

Deteksi Tuberkulosis Berdasarkan Chest X-Ray Menggunakan Convolutional Neural Network

JOEVITA SALSABILA FITRIANOVA¹, ELLY MATUL IMAH^{2,*}

¹Program Studi Sarjana Sains Data, Universitas Negeri Surabaya, Indonesia

²Program Studi Sarjana Kecerdasan Artifisial, Universitas Negeri Surabaya, Indonesia

Abstrak

Tuberkulosis (TB) merupakan salah satu penyakit infeksi yang masih menjadi masalah kesehatan global. Citra *Chest X-Ray* (CXR) banyak digunakan sebagai alat bantu diagnosis TB, namun interpretasi secara manual masih bergantung pada pengalaman radiolog. Perkembangan *Artificial Intelligence* (AI), khususnya *deep learning*, telah mendorong pengembangan sistem deteksi TB secara otomatis yang lebih cepat dan konsisten. Penelitian ini mengusulkan metode deteksi tuberkulosis berdasarkan CXR menggunakan *Convolutional Neural Network* (CNN). Kinerja model dievaluasi dan dibandingkan dengan beberapa model klasifikasi lainnya, yaitu MobileNetV2, EfficientNetB0, dan InceptionV3. Hasil eksperimen menunjukkan bahwa CNN memperoleh performa terbaik dengan nilai akurasi sebesar 1.00, sedangkan MobileNetV2, EfficientNetB0, dan InceptionV3 masing-masing mencapai akurasi sebesar 0.94, 0.96, dan 0.97. Hasil tersebut menunjukkan bahwa CNN mampu mempelajari karakteristik radiografis yang berkaitan dengan tuberkulosis secara efektif dan memberikan kinerja yang lebih baik dibandingkan model pembanding. Secara keseluruhan, penelitian ini menunjukkan bahwa CNN merupakan pendekatan yang potensial untuk mendukung deteksi tuberkulosis secara otomatis berdasarkan citra CXR.

Kata Kunci *tuberkulosis; chest x-ray; klasifikasi citra; deep learning; CNN*

Abstract

Tuberculosis (TB) remains one of the major infectious diseases worldwide. Chest X-Ray (CXR) imaging is widely used to support TB diagnosis; however, manual interpretation is highly dependent on radiologists' expertise. Advances in Artificial Intelligence (AI), particularly deep learning, have driven the development of automated TB detection systems that are faster and more consistent. This study proposes a tuberculosis detection method based on CXR images using a Convolutional Neural Network (CNN). The proposed model was evaluated and compared with several classification models, namely MobileNetV2, EfficientNetB0, and InceptionV3. Experimental results showed that the CNN achieved the best performance with an accuracy of 1.00, while MobileNetV2, EfficientNetB0, and InceptionV3 achieved accuracies of 0.94, 0.96, and 0.97, respectively. These results indicate that CNN is capable of effectively learning radiographic characteristics associated with tuberculosis and outperforming the comparison models. Overall, this study demonstrates that CNN is a promising approach for automated tuberculosis detection based on Chest X-Ray images.

Keywords *tuberculosis; chest X-ray; image classification; deep learning; CNN*

*Corresponding author. Email: ellymatul@unesa.ac.id.

1 Pendahuluan

Tuberkulosis (TB) merupakan penyakit menular yang disebabkan oleh *Mycobacterium tuberculosis* dan tetap menjadi masalah kesehatan global utama. Berdasarkan *Global Tuberculosis Report 2023* yang diterbitkan oleh World Health Organization, diperkirakan sekitar 10.8 juta orang terinfeksi TB pada tahun 2023 dengan 1.25 juta kematian, menjadikan TB kembali sebagai penyakit infeksius dengan angka kematian tertinggi di dunia [World Health Organization \(2023\)](#). Fakta tersebut menegaskan bahwa TB masih menjadi ancaman serius bagi kesehatan masyarakat global. Diagnosis TB paru umumnya dilakukan melalui pendekatan berbasis sputum, seperti *smear* mikroskopis, kultur bakteri, maupun uji molekuler. Metode tersebut terbukti efektif, namun memerlukan waktu, fasilitas laboratorium, dan tenaga terlatih, serta tidak selalu dapat dilakukan pada pasien yang kesulitan menghasilkan dahak [Kantipudi et al. \(2024\)](#). Citra radiografi seperti Chest X-Ray (CXR) mampu memberikan gambaran menyeluruh kondisi kelainan paru yang berkaitan dengan TB, seperti infiltrat, konsolidasi, kavitas, maupun efusi pleura [Ghanem et al. \(2024\)](#). Namun, interpretasi citra CXR secara manual masih memiliki beberapa keterbatasan. Hasil pembacaan radiografi sangat bergantung pada pengalaman dan keahlian radiolog sehingga dapat menimbulkan variasi interpretasi antar-pengamat maupun pada pengamat yang sama dalam waktu yang berbeda [Ghanem et al. \(2024\)](#). Kondisi tersebut dapat memengaruhi konsistensi dan objektivitas proses diagnosis, terutama pada daerah dengan keterbatasan tenaga medis spesialis [Feyisa et al. \(2023\)](#).


