul dalam kestabilan dan kualitas pembelajaran fitur, sehingga terdapat trade-off antara efisiensi waktu dan performa model.

3.5 Evaluasi Kinerja Model pada Data Uji

Evaluasi kinerja model dilakukan menggunakan data uji yang tidak pernah digunakan pada tahap pelatihan maupun validasi. Pengujian ini bertujuan untuk mengukur kemampuan generalisasi model CNN dasar dan ResNet50 dalam mengklasifikasikan citra X-ray paru-paru ke dalam dua kelas, yaitu Normal dan TBC.

3.5.1 Confusion Matrix Model CNN

Confusion matrix pada model CNN dasar Gambar 13, menunjukkan bahwa dari 150 data uji, seluruh 75 citra Normal berhasil diklasifikasikan dengan benar, sementara pada kelas TBC terdapat 72 citra terklasifikasi benar dan 3 citra salah dikenali sebagai Normal, tanpa adanya *false positive*. Hasil ini menghasilkan *recall* sebesar 1,00 untuk kelas Normal dan menunjukkan masih adanya sedikit kesalahan pada deteksi TBC. Secara keseluruhan, CNN mencapai akurasi 98,00% dengan nilai *precision*, *recall*, dan *F1-score* yang seimbang, menandakan bahwa meskipun dilatih tanpa bobot pretrained, model mampu mempelajari pola utama citra X-ray paru secara efektif.



Gambar 13. *Confusion Matrix* Model CNN


Classification Report:

	precision	recall	f1-score	support
Normal	0.9615	1.0000	0.9804	75
TBC	1.0000	0.9600	0.9796	75
accuracy			0.9800	150
macro avg	0.9808	0.9800	0.9800	150
weighted avg	0.9808	0.9800	0.9800	150

Gambar 14. *Klasifikasi Report* Model CNN

3.5.2 *Confusion Matrix* Model ResNet50

Confusion matrix ResNet50 Gambar 15, menunjukkan bahwa dari 150 data uji, seluruh 75 citra Normal berhasil diklasifikasikan dengan benar, sementara pada kelas TBC terdapat 74 citra terklasifikasi benar dan hanya 1 citra salah dikenali sebagai Normal. Hasil ini menghasilkan akurasi sebesar 99,33% dengan nilai precision, recall, dan F1-score yang sangat tinggi. Dibandingkan CNN dasar, ResNet50 memiliki kesalahan klasifikasi yang lebih sedikit, menegaskan bahwa transfer learning dan fine-tuning meningkatkan kemampuan ekstraksi fitur kompleks serta generalisasi model pada citra medis.



Gambar 15. *Confusion Matrix* Model ResNet50

Classification Report:

	precision	recall	f1-score	support
Normal	0.9868	1.0000	0.9934	75
TBC	1.0000	0.9867	0.9933	75
accuracy			0.9933	150
macro avg	0.9934	0.9933	0.9933	150
weighted avg	0.9934	0.9933	0.9933	150

Gambar 16. *Klasifikasi Report* Model ResNet50

Hasil evaluasi menunjukkan ResNet50 sedikit lebih unggul dari CNN dasar, khususnya pada klasifikasi TBC, meskipun CNN tetap kompetitif dengan arsitektur yang lebih sederhana.

3.6 Pengujian Lanjutan dan Analisis Robustness

Pengujian lanjutan (*robustness test*) dilakukan untuk menilai kemampuan generalisasi CNN dasar dan ResNet50 terhadap citra *X-ray* baru di luar data pelatihan, validasi, dan pengujian utama. Pada tahap ini, model digunakan langsung untuk inferensi tanpa pelatihan ulang terhadap citra uji eksternal yang diunggah secara manual. Pengujian ini bertujuan mengevaluasi konsistensi prediksi pada kondisi data nyata serta mengukur efisiensi waktu inferensi sebagai indikator kelayakan penerapan model pada sistem nyata.

