Jurnal Ilmu Kesehatan (JIKSAN)

Volume 2 No. 1 (2026) 79-87

ISSN: 3109-1911

Studi Awal Deteksi Otomatis TBC Menggunakan Deep Learning Convolutional Neural Networks di RSP Ario Wirawan Salatiga Untuk Mendukung Program Zero TB

Preliminary Study on Automated TB Detection Using Deep Learning Convolutional Neural Networks at RSP Ario Wirawan Salatiga in Support of the Zero TB Initiative

Susilo[1], Lilik Lestari[2], Rudi Setiawan[3]*
[1]Universitas Dian Nuswantoro, Semarang
[2]Rumah Sakit Paru dr. Ario Wirawan, Salatiga
[3]Universitas An Nasher, Cirebon

Email:
[3]rudi_setiawan@universitasannasher.ac.id

Article History:
Received: March 4, 2026
Revised: June 10, 2026
Accepted: June 24, 2026

Keyword: *CNN, Deep Learning, Tuberculosis, X-Ray, Zero TB*

Abstract

Background*: Tuberculosis (TB) remains a major global public health problem and requires rapid, accurate, and reliable screening to support the Zero TB initiative. In clinical practice, chest X-ray interpretation is still highly dependent on radiologists, which can be time-consuming and prone to subjectivity, especially under heavy workloads. Therefore, an automated detection system based on deep learning is needed to assist early TB screening.* ***Purpose****: This study aimed to develop and evaluate a Convolutional Neural Network (CNN)-based model for the automatic detection of tuberculosis from chest X-ray images at Ario Wirawan Pulmonary Hospital, Salatiga, in order to support the implementation of the Zero TB program.* ***Method****: This research employed a quantitative experimental approach. The dataset consisted of 175 training images, including 100 normal and 75 TB chest X-rays, and 170 testing images, including 100 normal and 70 TB images. Image preprocessing included resizing and pixel normalization before model training. The CNN model was optimized by testing variations in the number of epochs (5, 10, 20, and 40) and learning rates (1, 0.1, 0.01, and 0.001). Model performance was evaluated using accuracy, sensitivity, and specificity derived from the confusion matrix.* ***Result****: The findings showed that the CNN model achieved optimal performance at 20 epochs with a learning rate of 0.001. Under this configuration, the model reached 100.00% training accuracy and 98.82% testing accuracy. For the normal class, the model achieved a sensitivity of 1.0000 and a specificity of 0.9714, while for the TB class, it obtained a sensitivity of 0.9714 and a specificity of 1.0000. These results indicate that the proposed CNN model is highly effective and reliable as an early TB detection tool, with strong potential to assist radiologists in improving diagnostic efficiency and supporting the Zero TB initiative.*

Abstrak

Latar Belakang: Tuberkulosis (TB) masih menjadi masalah kesehatan masyarakat global yang utama dan memerlukan skrining yang cepat, akurat, serta andal untuk mendukung inisiatif Zero TB. Dalam praktik klinis, interpretasi foto rontgen dada masih sangat bergantung pada radiolog, yang dapat memakan waktu dan rentan terhadap subjektivitas, terutama di bawah beban kerja yang tinggi. Oleh karena itu, diperlukan sistem deteksi otomatis berbasis deep learning untuk membantu skrining dini TB. **Tujuan:** Penelitian ini bertujuan untuk mengembangkan dan mengevaluasi model berbasis Convolutional Neural Network (CNN) untuk deteksi otomatis tuberkulosis dari citra foto rontgen dada di Rumah Sakit Paru Ario Wirawan, Salatiga, guna mendukung implementasi program Zero TB. **Metode:** Penelitian ini menggunakan pendekatan eksperimen kuantitatif. Dataset terdiri dari 175 citra pelatihan, yang mencakup 100 foto rontgen dada normal dan 75 TB, serta 170 citra pengujian, yang mencakup 100 citra normal dan 70 citra TB. Prapemrosesan citra meliputi pengubahan ukuran (resizing) dan normalisasi piksel sebelum pelatihan model. Model CNN dioptimalkan dengan menguji variasi jumlah epoch (5, 10, 20, dan 40) serta learning rate (1, 0,1, 0,01, dan 0,001). Kinerja model dievaluasi menggunakan akurasi, sensitivitas, dan spesifisitas yang diperoleh dari confusion matrix. **Hasil:** Temuan menunjukkan bahwa model CNN mencapai kinerja optimal pada 20 epoch dengan learning rate 0,001. Pada konfigurasi ini, model mencapai akurasi pelatihan sebesar 100,00% dan akurasi pengujian sebesar 98,82%. Untuk kelas normal, model mencapai sensitivitas sebesar 1,0000 dan spesifisitas sebesar 0,9714, sedangkan untuk kelas TB diperoleh sensitivitas sebesar 0,9714 dan spesifisitas sebesar 1,0000. Hasil ini menunjukkan bahwa model CNN yang diusulkan sangat efektif dan andal sebagai alat deteksi dini TB, dengan potensi yang kuat untuk membantu radiolog dalam meningkatkan efisiensi diagnosis serta mendukung inisiatif Zero TB.