Perkembangan teknologi *Artificial Intelligence* (AI), khususnya *deep learning*, telah menunjukkan potensi yang besar dalam mendukung analisis citra medis secara otomatis. Salah satu metode yang banyak digunakan adalah *Convolutional Neural Network* (CNN), yang memiliki kemampuan untuk mengekstraksi fitur citra secara otomatis dan menghasilkan performa yang baik dalam berbagai tugas klasifikasi citra medis, termasuk deteksi tuberkulosis pada citra CXR [Kumar et al. \(2020\)](#). Keberhasilan pendekatan *deep learning* telah dibuktikan pada berbagai tugas analisis citra medis. Kermany dkk. menunjukkan bahwa model berbasis *deep learning* mampu mengidentifikasi penyakit paru pada citra radiografi [Kermany et al. \(2018\)](#). Pada kasus COVID-19, Wang dkk. mengembangkan COVID-Net untuk mendeteksi infeksi COVID-19 dari citra CXR secara otomatis [Wang et al. \(2020\)](#). Selain itu, Ardila dkk. menunjukkan bahwa pendekatan *deep learning* mampu mendeteksi kanker paru pada citra CT thoraks [Ardila et al. \(2019\)](#). Pada kasus tuberkulosis, Rahman dkk. mengembangkan sistem deteksi TB berbasis *deep learning* yang memanfaatkan citra CXR sebagai masukan model [Rahman et al. \(2020a\)](#). Hasil penelitian tersebut menunjukkan bahwa pendekatan *deep learning*, khususnya CNN, memiliki potensi yang besar dalam mendukung deteksi penyakit paru secara otomatis.

Performa yang diperoleh pada berbagai penelitian masih bervariasi akibat perbedaan dataset, arsitektur model, dan strategi pelatihan yang digunakan. Selain itu, sebagian penelitian memanfaatkan arsitektur yang relatif kompleks sehingga memerlukan sumber daya komputasi yang lebih besar. Berdasarkan hal tersebut, diperlukan penelitian yang mengevaluasi kemampuan arsitektur CNN dalam mengklasifikasikan tuberkulosis pada citra CXR secara efektif dan efisien. Penelitian ini bertujuan untuk mengembangkan model klasifikasi tuberkulosis berbasis CNN sebagai alternatif sistem skrining otomatis yang dapat membantu proses deteksi TB secara cepat, akurat, dan mudah diterapkan pada berbagai lingkungan pelayanan kesehatan.

2 Metode

2.1 Dataset

Penelitian ini menggunakan kombinasi dua dataset publik, yaitu Montgomery County dan Shenzhen Hospital Chest X-Ray Dataset yang diperkenalkan oleh Jaeger dkk. sebagai dataset skrining tuberkulosis berbasis citra CXR [Jaeger et al. \(2014\)](#). Dataset tersebut terdiri atas citra CXR *postero-anterior* (PA) dengan label TB dan normal yang banyak digunakan dalam penelitian deteksi TB berbasis *computer-aided diagnosis*. Pada penelitian ini, kedua dataset digabungkan sehingga diperoleh total 784 citra CXR yang terdiri atas 394 citra TB dan 390 citra normal. Dataset digunakan sebagai dasar dalam pengembangan model CNN untuk mengklasifikasikan citra ke dalam dua kelas, yaitu TB dan normal. Contoh citra dari masing-masing kelas ditunjukkan pada Gambar 1.