3.6.1 Pengujian Lanjutan Model CNN


Hasil pengujian menunjukkan bahwa CNN menghasilkan prediksi yang konsisten dengan nilai probabilitas yang cukup meyakinkan pada citra uji eksternal, baik untuk kelas TBC maupun Normal. Selain itu, CNN memiliki keunggulan dalam efisiensi komputasi, dengan waktu inferensi berkisar antara 63–171 ms per citra dan rata-rata sekitar ± 101 ms per gambar. Temuan ini menunjukkan bahwa arsitektur CNN yang sederhana memiliki kompleksitas rendah dan sesuai untuk aplikasi yang membutuhkan respons cepat.

3.6.2 Pengujian Lanjutan Model ResNet50

Hasil pengujian menunjukkan bahwa ResNet50 mampu menghasilkan prediksi dengan tingkat keyakinan probabilitas yang tinggi, baik pada citra TBC maupun Normal, sehingga memberikan estimasi yang lebih tajam dibanding CNN pada beberapa kasus. Namun, dari sisi efisiensi, ResNet50 memiliki waktu inferensi yang lebih lama, dengan kisaran 109–5.599 ms per gambar dan rata-rata sekitar ± 1.954 ms, akibat kompleksitas arsitektur residual dan jumlah parameter yang lebih besar dibanding CNN dasar.

3.6.3 Analisis Robustness dan Kecepatan Inferensi

Hasil pengujian lanjutan menunjukkan bahwa CNN dan ResNet50 mampu mengklasifikasikan citra *X-ray* baru secara konsisten tanpa kesalahan signifikan. CNN unggul dalam kecepatan dan stabilitas dengan waktu inferensi sekitar ± 100 ms per gambar, sehingga cocok untuk sistem real-time atau perangkat terbatas, sedangkan ResNet50 menghasilkan probabilitas prediksi yang lebih tajam berkat kemampuan representasi fitur yang lebih kompleks, namun memerlukan waktu inferensi lebih lama sekitar $\pm 1,9$ detik per gambar. Temuan ini menegaskan adanya trade-off antara efisiensi komputasi dan ketajaman prediksi dalam pemilihan model untuk implementasi praktis.




Gambar 17. Hasil Prediksi CNN dan ResNet50 pada Citra Uji 1

file	cnn_pred	cnn_prob_tbc	cnn_time_ms	res_pred	res_prob_tbc	res_time_ms
0 diagnosis.jpg	TBC	0.637649	171.378932	Normal	0.480943	5599.958932

Rata-rata waktu inferensi CNN : 171.38 ms/gambar
Rata-rata waktu inferensi ResNet50: 5599.96 ms/gambar
Kesimpulan cepat: CNN lebih cepat untuk inferensi pada uji ini.

Gambar 18. Waktu Inferensi CNN dan ResNet50 1




Gambar 19. Hasil Prediksi CNN dan ResNet50 pada Citra Uji 2

```
***
```

file	cnn_pred	cnn_prob_tbc	cnn_time_ms	res_pred	res_prob_tbc	res_time_ms
0 asasas.jpg	Normal	0.473077	69.574609	TBC	0.847237	109.703772

Rata-rata waktu inferensi CNN : 69.57 ms/gambar
Rata-rata waktu inferensi ResNet50: 109.70 ms/gambar
Kesimpulan cepat: CNN lebih cepat untuk inferensi pada uji ini.

Gambar 20. Waktu Inferensi CNN dan ResNet50 2



Gambar 21. Hasil Prediksi CNN dan ResNet50 pada Citra Uji 3

```
***
```

file	cnn_pred	cnn_prob_tbc	cnn_time_ms	res_pred	res_prob_tbc	res_time_ms
0 Capture.JPG	Normal	0.030282	63.920151	Normal	0.021977	151.979834

Rata-rata waktu inferensi CNN : 63.92 ms/gambar
Rata-rata waktu inferensi ResNet50: 151.98 ms/gambar
Kesimpulan cepat: CNN lebih cepat untuk inferensi pada uji ini.