PENDAHULUAN

Tuberkulosis (TBC) merupakan salah satu penyakit menular paling mematikan di dunia yang masih menjadi fokus utama kesehatan masyarakat global(Bengio, 2024; Pesapane et al., 2024). Dalam rangka menanggulangi penyebaran penyakit ini, program *Zero TB* telah dicanangkan untuk menurunkan angka insidensi secara drastis melalui deteksi dini dan pengobatan yang komprehensif(Adrianison S Simbolon, 2024; Global Initiative for Chronic Obstructive Lung Disease, 2024). Penanganan penyakit ini seringkali terkendala oleh kurangnya fasilitas diagnostik yang memadai serta rasio tenaga kesehatan yang tidak sebanding dengan beban kasus di masyarakat. Hal ini mengakibatkan banyak pasien tidak teridentifikasi pada fase awal dan menjadi sumber penularan aktif(Anggoro S Amin, 2023, 2023; Apriningsih, 2024). Oleh karena itu, diperlukan sebuah mekanisme deteksi dini yang cepat, objektif, dan dapat diandalkan untuk menekan tingkat keparahan TBC di masyarakat, termasuk dukungan infrastruktur deteksi di rumah sakit rujukan seperti Rumah Sakit Paru dr. Ario Wirawan (RSPAW) Salatiga(Anggoro S Amin, 2023; Daryati et al., 2022).

Pemeriksaan standar untuk mendiagnosis TBC secara klinis sangat bergantung pada interpretasi visual dari citra rontgen dada (CXR) oleh dokter spesialis radiologi. Namun, proses pembacaan citra medis ini memakan waktu yang tidak sedikit dan rentan terhadap subjektivitas klinis, terutama saat beban kerja sangat tinggi(Pham et al., 2022). Di sisi lain, manifestasi awal TBC pada citra rontgen terkadang samar dan tumpang tindih dengan kelainan paru lainnya(Ozturk et al., 2020). Ketimpangan rasio antara jumlah dokter spesialis dan beban citra harian menciptakan *bottleneck* dalam alur layanan. Hal ini memunculkan urgensi untuk mengintegrasikan teknologi kecerdasan buatan, khususnya *Deep Learning*, guna membantu proses triase dan pembacaan awal radiografi secara komputasional(Fairuzabadi et al., 2025; Karnyoto et al., 2025; Mardiawati et al., 2025). Penerapan *deep learning* untuk analisis citra medis telah menunjukkan kemajuan yang pesat dan menawarkan solusi diagnostik yang lebih cepat dan konsisten(Mire et al., 2022; Zhou, 2023).

Dalam beberapa tahun terakhir, algoritma *Convolutional Neural Network* (CNN) telah terbukti sangat efektif dalam berbagai studi segmentasi dan deteksi anomali pada citra medis(Ali S Abdalrad, 2025; Iqbal et al., 2024; Rochmawati S Maryani, 2025; Sancı S Öke Günel, 2024). Implementasi kecerdasan buatan, khususnya melalui teknik *deep learning* dengan *Convolutional Neural Networks* (CNN), telah menjadi paradigma baru dalam mempercepat proses skrining tuberkulosis (TBC) secara masif dan efisien. Penelitian terkini menunjukkan bahwa pemilihan arsitektur CNN yang tepat mampu meningkatkan akurasi deteksi pada citra rontgen dada secara signifikan(Alsenani, 2024), sementara pendekatan *transfer learning* terbukti menjadi solusi efektif untuk mengatasi keterbatasan ketersediaan data pada lingkungan klinis. Mengingat urgensi program "Zero TB" di Indonesia, adopsi teknologi ini pada fasilitas layanan kesehatan spesifik seperti RSP Ario Wirawan Salatiga menjadi langkah krusial untuk mentransformasi temuan riset berbasis model menjadi instrumen pendukung keputusan klinis yang aplikatif dan berdampak nyata di lapangan. Implementasi kecerdasan buatan, khususnya melalui teknik *deep learning* dengan *Convolutional Neural Networks* (CNN), telah menjadi paradigma baru dalam mempercepat proses skrining tuberkulosis (TBC) secara masif dan efisien. Penelitian (Pradhan et al., 2025) (Alsenani, 2024) menunjukkan bahwa pemilihan arsitektur CNN yang tepat mampu meningkatkan akurasi deteksi pada citra rontgen dada secara signifikan, sementara pendekatan *transfer learning* terbukti menjadi solusi efektif untuk mengatasi keterbatasan ketersediaan data pada lingkungan klinis. Meskipun penelitian terdahulu telah berhasil menerapkan berbagai arsitektur kecerdasan buatan untuk diagnosis patologi paru(Hasenstab, 2024, 2025), studi spesifik yang mengeksplorasi optimasi model berbasis rontgen dada dengan menyesuaikan dinamika data TBC pada rumah sakit lokal di Indonesia masih sangat terbatas(Do et al., 2026; Dwijayanti et al., 2025; Risma S Utami, 2025; Shahira et al., 2025). Terdapat *gap analysis* di mana model kecerdasan buatan perlu disesuaikan parameter pembelajarannya agar mampu mengekstraksi fitur patologis TBC secara akurat menggunakan citra rontgen standar yang lebih aksesibel dan menekan angka *false* negative(Al Wachami et al., 2024; Krishnaveni et al., 2024; Yang et al., 2025).