Gambar 1: Contoh citra CXR pada dataset klasifikasi TB

Dataset kemudian dibagi menjadi data pelatihan, validasi, dan pengujian dengan rasio 70:15:15. Pembagian data ke dalam subset pelatihan, validasi, dan pengujian dilakukan untuk mendukung proses pelatihan model, pemilihan hiperparameter, serta evaluasi kemampuan generalisasi model pada data yang belum pernah dilihat sebelumnya [Harris et al. \(2021\)](#); [Wen et al. \(2022\)](#). Data validasi digunakan untuk memantau proses pelatihan dan mencegah *overfitting*, sedangkan data pengujian digunakan untuk mengevaluasi performa akhir model pada data yang independen dari proses pelatihan [Harris et al. \(2021\)](#); [Wen et al. \(2022\)](#).

2.2 Alur Penelitian

Penelitian ini mengusulkan metode deteksi TB secara otomatis pada citra Chest X-Ray (CXR) menggunakan *Convolutional Neural Network* (CNN). Proses penelitian diawali dengan tahap *preprocessing* untuk menyeragamkan ukuran citra dan melakukan normalisasi intensitas piksel sehingga data siap digunakan pada proses pelatihan model. Citra hasil *preprocessing* kemudian digunakan sebagai masukan bagi model CNN untuk mengekstraksi fitur dan mempelajari karakteristik radiografis yang berkaitan dengan tuberkulosis. Selanjutnya, model melakukan proses klasifikasi untuk membedakan citra ke dalam dua kelas, yaitu TB dan Normal. Pada tahap akhir, sistem menghasilkan keluaran berupa deteksi kelas citra berdasarkan hasil klasifikasi yang dilakukan oleh model CNN. Diagram alur penelitian ditunjukkan pada Gambar 2.



Gambar 2: Diagram Alur Penelitian

2.3 Preprocessing

Tahap *preprocessing* dilakukan untuk mempersiapkan citra CXR sebelum digunakan pada proses pelatihan dan pengujian model CNN. Pada penelitian ini, ukuran dan karakteristik dataset citra CXR bervariasi karena perbedaan perangkat akuisisi maupun resolusi. Kondisi tersebut dapat memengaruhi konsistensi data masukan dan kinerja model selama proses pelatihan. Oleh karena itu, *preprocessing* diperlukan untuk menyeragamkan format data sehingga model dapat mempelajari pola citra secara lebih efektif dan stabil.


Pada penelitian ini, seluruh citra CXR terlebih dahulu diubah ukurannya (*resizing*) menjadi 256×256 piksel. Proses *resizing* bertujuan untuk menyeragamkan dimensi citra yang berasal dari berbagai dataset sehingga dapat digunakan sebagai masukan model CNN dengan ukuran yang konsisten. Penggunaan ukuran citra yang lebih kecil dapat mengurangi kebutuhan memori dan waktu komputasi selama proses pelatihan tanpa menghilangkan informasi visual penting yang diperlukan untuk proses klasifikasi [Kumar et al. \(2020\)](#); [Shorten and Khoshgoftaar \(2019\)](#).

Setelah proses *resizing*, dilakukan normalisasi intensitas piksel dengan membagi setiap nilai intensitas piksel pada citra terhadap nilai maksimum, yaitu 255. Proses ini mengubah rentang nilai intensitas piksel dari 0–255 menjadi nilai kontinu pada rentang 0–1, tanpa mengubah informasi visual pada citra. Normalisasi bertujuan untuk mengurangi perbedaan skala data masukan sehingga proses optimisasi dapat berlangsung lebih stabil. Selain itu, normalisasi membantu mempercepat konvergensi model dan meningkatkan efisiensi pelatihan karena distribusi data menjadi lebih seragam [LeCun et al. \(2012\)](#). Hasil dari tahap *preprocessing* berupa citra CXR berukuran 256×256 piksel dengan nilai intensitas yang telah dinormalisasi, yang selanjutnya digunakan sebagai masukan pada tahap klasifikasi tuberkulosis menggunakan CNN.

2.4 Klasifikasi Tuberkulosis Menggunakan CNN

Convolutional Neural Network (CNN) merupakan salah satu metode *Deep Learning* yang dirancang untuk memproses data berbentuk grid dua dimensi, seperti citra, melalui proses ekstraksi fitur secara otomatis menggunakan operasi konvolusi [Ilahiyah and Nilogiri \(2018\)](#). CNN mampu mempelajari representasi fitur langsung dari data citra sehingga banyak digunakan pada berba-

bagai tugas klasifikasi citra medis Kumar et al. (2020). Kemampuan tersebut menjadikan CNN sebagai salah satu metode yang efektif untuk mendeteksi pola radiografis yang berkaitan dengan keberadaan tuberkulosis pada citra CXR. Arsitektur CNN yang digunakan dalam penelitian ini ditunjukkan pada Gambar 3. Model dirancang untuk mengklasifikasikan citra CXR ke dalam dua kelas, yaitu TB dan normal. Konfigurasi setiap lapisan pada arsitektur CNN yang digunakan dalam penelitian ini disajikan pada Tabel 1. Tabel tersebut menunjukkan jenis lapisan, dimensi keluaran (output shape), serta jumlah parameter yang dipelajari pada masing-masing lapisan selama proses pelatihan.