Gambar 22. Waktu Inferensi CNN dan ResNet50 3

3.7 Analisis Perbandingan Kinerja CNN dan ResNet50

3.7.1 Perbandingan Akurasi dan Generalisasi

Berdasarkan evaluasi data uji, CNN dasar dan ResNet50 sama-sama menunjukkan performa sangat baik dalam klasifikasi citra X-ray paru Normal dan TBC. CNN mencapai akurasi 98,00% dengan nilai precision, recall, dan F1-score yang seimbang, meskipun menghasilkan tiga kesalahan klasifikasi, sedangkan ResNet50 menunjukkan kinerja lebih tinggi dengan akurasi 99,33%, nilai metrik rata-rata di atas 0,99, dan hanya satu kesalahan klasifikasi. Dari sisi generalisasi, kedua model menunjukkan konvergensi yang stabil, dengan CNN mengalami fluktuasi ringan namun masih wajar, sementara ResNet50 lebih konsisten terutama pada tahap fine-tuning. Pengujian lanjutan pada citra eksternal juga menunjukkan prediksi yang konsisten, di mana ResNet50 menghasilkan probabilitas yang lebih tajam berkat kemampuan representasi fitur yang lebih kuat, sementara CNN tetap kompetitif pada kondisi data terbatas.

3.7.2 Analisis Efisiensi Komputasi

Analisis efisiensi komputasi menunjukkan bahwa CNN dasar jauh lebih cepat dibanding ResNet50, baik pada tahap pelatihan maupun inferensi. CNN hanya membutuhkan waktu pelatihan sekitar 40,46 detik, sedangkan ResNet50 memerlukan total sekitar 226,99 detik dari tahap transfer learning dan fine-tuning akibat kompleksitas arsitektur dan jumlah parameter yang lebih besar. Pada tahap inferensi, CNN juga lebih efisien dengan waktu sekitar ± 100 ms per gambar, sementara ResNet50 membutuhkan sekitar ± 1.900 ms. Temuan ini menegaskan adanya trade-off antara akurasi dan efisiensi, di mana ResNet50 unggul dalam kualitas prediksi dan generalisasi, sedangkan CNN lebih cocok untuk aplikasi cepat dan perangkat dengan sumber daya terbatas.

4. KESIMPULAN

Berdasarkan hasil implementasi dan evaluasi, model CNN dasar dan ResNet50 berbasis *transfer learning* sama-sama mampu mengklasifikasikan citra X-ray paru dengan tingkat akurasi yang sangat tinggi, yaitu masing-masing sebesar 98,00% dan 99,33% pada data uji, sehingga menegaskan bahwa pendekatan *deep learning* efektif digunakan sebagai alat bantu klasifikasi citra medis untuk mendeteksi indikasi tuberkulosis secara otomatis. Dari sisi kemampuan generalisasi, ResNet50 menunjukkan performa yang sedikit lebih unggul dibandingkan CNN dasar, ditunjukkan oleh nilai precision, recall, dan F1-score yang lebih stabil serta jumlah kesalahan klasifikasi yang lebih kecil pada *confusion matrix*, yang didukung oleh pemanfaatan bobot *pretrained* dan mekanisme *residual connection* sehingga mampu mengekstraksi fitur kompleks secara lebih optimal meskipun jumlah data relatif terbatas. Pengujian robustness menggunakan citra eksternal juga memperlihatkan bahwa kedua model menghasilkan prediksi yang konsisten, dengan CNN memiliki keunggulan pada kecepatan inferensi, sedangkan ResNet50 menunjukkan tingkat keyakinan prediksi yang lebih stabil pada beberapa sampel. Dari aspek efisiensi komputasi, CNN dasar unggul signifikan dalam waktu pelatihan dan inferensi dengan waktu training sekitar 40 detik, sementara ResNet50 memerlukan sekitar 227 detik atau sekitar 5,6 kali lebih lama, sehingga