Menjawab kesenjangan tersebut, penelitian ini menawarkan kebaruan (*novelty*) melalui skenario pengujian komprehensif terhadap parameter *learning rate* dan *epoch* pada algoritma *Deep Learning* untuk deteksi spesifik TBC. Optimalisasi komputasi ini tidak hanya berfokus pada pencapaian akurasi tertinggi, tetapi juga mengevaluasi metrik sensitivitas dan spesifisitas untuk memastikan sistem handal dalam mendeteksi infeksi tanpa menghasilkan alarm palsu yang berlebihan. Tujuan utama dari penelitian ini adalah merancang, melatih, dan mengevaluasi kinerja arsitektur CNN dalam mendeteksi TBC secara otomatis. Diharapkan, studi awal ini dapat menjadi fondasi bagi pengembangan peranti lunak penunjang diagnostik yang mendukung program *Zero TB* di RSPAW Salatiga(Setyawan, 2025).

METODE PENELITIAN

Penelitian ini menggunakan jenis penelitian kuantitatif dengan pendekatan eksperimental komputasional. Fokus utama penelitian adalah merancang dan mengevaluasi arsitektur jaringan saraf tiruan berjenis *Convolutional Neural Network* (CNN) untuk klasifikasi biner citra paru-paru. Populasi dalam penelitian ini adalah kumpulan citra rontgen dada digital. Teknik *purposive sampling* digunakan untuk menyaring citra, menghasilkan dataset yang terdiri dari dua kelas: Normal dan TB data radiograf ditunjukkan pada Gambar 1. Total sampel data latih (*training data*) berjumlah 175 citra, dengan rincian 100 citra Normal dan 75 citra TB. Sementara itu, untuk keperluan validasi, disiapkan 170 citra sebagai data uji (*testing data*) yang memuat 100 citra Normal dan 70 citra TB.