Gambar 3: Arsitektur CNN

Tabel 1: Konfigurasi Arsitektur CNN

Layer	Output Shape	Parameter
Conv2D (32, 3 × 3)	256 × 256 × 32	896
MaxPooling2D	128 × 128 × 32	0
Conv2D (64, 3 × 3)	128 × 128 × 64	18,496
MaxPooling2D	64 × 64 × 64	0
Conv2D (128, 3 × 3)	64 × 64 × 128	73,856
MaxPooling2D	32 × 32 × 128	0
Flatten	131,072	0
Dense (128)	128	16,777,344
Dropout (0.5)	128	0
Dense (Sigmoid)	1	129
Total Parameter		16,870,721

Arsitektur CNN terdiri atas tiga *convolutional block*, yang masing-masing memuat lapisan konvolusi, fungsi aktivasi ReLU, dan *max pooling*. Lapisan konvolusi berfungsi untuk mengekstraksi fitur lokal dari citra, seperti tepi, tekstur, dan pola visual yang berkaitan dengan kelainan paru. Jumlah filter ditingkatkan secara bertahap dari 32, 64, hingga 128 agar model dapat mempelajari representasi fitur yang semakin kompleks pada setiap tingkat kedalaman jaringan. Operasi konvolusi yang digunakan pada CNN dapat dinyatakan pada Persamaan 1

$$(X * K)(i, j) = \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} X(i + m, j + n) \cdot K(m, n) \quad (1)$$

Pada Persamaan 1, X menyatakan citra masukan, K merupakan kernel konvolusi berukuran

$M \times N$, dan $(X * K)(i, j)$ merupakan nilai keluaran pada posisi tertentu setelah proses konvolusi dilakukan Goodfellow et al. (2016). Operasi ini digunakan untuk mengekstraksi berbagai pola dan karakteristik visual yang relevan terhadap keberadaan TB pada area paru. Setelah proses konvolusi, fungsi aktivasi *Rectified Linear Unit* (ReLU) diterapkan untuk memperkenalkan sifat nonlinier pada jaringan. Fungsi ReLU dapat dinyatakan pada Persamaan 2.

$$f(x) = \max(0, x) \quad (2)$$

Penggunaan ReLU membantu mengurangi permasalahan *vanishing gradient* dan meningkatkan efisiensi proses pelatihan model Nair and Hinton (2010). Selanjutnya, lapisan *max pooling* digunakan untuk mengurangi dimensi spasial *feature map* dengan mempertahankan informasi yang paling dominan. Proses ini membantu mengurangi kompleksitas komputasi sekaligus meningkatkan kemampuan generalisasi model Goodfellow et al. (2016).

Hasil ekstraksi fitur dari lapisan konvolusi kemudian diubah menjadi vektor satu dimensi melalui lapisan *flatten*. Vektor tersebut diteruskan ke *fully connected layer* untuk melakukan proses klasifikasi berdasarkan fitur-fitur yang telah dipelajari sebelumnya Kumar et al. (2020). Selain itu, lapisan *dropout* dengan nilai 0,5 diterapkan untuk mengurangi risiko *overfitting* selama proses pelatihan model dengan cara menonaktifkan sebagian neuron secara acak pada setiap iterasi Srivastava et al. (2014). Pada lapisan keluaran digunakan satu neuron dengan fungsi aktivasi sigmoid untuk menghasilkan probabilitas kelas TB atau normal. Fungsi sigmoid dapat dinyatakan pada Persamaan 3.