menunjukkan adanya *trade-off* antara kualitas prediksi dan kebutuhan komputasi, di mana CNN lebih sesuai untuk sistem dengan keterbatasan sumber daya atau kebutuhan respons cepat, sedangkan ResNet50 lebih tepat digunakan pada aplikasi yang memprioritaskan akurasi dan stabilitas generalisasi, sehingga pemilihan model perlu disesuaikan dengan kebutuhan implementasi sistem yang diinginkan.

REFERENCES

- [1] A. Rasyid and L. Heryawan, "Klasifikasi Penyakit Tuberculosis (TB) Organ Paru Manusia Berdasarkan Citra Rontgen Thorax Menggunakan Metode Convolutional Neural Network (CNN)," *J. Manaj. Inf. Kesehat. Indones.*, vol. 11, no. 1, pp. 35–44, 2023, doi: 10.33560/jmiki.v11i1.484.
- [2] P. P. Aldi Akbar Alimi, Ahmad Rio Adriansyah, "PENGEMBANGAN SISTEM DETEKSI TUBERKULOSIS PADA CITRA X-RAY MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK (CNN) DENGAN FRAMEWORK LARAVEL," *J. Inform. Terpadu*, vol. 10, no. 2, pp. 129–138, 2024, [Online]. Available: <https://journal.nurulfikri.ac.id/index.php/JIT>
- [3] Y. Aldiansyah, P. R. Fadilah, E. P. Nainggolan, A. P. Susilo, and P. Rosyani, "Penerapan Klasifikasi CNN Kepada Citra X-Ray Untuk Deteksi Tuberkolosis," *JURIHUM J. Inov. dan Hum.*, vol. 2, no. 3, pp. 471–476, 2024.
- [4] G. P. H. P. Gusti, E. Haerani, F. Syafria, F. Yanto, and S. K. Gusti, "Implementation of convolutional neural network algorithm (ResNet-50) for benign and malignant skin cancer classification," *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 4, no. 3, pp. 984–992, 2024.
- [5] G. M. A. Sihotang and J. Supardi, "Pengembangan Model CNN ResNet-18 untuk Klasifikasi Kondisi Gigi Berbasis Citra RGB sebagai Solusi Diagnostik Digital," *J. Pendidik. dan Teknol. Indones.*, vol. 4, no. 12, pp. 747–758, 2024, doi: 10.52436/1.jpti.568.
- [6] F. Y. Sulistia and A. Vatesia, "Penerapan Deep Learning Menggunakan Convolutional Neural Network (CNN) Untuk Klasifikasi Daging Ayam Menggunakan Arsitektur Resnet-50," *INTECOMS J. Inf. Technol. Comput. Sci.*, vol. 7, no. 3, pp. 685–691, 2024, doi: 10.31539/intecom.v7i3.10087.
- [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, pp. 1–8, 2024, doi: 10.56211/sudo.v3i1.483.
- [8] N. Fitriah, *IMPLEMENTASI ALGORITMA CONVOLUTIONAL NEURAL NETWORK DALAM KLASIFIKASI KEPARAHAN LUKA KAKI PENDERITA DIABETES MELLITUS TIPE 2*. Medan: UINSU Press, 2025.
- [9] M. B. Kurniawan and E. Utami, "Perbandingan Kinerja ResNet50, VGG16, dan MobileNetV2 untuk Klasifikasi Tumor Otak pada Citra MRI," *J. Sist. Inf.*, vol. 14, no. 2, pp. 767–777, 2025, [Online]. Available: <http://sistemasi.ftik.unisi.ac.id>