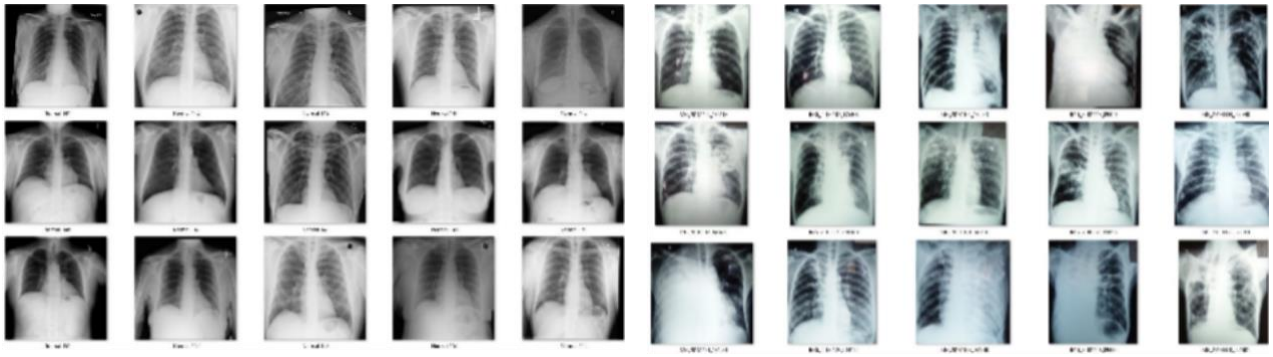

Radiograf Normal Radiograf TB

Gambar 1. Data Radiograf Normal S TB

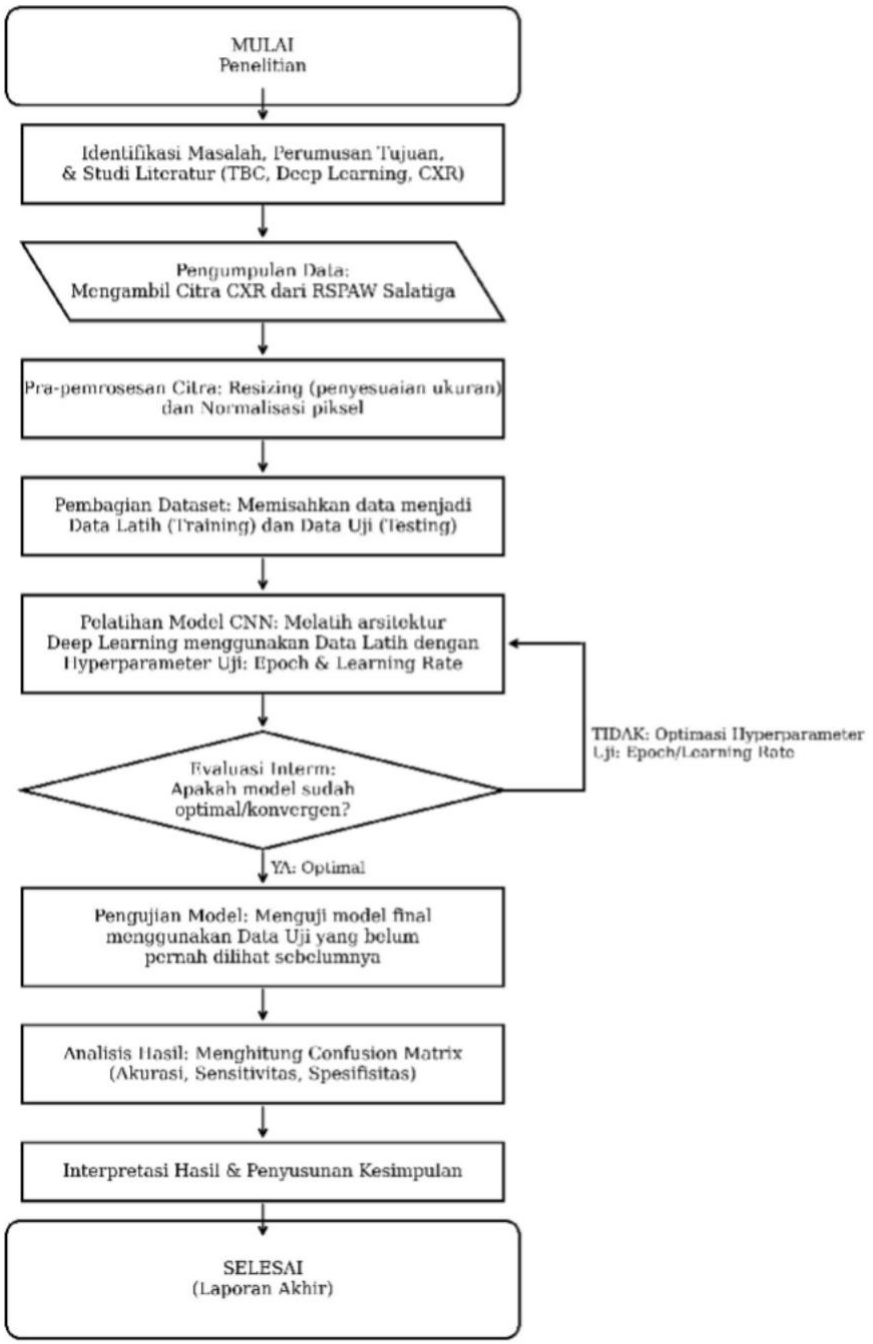

Gambar 2. Flowchart Tahapan Metode Penelitian

Alur metodologi penelitian ini disusun secara sistematis seperti yang ditunjukkan pada diagram alir di Gambar 2. Tahapan diawali dengan inisiasi penelitian yang mencakup identifikasi masalah, perumusan tujuan, serta studi literatur mendalam mengenai penyakit TBC, teknologi *deep learning*, dan karakteristik citra Chest X-Ray (CXR). Selanjutnya, dilakukan pengumpulan data berupa pengambilan citra CXR asli dari RSPAW Salatiga. Citra mentah yang diperoleh kemudian masuk ke tahap pra-pemrosesan yang meliputi penyesuaian ukuran (*resizing*) dimensi gambar dan normalisasi nilai piksel guna menyeragamkan format input model. Sebelum memasuki tahap pemodelan, dataset dipisahkan secara independen menjadi Data Latih (*Training Data*) dan Data Uji (*Testing Data*).

Tahap inti penelitian berfokus pada pelatihan model *Convolutional Neural Network* (CNN) menggunakan Data Latih. Proses komputasi dan evaluasi interim model dilakukan secara iteratif dengan memanipulasi dua *hyperparameter fundamental*: jumlah *epoch* (5, 10, 20, 40) pada tingkat pembelajaran konstan, serta variasi *learning rate* (1; 0,1; 0,01; 0,001) pada *epoch* yang terbukti optimal. Apabila model belum mencapai kondisi

konvergen atau optimal, sistem akan melakukan pengulangan untuk mengoptimasi *hyperparameter* tersebut. Sebaliknya, jika model dinyatakan telah optimal, alur berlanjut ke tahap pengujian model (*testing*) menggunakan data uji yang belum pernah dilihat oleh sistem sebelumnya. Terakhir, kinerja akhir model dianalisis secara kuantitatif menggunakan matriks konfusi (*confusion matrix*) untuk mendapatkan nilai Akurasi, Sensitivitas (*Sensitivity*), dan Spesifisitas (*Specificity*), sebelum akhirnya dilakukan interpretasi hasil, penyusunan kesimpulan, dan finalisasi Laporan Akhir.

HASIL

Bagian ini menyajikan karakteristik performa hasil pelatihan dan pengujian dari arsitektur CNN yang dirancang untuk klasifikasi penyakit tuberkulosis. Analisis kinerja model dikelompokkan ke dalam dua skenario pengujian utama: evaluasi pengaruh variasi jumlah siklus pelatihan (*epoch*) dan analisis sensitivitas laju pembelajaran (*learning rate*). Kinerja model direkam berdasarkan nilai akurasi pada data latih maupun data uji, serta dievaluasi metrik diagnostiknya pada masing-masing kelas target.