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (3)$$

Fungsi sigmoid menghasilkan nilai keluaran pada rentang 0 hingga 1 sehingga sesuai digunakan pada permasalahan klasifikasi biner. Nilai probabilitas yang dihasilkan kemudian digunakan untuk menentukan kelas akhir citra CXR. Proses pelatihan model dilakukan menggunakan *Adam Optimizer* karena mampu menyesuaikan laju pembelajaran secara adaptif dan menunjukkan performa yang baik pada berbagai permasalahan *deep learning* Kingma and Ba (2015). Fungsi kerugian yang digunakan adalah *binary cross-entropy* karena penelitian ini merupakan permasalahan klasifikasi biner. Persamaan *binary cross-entropy* dapat dinyatakan sebagai berikut.

$$L = -\frac{1}{N} \sum_{i=1}^N [y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)] \quad (4)$$

dengan y_i menyatakan label sebenarnya dan $\hat{y}_i$ merupakan probabilitas hasil prediksi model Goodfellow et al. (2016). Berdasarkan arsitektur dan konfigurasi yang telah dirancang, CNN digunakan untuk mempelajari karakteristik radiografis yang membedakan citra CXR TB dan normal secara otomatis melalui proses ekstraksi fitur bertingkat. Model mampu menghasilkan performa klasifikasi yang baik tanpa memerlukan proses ekstraksi fitur secara manual. Pendekatan ini mampu menghasilkan sistem deteksi TB yang sederhana, efisien, dan tetap memiliki performa yang baik dalam membedakan citra TB dan normal.

2.5 Metrik Evaluasi

Kinerja model CNN pada penelitian ini dievaluasi menggunakan beberapa metrik klasifikasi, yaitu *accuracy*, *precision*, *recall*, dan *F1-score*. Metrik-metrik tersebut digunakan untuk mengukur kemampuan model dalam mengklasifikasikan citra CXR ke dalam kelas TB dan normal secara

akurat. Selain itu, *confusion matrix* digunakan untuk menganalisis distribusi hasil prediksi model terhadap masing-masing kelas sehingga dapat diketahui jumlah prediksi yang benar maupun salah pada setiap kategori Sokolova and Lapalme (2009).

Accuracy digunakan untuk mengukur proporsi prediksi yang berhasil diklasifikasikan dengan benar terhadap seluruh data pengujian. Nilai *accuracy* dihitung menggunakan Persamaan 5, sedangkan nilai *precision*, *recall*, dan *F1-score* masing-masing dihitung menggunakan Persamaan 6, Persamaan 7, dan Persamaan 8. Pada Persamaan 5–8, *TP* (*True Positive*) menyatakan jumlah citra TB yang berhasil diprediksi dengan benar sebagai TB, *TN* (*True Negative*) menyatakan jumlah citra normal yang berhasil diprediksi dengan benar sebagai normal, *FP* (*False Positive*) menyatakan jumlah citra normal yang salah diprediksi sebagai TB, sedangkan *FN* (*False Negative*) menyatakan jumlah citra TB yang salah diprediksi sebagai normal. Metrik-metrik tersebut digunakan untuk memberikan evaluasi yang komprehensif terhadap kemampuan model CNN dalam mendeteksi tuberkulosis berdasarkan citra CXR.

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (5)$$

$$\text{Precision} = \frac{TP}{TP + FP} \quad (6)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (7)$$

$$\text{F1-score} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (8)$$

3 Hasil dan Pembahasan

3.1 Kinerja Model Klasifikasi Tuberkulosis


Pada penelitian ini, model CNN yang diusulkan dibandingkan dengan beberapa arsitektur klasifikasi lainnya untuk mengevaluasi kinerjanya dalam mendeteksi tuberkulosis berdasarkan citra CXR. Evaluasi dilakukan menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score*. Hasil perbandingan kinerja masing-masing model ditunjukkan pada Tabel 2. Berdasarkan hasil pengujian, model CNN menghasilkan performa yang kompetitif dibandingkan model lainnya dengan nilai *accuracy*, *precision*, *recall*, dan *F1-score* yang tinggi. Oleh karena itu, CNN dipilih sebagai model klasifikasi pada tahap ini untuk mengevaluasi pengaruh segmentasi paru terhadap kinerja deteksi TB.