- [10] Arimbi Puspitasari, Diana Sava Salsabila, and Dwi Roliawati, "Penerapan ResNet50-CNN untuk Optimalisasi Klasifikasi pada Data Fashion," *Indones. J. Data Sci.*, vol. 3, no. 1, pp. 1–12, 2025, doi: 10.30989/ijds.v3i1.1533.
- [11] A. Ridhovan and A. Suharto, "Penerapan Metode Residual Network (Resnet) Dalam Klasifikasi Penyakit Pada Daun Gandum," *JUPI (Jurnal Ilm. Penelit. dan Pembelajaran Inform.)*, vol. 7, no. 1, pp. 58–65, 2022, doi: 10.29100/jupi.v7i1.2410.
- [12] U. Kulsum and A. Cherid, "Penerapan Convolutional Neural Network Pada Klasifikasi Tanaman Menggunakan ResNet50," *Simkom*, vol. 8, no. 2, pp. 221–228, 2023, doi: 10.51717/simkom.v8i2.191.
- [13] F. P. Daviana, A. Aryanti, and N. Anugraha, "Performance Comparison Between ResNet50 and MobileNetV2 for Indonesian Sign Language Classification," *JURIKOM (Jurnal Ris. Komputer)*, vol. 12, no. 3, pp. 319–328, 2025, doi: 10.30865/jurikom.v12i3.8667.
- [14] Isvine Zahroya Jazmine Marzuki Fahd, Abdul Rabi, and Elta Sonalitha, "Perbandingan Akurasi Model ResNet50 dan VGG16 dalam Mengklasifikasi Penyakit Cacar Menggunakan Metode Convolutional Neural Network," *Uranus J. Ilm. Tek. Elektro, Sains dan Inform.*, vol. 3, no. 1, pp. 170–180, 2025, doi: 10.61132/uranus.v3i1.679.
- [15] J. Liu and Y. Huang, "Comparison of different CNN models in tuberculosis detecting," *KSII Trans. Internet Inf. Syst.*, vol. 14, no. 8, pp. 3519–3533, 2020, doi: 10.3837/tiis.2020.08.021.
- [16] D. Garmenta Nuriansyah, W. Ayu, and D. Pramana Hostiadi, "Perbandingan Performa Model Pre-Trained Cnn Pada Citra Cxr Dalam Klasifikasi Penyakit Paru-Paru," *Pros. Semin. Has. Penelit. Inform. dan Komput. 2024* □ *SPINTER 202*, vol. 1, no. 2, pp. 22–26, 2024.
- [17] T. Berliani, E. Rahardja, and L. Septiana, "Perbandingan Kemampuan Klasifikasi Citra X-ray Paru-paru menggunakan Transfer Learning ResNet-50 dan VGG-16," *J. Med. Heal.*, vol. 5, no. 2, pp. 123–135, 2023, doi: 10.28932/jmh.v5i2.6116.
- [18] R. S. Shivam Soam, Manan Manglik, Sanyam Sharma, "Comparative Study of Keras CNNs for Tuberculosis Detection from Chest X-rays," *Interantional J. Sci. Res. Eng. Manag.*, vol. 08, no. 05, pp. 1–5, 2024, doi: 10.55041/ijsem34126.
- [19] T. Rahman *et al.*, "Reliable Tuberculosis Detection using Chest X-ray with Deep Learning, Segmentation and Visualization," *IEEE Access*, 2020.
- [20] M. Munadi, "Penerapan Algoritma Deep Learning untuk Deteksi Dini Penyakit dari Citra Medis," *J. Comput. Sci. Inf. Technol.*, vol. 1, no. 2, pp. 53–59, 2025, doi: 10.70716/jocsit.v1i2.259.
- [21] X. Xue *et al.*, "Computational Experiments: A New Analysis Method for Cyber-Physical-Social Systems," *IEEE Trans. Syst. Man, Cybern. Syst.*, vol. 54, pp. 813–826, 2024, doi: 10.1109/tsmc.2023.3322402.