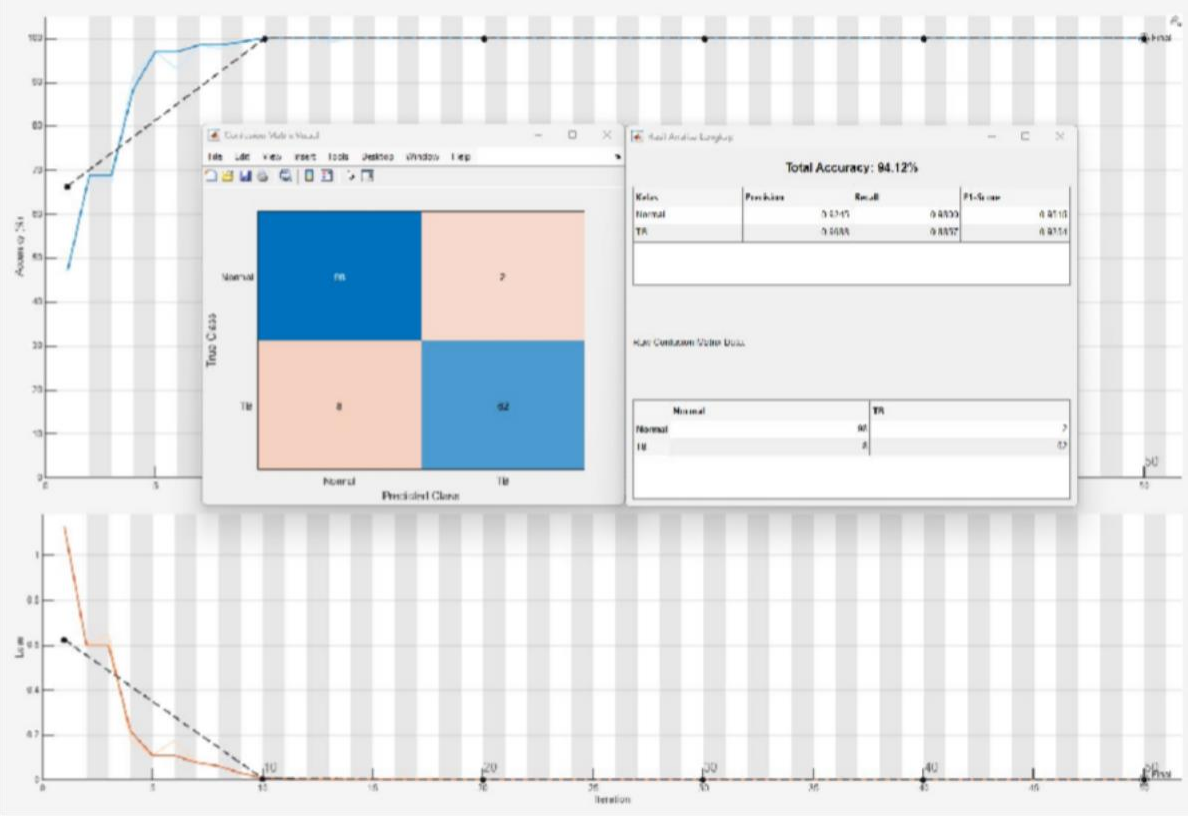

Gambar 3. Tampilan proses training dan testing

Pengaruh Variasi Epoch

Tahap pertama pengujian berfokus pada observasi tren konvergensi algoritma seiring dengan bertambahnya jumlah *epoch*. Pada skenario ini, *learning rate* ditetapkan konstan pada angka 0,001. Hasil analisis menunjukkan eskalasi kemampuan pengenalan pola ketika siklus pembelajaran dinaikkan dari 5 ke 20 epoch. Pada epoch 20 dan 40, akurasi pelatihan mencapai 100%, dengan akurasi pengujian tertinggi stabil pada 98,82%. Stabilitas hasil uji ini mengindikasikan bahwa model telah menemukan titik konvergensi optimal pada rentang waktu tersebut.

Tabel 1. Kinerja Model Berdasarkan Variasi Epoch (L Rate = 0,001)

Epoch	Akurasi Pelatihan (%)	Akurasi Pengujian (%)	Kelas Target	Sensitivitas	Spesifisitas
5	93,14	90,00	Normal	0,88	0,93
			TB	0,93	0,88
10	99,43	92,94	Normal	0,96	0,88

Epoch	Akurasi Pelatihan (%)	Akurasi Pengujian (%)	Kelas Target	Sensitivitas	Spesifisitas
			TB	0,88	0,96
20	100,00	98,82	Normal	1	0,97
			TB	0,97	1
40	100,00	98,82	Normal	1	0,97
			TB	0,97	1

Pengaruh Variasi Learning Rate

Setelah mengidentifikasi bahwa epoch ke-20 merupakan titik stabil, analisis bivariat dilakukan dengan memodifikasi laju pembelajaran. Pada *learning rate* bernilai 1, sistem kesulitan dalam menemukan pola minimal sehingga akurasi uji hanya mencapai 41,18%. Titik puncak optimasi dicapai pada laju pembelajaran 0,001, yang memberikan akurasi uji tertinggi sebesar 98,82%. Hal ini berbeda dengan sistem yang menuntut laju lebih besar, menandakan bahwa penyesuaian bobot gradien pada deteksi TBC lebih efektif dilakukan secara bertahap (skala kecil).