Tabel 2: Hasil Eksperimen Model Klasifikasi TB

Model	Precision	Recall	F1-Score	Accuracy
MobileNetV2	0.92	0.96	0.93	0.94
EfficientNetB0	0.94	0.97	0.96	0.96
InceptionV3	0.96	0.97	0.97	0.97
CNN	1.00	1.00	1.00	1.00


Performa yang diperoleh menunjukkan bahwa arsitektur CNN yang dirancang telah mampu mengekstraksi fitur-fitur penting dari citra CXR, mulai dari pola tekstur, distribusi intensitas,

hingga karakteristik visual yang berkaitan dengan penyakit TB pada paru. Penggunaan beberapa *convolutional block*, *max pooling*, dan *dropout* mendukung proses ekstraksi fitur serta membantu mengurangi risiko *overfitting* selama pelatihan. Kombinasi kualitas data, konfigurasi arsitektur CNN, serta proses pelatihan yang sesuai menghasilkan performa klasifikasi yang sangat baik pada dataset pengujian. Untuk memperoleh gambaran yang lebih rinci mengenai hasil klasifikasi, dilakukan analisis menggunakan *confusion matrix*. Hasil *confusion matrix* model CNN ditunjukkan pada Gambar 4. Berdasarkan Gambar 4, seluruh citra pada data pengujian berhasil diklasifikasikan dengan benar ke dalam kelas TB dan normal. Tidak ditemukan nilai *false positive* maupun *false negative*, yang menunjukkan bahwa model mampu membedakan kedua kelas secara konsisten pada dataset pengujian.




Gambar 4: Confusion Matrix CNN

Sebagai evaluasi tambahan, model diuji menggunakan beberapa citra CXR baru yang tidak termasuk dalam dataset pelatihan maupun pengujian. Gambar 5 memperlihatkan contoh hasil klasifikasi yang benar dan salah. Meskipun model mencapai performa yang sangat baik pada dataset pengujian, masih ditemukan beberapa kasus salah klasifikasi pada data baru. Hal ini mengindikasikan bahwa model belum sepenuhnya mampu melakukan generalisasi terhadap seluruh variasi karakteristik citra yang dijumpai di luar data yang digunakan selama proses pengembangan model. Perbedaan kualitas citra, distribusi intensitas, tingkat kontras, maupun variasi pola radiografis antar dataset dapat menyebabkan distribusi data baru berbeda dengan data pelatihan, sehingga memengaruhi kemampuan model dalam mengenali karakteristik TB secara konsisten. Meskipun demikian, sebagian besar citra baru tetap berhasil diklasifikasikan dengan benar. Hasil ini menunjukkan bahwa model memiliki kemampuan generalisasi yang baik serta tetap konsisten dengan performa yang diperoleh pada dataset pengujian.



Gambar 5: Hasil inferensi model pada data CXR baru dengan *ground truth* TB: (a) klasifikasi benar dan (b) salah klasifikasi.

Proses pelatihan model CNN diamati melalui kurva *training* dan *validation* sebagaimana ditunjukkan pada Gambar 6. Berdasarkan Gambar 6, nilai *training accuracy* dan *validation accuracy* meningkat secara konsisten selama proses pelatihan hingga mencapai kondisi konvergen. Selain itu, tidak terlihat perbedaan yang signifikan antara kurva pelatihan dan validasi, yang menunjukkan bahwa model mampu mempelajari pola pada data dengan baik tanpa mengalami *overfitting*. Hasil tersebut menunjukkan bahwa model memiliki kemampuan generalisasi yang baik dalam membedakan citra TB dan normal.



Gambar 6: Kurva pembelajaran model CNN

Secara keseluruhan, hasil eksperimen menunjukkan bahwa model CNN mampu mengklasifikasi citra CXR ke dalam kelas TB dan normal dengan performa yang sangat baik. Nilai *accuracy*, *precision*, *recall*, dan *F1-score* yang diperoleh menunjukkan bahwa model mampu mempelajari karakteristik radiografis yang berkaitan dengan tuberkulosis secara efektif. Hasil ini mengindikasikan bahwa CNN memiliki potensi untuk digunakan sebagai metode deteksi TB berbasis citra CXR yang sederhana, efisien, dan akurat.

3.2 Perbandingan dengan Penelitian Sebelumnya

Untuk mengevaluasi efektivitas metode yang diusulkan, dilakukan perbandingan dengan beberapa penelitian terdahulu yang menggunakan citra CXR untuk deteksi TB. Perbandingan dilakukan berdasarkan dataset yang digunakan, pendekatan yang diterapkan, serta nilai akurasi yang diperoleh sebagaimana ditunjukkan pada Tabel 3.

Tabel 3: Perbandingan dengan Penelitian Sebelumnya

Peneliti	Dataset	Metode	Accuracy
Abideen et al. (2020)	Montgomery	Bayesian CNN	96.42%
Msonda et al. (2020)	Montgomery	ResNet50 + SPP	98.00%
Msonda et al. (2020)	Shenzhen	GoogleNet + SPP	100.00%
Rahman et al. (2020b)	Shenzhen, Montgomery, NIAID TB	DenseNet201	98.60%
Ayaz et al. (2021)	Montgomery + Shenzhen	Ensemble Learning	97.00%
Hwa et al. (2019)	Montgomery + Shenzhen	Ensemble CNN	97.60%
Abdullah et al. (2023)	Montgomery + Shenzhen	TB-DenseNet	99.33%
Hossain et al. (2024)	Montgomery, Shenzhen, Dataset Tambahan	Hybrid CNN (VGG16 + ResNet50 + DenseNet121)	97.40%
Penelitian ini	Montgomery + Shenzhen	CNN	100.00%

Hasil perbandingan menunjukkan bahwa model CNN yang diusulkan mampu menghasilkan performa yang kompetitif dibandingkan berbagai penelitian terdahulu pada dataset CXR tuberkulosis. Beberapa penelitian sebelumnya menggunakan pendekatan yang lebih kompleks, seperti ensemble learning, Bayesian CNN, hybrid CNN, maupun kombinasi beberapa arsitektur deep learning untuk meningkatkan performa klasifikasi. Namun demikian, model CNN yang digunakan dalam penelitian ini mampu mencapai akurasi sebesar 1.00 pada dataset Montgomery dan Shenzhen. Hasil tersebut menunjukkan bahwa arsitektur CNN yang relatif sederhana tetap mampu mempelajari karakteristik radiografis yang berkaitan dengan tuberkulosis secara efektif. Selain dipengaruhi oleh desain arsitektur model, performa yang diperoleh juga didukung oleh proses preprocessing, konfigurasi pelatihan, serta kualitas dataset yang digunakan. Dengan kompleksitas yang lebih rendah dibandingkan beberapa metode pembanding, pendekatan yang diusulkan berpotensi memberikan efisiensi komputasi yang lebih baik tanpa mengurangi kemampuan deteksi TB pada citra CXR.

4 Kesimpulan

Penelitian ini berhasil mengembangkan model deteksi tuberkulosis berbasis *citra Chest X-Ray* (CXR) menggunakan *Convolutional Neural Network* (CNN). Berdasarkan hasil eksperimen, CNN menunjukkan performa terbaik dibandingkan MobileNetV2, EfficientNetB0, dan InceptionV3 dengan memperoleh nilai *accuracy* sebesar 1.00. Hasil tersebut membuktikan bahwa CNN mampu mengekstraksi dan mempelajari fitur radiografis yang berkaitan dengan tuberkulosis secara efektif. Oleh karena itu, model yang diusulkan berpotensi untuk diimplementasikan sebagai sistem pendukung diagnosis tuberkulosis yang objektif, cepat, dan konsisten dalam membantu proses skrining berbasis citra CXR. Temuan ini menunjukkan bahwa pendekatan berbasis *deep learning*, khususnya CNN, memiliki kemampuan yang sangat baik dalam mengidentifikasi karakteristik tuberkulosis pada citra radiografi dada, sehingga berpotensi meningkatkan efisiensi dan konsistensi diagnosis serta efektif dalam mendukung deteksi tuberkulosis secara otomatis.

Ucapan Terima Kasih

Penulis mengucapkan terima kasih kepada Program Studi S1 Sains Data Universitas Negeri Surabaya serta seluruh pihak yang telah memberikan dukungan dan masukan selama pelaksanaan penelitian ini.