Tabel 2. Kinerja Model Berdasarkan Variasi Learning Rate (Epoch = 20)

Learning Rate	Akurasi Pelatihan (%)	Akurasi Pengujian (%)	Kelas Target	Sensitivitas	Spesifisitas
1	42,86	41,18	Normal	0	1
			TB	1	0
0,1	92,00	84,71	Normal	0,79	0,93
			TB	0,93	0,79
0,01	100,00	95,29	Normal	0,96	0,94
			TB	0,94	0,96
0,001	100,00	98,82	Normal	1	0,97
			TB	0,97	1

PEMBAHASAN

Pengembangan sistem deteksi otomatis berbasis *Deep Learning* dengan arsitektur *Convolutional Neural Network* (CNN) dalam studi ini terbukti menunjukkan performa yang sangat tangguh untuk klasifikasi biner citra rontgen dada (*Chest X-Ray*/CXR) pasien tuberkulosis. Keberhasilan model dalam mengenali hierarki fitur visual patologis paru-paru sangat dipengaruhi oleh pengaturan parameter komputasi selama proses pelatihan. Evaluasi performa model dilakukan melalui dua skenario utama, yaitu pengujian variasi jumlah siklus pelatihan (*epoch*) dan sensitivitas laju pembelajaran (*learning rate*).

1. Dinamika Konvergensi Model Berdasarkan Variasi Epoch

Berdasarkan data eksperimen, jumlah *epoch* memegang peranan krusial terhadap kemampuan adaptasi bobot jaringan saraf dalam mengenali karakteristik visual paru-paru normal dan terinfeksi TBC. Ketika jaringan dilatih dalam durasi yang terlalu singkat, seperti pada konfigurasi 5 *epoch*, model mengalami kondisi *underfitting* dengan akurasi pengujian yang relatif rendah, yaitu 90,00%. Pada kondisi ini, metrik sensitivitas untuk kelas Normal hanya menyentuh angka 0,88, yang mengindikasikan bahwa model belum sepenuhnya optimal dalam memetakan fitur-fitur spasial yang membedakan densitas citra medis.

Peningkatan komputasi secara bertahap menunjukkan eskalasi performa yang signifikan. Ketika siklus dinaikkan ke 10 *epoch*, akurasi pengujian meningkat menjadi 92,94%. Titik konvergensi optimal akhirnya tercapai pada konfigurasi 20 *epoch*, di mana akurasi pelatihan mencapai 100,00% dan akurasi pengujian stabil di angka puncak 98,82%. Stabilitas performa ini terkonfirmasi saat eksperimen dilanjutkan hingga 40 *epoch*, di mana tidak ditemukan penurunan akurasi uji maupun gejala *overfitting* (bias hafalan data). Peningkatan durasi pelatihan hingga 20 *epoch* terbukti berhasil menstabilkan sensitivitas kelas Normal menjadi sempurna (1,0000) dan spesifisitas kelas TBC menjadi sempurna (1,0000).

2. Sensitivitas Ruang Parameter Laju Pembelajaran (*Learning Rate*)

Eksperimen bivariat pada *epoch* ke-20 mengungkap bahwa penentuan laju pembelajaran (*learning rate*) sangat sensitif terhadap keberhasilan optimasi model. Penyetelan *learning rate* yang terlampau tinggi pada nilai

1,0 menyebabkan pembaruan bobot gradien melompat terlalu jauh (*overshooting*), sehingga algoritma gagal menemukan titik minimum global. Dampak klinis dari kegagalan ini sangat fatal, di mana akurasi pengujian merosot tajam hingga 41,18% karena model secara keliru mengklasifikasikan semua citra masukan sebagai kasus TBC (nilai spesifisitas TBC berada pada angka 0).

Sebaliknya, penurunan nilai *learning rate* secara bertahap terbukti memberikan stabilitas pembaruan bobot yang lebih presisi. Pada nilai 0,1 akurasi uji meningkat ke 84,71%, dan terus naik menjadi 95,29% pada nilai 0,01. Puncak optimalisasi dicapai secara absolut pada laju pembelajaran 0,001 dengan akurasi pengujian tertinggi sebesar 98,82%. Hal ini mengindikasikan bahwa ekstraksi fitur patologis TBC dari citra rontgen standar memerlukan penyesuaian bobot gradien dalam skala kecil secara bertahap agar model dapat mengenali opasitas atau infiltrat samar pada jaringan paru-paru.

3. Implikasi Klinis Terhadap Program Zero TB

Jika dikomparasikan dengan proses interpretasi manual oleh praktisi medis, integrasi model CNN sekuensial ini menawarkan nilai efisiensi dan objektivitas yang sangat tinggi di fasilitas kesehatan. Dalam konteks klinis, metrik evaluasi dari konfigurasi terbaik (20 *epoch*; *learning rate* 0,001) memegang peranan vital. Nilai spesifisitas kelas TBC yang mencapai angka sempurna (1,0000) menandakan bahwa model memiliki kemampuan mutlak untuk tidak salah mendiagnosis pasien sehat/normal sebagai pasien TBC. Hal ini secara dramatis dapat menekan munculnya "alarm palsu" (*false positive*), sehingga mengurangi beban psikologis pasien dan menghindari pemborosan biaya pengobatan yang tidak perlu.