References

- Abdullah, A., Alqudah, M. A., Al-Badarneh, A., and Al-Hroob, A. (2023). Tuberculosis chest x-ray detection using cnn-based hybrid segmentation and classification approach. *Biomedical Signal Processing and Control*, 84:104667.
- Abideen, Z. U., Ghafoor, M., Munir, K., Saqib, M., Ullah, A., Zia, T., Tariq, S. A., Ahmed, G., and Zahra, A. (2020). Uncertainty assisted robust tuberculosis identification with bayesian convolutional neural networks. *IEEE Access*, 8:22812–22825.
- Ardila, D., Kiraly, A. P., Bharadwaj, S., et al. (2019). End-to-end lung cancer screening with three-dimensional deep learning on low-dose chest computed tomography. *Nature Medicine*, 25(6):954–961.
- Ayaz, M., Shaukat, M., Khan, M. A., et al. (2021). Tuberculosis detection using ensemble learning methods in chest x-ray images. *Computers, Materials and Continua*.
- Feyisa, B. B. et al. (2023). Weak localization of radiographic manifestations in pulmonary tuberculosis from chest x-ray: A systematic review. *Sensors*, 23(15):6781.
- Ghanem, M., Srivastava, R., Ektefaie, Y., et al. (2024). Tuberculosis disease severity assessment using clinical variables and radiology enabled by artificial intelligence. *medRxiv*.
- Goodfellow, I., Bengio, Y., and Courville, A. (2016). *Deep Learning*. MIT Press.
- Harris, C. R. et al. (2021). Pathml: A unified framework for whole-slide image analysis with deep learning. *medRxiv*.
- Hossain, M., Khan, M. A., Hamza, A., Alzahrani, A. I., Alalwan, N., Shabaz, M., and Khan, F. (2024). A deep learning-based x-ray imaging diagnosis system for classification of tuberculosis, covid-19, and pneumonia traits using evolutionary algorithm. *AI and Learning Systems*.
- Hwa, S. K. T., Hijazi, M. H. A., Bade, A., Yaakob, R., and Jeffree, M. S. (2019). Ensemble deep learning for tuberculosis detection using chest x-ray and canny edge detected images. *IAES International Journal of Artificial Intelligence (IJ-AI)*, 8(4):429–435.

- Ilahiyah, S. and Nilogiri, A. (2018). Implementasi convolutional neural network untuk klasifikasi citra digital. *Jurnal Teknologi Informasi dan Ilmu Komputer*, 5(3):321–328.
- Jaeger, S., Candemir, S., Antani, S., Wang, Y.-X. J., Lu, P.-X., and Thoma, G. (2014). Two public chest x-ray datasets for computer-aided screening of pulmonary diseases. *Quantitative Imaging in Medicine and Surgery*, 4(6):475–477.
- Kantipudi, K., Gu, J., Bui, V., Yu, H., Jaeger, S., and Yaniv, Z. (2024). Automated pulmonary tuberculosis severity assessment on chest x-rays. *Journal of Imaging Informatics in Medicine*, 37(5):2173–2185.
- Kermany, D. S., Goldbaum, M., Cai, W., et al. (2018). Identifying medical diagnoses and treatable diseases by image-based deep learning. *Cell*, 172(5):1122–1131.
- Kingma, D. P. and Ba, J. (2015). Adam: A method for stochastic optimization. *International Conference on Learning Representations (ICLR)*.
- Kumar, A., Singh, A., and Saxena, A. (2020). An overview of medical images classification based on cnn. *Inpressco International Journal*, 10(1):1–8.
- LeCun, Y., Bottou, L., Orr, G. B., and Müller, K.-R. (2012). Efficient backprop. In *Neural Networks: Tricks of the Trade*, pages 9–48. Springer.
- Msonda, P., Uymaz, S. A., and Karaağaç, S. S. (2020). Spatial pyramid pooling in deep convolutional networks for automatic tuberculosis diagnosis. *Traitement du Signal*, 37(6):1075–1084.
- Nair, V. and Hinton, G. E. (2010). Rectified linear units improve restricted boltzmann machines. In *Proceedings of the 27th International Conference on Machine Learning*.
- Rahman, T., Chowdhury, M. E. H., Khandakar, A., Islam, K. R., et al. (2020a). Reliable tuberculosis detection using chest x-ray with deep learning, segmentation and visualization. *IEEE Access*, 8:191586–191601.
- Rahman, T., Khandakar, A., Kadir, M. A., et al. (2020b). Reliable tuberculosis detection using chest x-ray with deep learning, segmentation and visualization. *IEEE Access*, 8:191586–191601.
- Shorten, C. and Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of Big Data*, 6(1):60.
- Sokolova, M. and Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information Processing and Management*, 45(4):427–437.
- Srivastava, N., Hinton, G. E., Krizhevsky, A., Sutskever, I., and Salakhutdinov, R. (2014). Dropout: A simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*, 15(56):1929–1958.
- Wang, L., Lin, Z. Q., and Wong, A. (2020). Covid-net: A tailored deep convolutional neural network design for detection of covid-19 cases from chest x-ray images. *Scientific Reports*, 10(1):19549.
- Wen, D. et al. (2022). Inflation of test accuracy due to data leakage in deep learning-based classification of oct images. *Scientific Data*, 9(1).
- World Health Organization (2023). *Global Tuberculosis Report 2023*. World Health Organization, Geneva, Switzerland.