Di sisi lain, nilai sensitivitas TBC yang tinggi (0,9714) memastikan bahwa risiko lolosnya pasien yang benar-benar mengidap infeksi aktif (*false negative*) dapat diminimalisasi secara ketat. Di Rumah Sakit Paru dr. Ario Wirawan (RSPAW) Salatiga, ketimpangan rasio antara dokter spesialis radiologi dan volume beban citra harian kerap kali menciptakan antrean atau *bottleneck* layanan. Implementasi sistem kecerdasan buatan ini sangat potensial diaplikasikan sebagai instrumen triase otomatis. Dengan kemampuan penapisan awal yang cepat dan presisi, teknologi ini dapat menyaring citra secara komputasional, memprioritaskan kasus-kasus mencurigakan untuk segera ditinjau oleh radiolog, dan pada akhirnya berkontribusi nyata dalam mengakselerasi program eliminasi TBC nasional (*Zero TB Initiative*).

Jika dikomparasikan dengan interpretasi manual radiologi, sistem ini menawarkan efisiensi tinggi. Tingkat *false positive* dapat ditekan secara dramatis. Dalam konteks sistem skrining awal di RSPAW Salatiga yang mengusung inisiatif *Zero TB*, algoritma *deep learning* ini sangat berpotensi memberikan triase otomatis, memfokuskan dokter spesialis pada kasus-kasus yang paling mengindikasi tuberkulosis.

KESIMPULAN

Penelitian ini telah berhasil mengevaluasi dan mengoptimalkan sistem klasifikasi komputasional untuk mengidentifikasi Tuberkulosis menggunakan citra rontgen dada dan *Convolutional Neural Network*. Konfigurasi iterasi pada 20 *epoch* dengan laju pembelajaran 0,001 merupakan pengaturan paling tangguh, mencapai kinerja evaluasi tertinggi dengan akurasi pengujian 98,82%. Arsitektur yang dirancang terbukti mumpuni membedakan secara presisi, terbukti dari nilai sensitivitas 1 untuk kelas normal dan spesifisitas 1 untuk deteksi TB. Implementasi komputasi ini sangat potensial untuk diaplikasikan sebagai instrumen dukungan dalam mempercepat penapisan radiodiagnostik demi mensukseskan program *Zero TB* di fasilitas medis tingkat lanjut.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih yang sebesar-besarnya kepada Kementerian Kesehatan Republik Indonesia melalui Rumah Sakit Paru dr. Ario Wirawan (RSPAW) Salatiga atas dukungan institusional yang telah diberikan. Akses terhadap basis data citra radiografi dada (CXR) serta kelancaran fasilitas yang disediakan oleh instalasi radiologi dan rekam medis sangat berkontribusi krusial dalam proses pelatihan maupun validasi model komputasi pada penelitian ini. Penulis juga mengapresiasi seluruh tenaga medis profesional yang telah memberikan saran klinis selama proses pengembangan sistem deteksi ini.

DAFTAR PUSTAKA

Adrianison, A., S Simbolon, R. L. (2024). Update on the Global Initiative for Chronic Obstructive Lung Disease (GOLD 2023). *Jurnal Respirologi Indonesia*, *44*(1), 98–105.

Al Wachami, N., Guennouni, M., S Iderdar, Y. (2024). Estimating the global prevalence of chronic obstructive pulmonary disease (COPD): A systematic review and meta-analysis. *BMC Public Health*, *24*(1), 297.

Ali, K. S., S Abdalrad, A. S. (2025). Deep learning for chest X-ray classification: A comprehensive review of methods, advances, and clinical integration. *Journal of Al-Qadisiyah for Computer Science and Mathematics*, *17*(4), 81–94.

Alsenani, F. (2024). Unraveling potential neuroprotective mechanisms of herbal medicine for Alzheimer's diseases through comprehensive molecular docking analyses. *Saudi Journal of Biological Sciences*, *31*(6), 103998. https://doi.org/10.1016/j.sjbs.2024.103998

Anggoro, F. T., S Amin, F. (2023). Perancangan dan implementasi sistem anjungan pendaftaran mandiri di Rumah Sakit Paru dr. Ario Wirawan Salatiga menggunakan algoritma FIFO. *Jurnal Elektronika Dan Komputer*, *16*(1).

Apriningsih, A. (2024). Peningkatan pengetahuan petugas kesehatan mengenai peran spirometri sebagai alat deteksi dini Penyakit Paru Obstruktif Kronik (PPOK) di fasilitas kesehatan layanan primer. *Smart Society Empowerment Journal*, *4*(1), 29–37.

Bengio, Y. (2024). Practical recommendations for gradient-based training of deep architectures. In *Neural networks: Tricks of the trade: Second edition* (pp. 437–478). Springer.

Daryati, S., Indrati, R., S Illahi, N. W. (2022). Literature review dosis radiasi pada pemeriksaan radiografi thorax anak di Instalasi Radiologi Rumah Sakit Paru dr. Ario Wirawan Salatiga. *JUSIKA: Jurnal Sistem Informasi, Kapasitas, Dan Informatika*, *6*(2), 104.

Do, P. D., Van, H. N. N., S Vo, V. H. (2026). A unified multimodal framework for chest X-ray retrieval and disease prediction for clinical decision support. *Computers in Biology and Medicine*, *208*, 111667. https://doi.org/10.1016/j.compbiomed.2026.111667

Dwijayanti, S., Agam, R., S Suprapto, B. Y. (2025). Comparative study of CNN techniques for tuberculosis detection using chest X-ray images from Indonesia. *SINERGI*, *29*(2), 485–496. https://doi.org/10.22441/sinergi.2025.2.018

Fairuzabadi, M., Sari, I. P., S Ekowicaksono, I. (2025). *Deep learning untuk pemula: Memahami algoritma, tools, dan masa depan AI*. Yayasan Kita Menulis.

Global Initiative for Chronic Obstructive Lung Disease. (2024). *Global strategy for prevention, diagnosis and management of COPD: 2024 report*. GOLD. https://goldcopd.org/2024-gold-report

Hasenstab, K. A. (2024). Single inhalation lung CT scan deep learning model for COPD diagnosis and staging. *Radiology: Cardiothoracic Imaging*, *6*(1).

Hasenstab, K. A. (2025). Deep learning for detecting and early predicting chronic obstructive pulmonary disease from spirogram time series. *NPJ Systems Biology and Applications*, *11*(1), 18.

Iqbal, H., Khan, A., Nepal, N., Khan, F., S Moon, Y. K. (2024). Deep learning approaches for chest radiograph interpretation: A review of methods and advances. *Electronics*, *13*(23), 4688.

Karnyoto, A. S., Nugroho, K. S., Mozar, F. S., S Pardamean, B. (2025). *Kecerdasan buatan bidang kesehatan*. Instiper Press.

Krishnaveni, A., Rajkumar, G. V., Raj, J. R. F., Krishnan, R. S., Murali, S., S Settu, I. J. (2024). MultimodNet: A Multimodal Deep Learning Model for COPD Staging based on Chest X-Ray and Pulmonary Function Tests. *2024 3rd International Conference on Automation, Computing and Renewable Systems (ICACRS)*, 1683–1690.

Mardiawati, M., Paliling, A., S Mutmainnah, N. (2025). *Revolusi deep learning dalam transformasi kesehatan*. Green Pustaka Indonesia.

Mire, A., Elangovan, V., S Patil, S. (2022). *Advances in deep learning for medical image analysis* (1st ed.). CRC Press.

Ozturk, T., Talo, M., Yildirim, E. A., Baloglu, U. B., Yildirim, O., S Rajendra Acharya, U. (2020). Automated detection of COVID-19 cases using deep neural networks with X-ray images. *Computers in Biology and Medicine*, *121*, 103792. https://doi.org/10.1016/j.compbiomed.2020.103792

Pesapane, F., Gnocchi, G., Quarrella, C., Sorce, A., Nicosia, L., Mariano, L., Bozzini, A. C., Marinucci, I., Priolo, F., Abbate, F., Carrafiello, G., S Cassano, E. (2024). Errors in Radiology: A Standard Review. *Journal of Clinical Medicine*, *13*(15), 4306. https://doi.org/10.3390/jcm13154306

Pham, H. H., Nguyen, H. Q., Nguyen, H. T., Le, L. T., S Khanh, L. (2022). An accurate and explainable deep learning system improves interobserver agreement in the interpretation of chest radiograph. *IEEE Access*, *10*, 104512–104531.

Pradhan, D., Pradhan, N., S Surabhi, G. K. (2025). Omics Approach for the Identification and Validation of Genes, Proteins and Regulators in Relevance to Fruit Development, Ripening and Shelf Life: Current Status and Future Prospectives. *Journal of Advances in Biology & Biotechnology*, *28*(11), 1714–1744. https://doi.org/10.9734/jabb/2025/v28i113356

Risma, V. M., S Utami, E. (2025). Tuberculosis Diagnosis From X-Ray Images Using Deep Learning And Contrast Enhancement Techniques. *Jurnal Teknik Informatika (Jutif)*, *6*(2), 981–994. https://doi.org/10.52436/1.jutif.2025.6.2.4315

Rochmawati, D. R., S Maryani, L. (2025). Deep learning-based ResNet-50 transfer learning approaches for pneumonia detection from chest X-ray images: With and without fine-tuning. *Indonesian Journal of Health Research and Development*, *3*(3), 146–153.

Sancı, M. E., S Öke Günel, G. (2024). Neural Network Based Adaptive Inverse Optimal Control for Non-Affine Nonlinear Systems. *Neural Processing Letters*, *56*(2), 46. https://doi.org/10.1007/s11063-024-11456-9

Setyawan, N. H. (2025). The role of demographics in the early detection of breast cancer: Case report at dr. Ario Wirawan Pulmonary Hospital. *Medica Hospitalia (Med Hosp)*, *12*(2), 209–215.

Shahira, F., Negara, B. S., Yanto, F., S Sanjaya, S. (2025). Optimasi Hyperparameter Deep Learning untuk Deteksi X-Ray Paru-Paru Menggunakan Bayesian Optimization. *Journal of Information Engineering and Educational Technology*, *9*(1), 53–63. https://doi.org/10.26740/jieet.v9n1.p53-63

Yang, H., Wu, Y., Wu, T., Ji, J., Lei, S., S Xu, W. (2025). Accuracy of deep learning in diagnosing chronic obstructive pulmonary disease: A systematic review and meta-analysis. *The Cochrane Library*.

Zhou, S. K. (2023). *Deep learning for medical image analysis* (2nd ed.). Academic Press.