

Analisis Perbandingan Kinerja Arsitektur CNN untuk Klasifikasi Penyakit Tuberkulosis pada Citra Rontgen Thoraks

Isyeh Rafi Maulana*, Wahyu Aji Eko Prabowo

Fakultas Ilmu Komputer, Teknik Informatika, Universitas Dian Nuswantoro, Semarang, Indonesia

Email: ¹*111202214060@mhs.dinus.ac.id, ²prabowo@dsn.dinus.ac.id

Email Penulis Korespondensi: 111202214060@dinus.ac.id

Submitted 07-01-2026; Accepted 24-02-2026; Published 28-02-2026

Abstrak

Tuberkulosis (TB) adalah penyakit menular jangka panjang yang menjadi salah satu penyebab kematian paling tinggi di dunia. Proses diagnosis konvensional sering kali terhambat oleh biaya yang tinggi dan kerumitan teknisnya, sehingga pemeriksaan sinar-X dada (CXR) yang dikombinasikan oleh sistem deteksi komputer berbasis kecerdasan buatan (AI) muncul sebagai alternatif yang lebih efisien. Penelitian ini bertujuan untuk menganalisis perbandingan efektivitas tiga arsitektur dasar CNN, AlexNet, ZFNet, dan ResNet18 dalam mendeteksi TB melalui citra rontgen dada. Metodologi penelitian ini menerapkan kerangka kerja *Knowledge Discovery in Databases* (KDD) pada dataset CXR publik. Optimasi dilakukan menggunakan strategi *Grid Search* dengan 5-Fold *Cross Validation* yang menguji kombinasi *learning rate* dan *batch size* secara sistematis. Hasil eksperimen menunjukkan adanya korelasi positif yang signifikan antara kedalaman arsitektur dan kinerja diagnostik. Melalui parameter terbaik yang ditemukan pada proses *Grid Search*, yaitu *learning rate* 0,0001 dan *batch size* 32, model ResNet18 menunjukkan hasil paling unggul dengan skor Akurasi, 99,28%, presisi, recall, F1-score, dan AUC-ROC sebesar 100%. Keunggulan ResNet18 terletak pada mekanisme *residual learning* yang efektif dalam mengatasi masalah *vanishing gradient* serta memperlancar ekstraksi fitur patologis yang kompleks. Kombinasi ResNet18 dengan optimasi *Grid Search* membuktikan bahwa perpaduan arsitektur modern dan penyesuaian sistematis menghasilkan sistem *Computer-Aided Detection* (CAD) yang sangat dapat diandalkan, melampaui hasil dari penelitian sebelumnya.

Kata Kunci: Convolutional Neural Network; Tuberkulosis; Chest X-Ray; ResNet18; Grid Search

Abstract

Tuberculosis (TB) is a chronic infectious disease and one of the leading causes of mortality worldwide. Conventional diagnostic processes are often hampered by high costs and technical complexity; consequently, Chest X-Ray (CXR) examinations combined with Artificial Intelligence (AI)-based computer detection systems have emerged as a more efficient alternative. This study aims to comparatively analyze the effectiveness of three fundamental CNN architectures AlexNet, ZFNet, and ResNet18 in detecting TB from chest X-ray images. The research methodology employs the *Knowledge Discovery in Databases* (KDD) framework on a public CXR dataset. Hyperparameter optimization was implemented using a *Grid Search* strategy integrated with 5-Fold *Cross-Validation* to systematically identify the optimal configuration. Experimental results indicate a significant positive correlation between architectural depth and diagnostic performance. Based on the optimal parameters identified through *Grid Search* specifically a *learning rate* of 0.0001 and a *batch size* of 32 the ResNet18 model demonstrated superior performance, achieving 99.28% scores for Accuracy, and 100% for precision, recall, F1-score and AUC-ROC. The superiority of ResNet18 lies in its *residual learning* mechanism, which effectively addresses the *vanishing gradient* problem and facilitates the extraction of complex pathological features. The combination of ResNet18 with *Grid Search* optimization demonstrates that the synergy of modern architecture and systematic tuning yields a highly reliable *Computer-Aided Detection* (CAD) system, surpassing the results of previous studies.

Keywords: Convolutional Neural Network; Tuberculosis; Chest X-Ray; ResNet18; Grid Search.

1. PENDAHULUAN

Tuberkulosis (TB) merupakan penyakit menular kronis yang menjadi salah satu penyebab kematian tertinggi di dunia akibat agen infeksius tunggal, menempati peringkat kedua setelah COVID-19 dan melampaui HIV/AIDS. Berdasarkan laporan *Global Tuberculosis Report* terbaru, diperkirakan 10,6 juta orang menderita TB secara global dengan angka kematian mencapai 1,3 juta jiwa pada tahun 2022 [1]. Penyakit ini disebabkan oleh bakteri *Mycobacterium tuberculosis* yang utamanya menyerang parenkim paru. Di negara-negara dengan beban penyakit tinggi seperti Indonesia, pengendalian TB menghadapi tantangan besar akibat keterlambatan diagnosis yang memicu rantai penularan di komunitas. Oleh karena itu, strategi skrining massal yang efektif dan efisien sangat diperlukan untuk mendeteksi kasus aktif maupun laten, terutama pada populasi rentan seperti anak-anak dan remaja [2]. Secara konvensional, diagnosis TB paru dilakukan melalui pemeriksaan mikroskopis sputum, tes molekuler cepat, dan kultur bakteri. Meskipun teknologi pengurutan genom (*sequencing*) terbaru seperti *Nanopore Sequencing* menawarkan resolusi data genomik yang komprehensif untuk mendeteksi resistensi obat dan investigasi wabah, metode ini memiliki hambatan biaya kapital yang tinggi dan prosedur teknis yang rumit untuk diterapkan secara luas di fasilitas kesehatan tingkat dasar [3]. Sebagai alternatif yang lebih terjangkau dan tersedia luas, pemeriksaan radiologi menggunakan Sinar-X dada (*Chest X-Ray* atau CXR) tetap menjadi modalitas utama untuk triase dan skrining awal. WHO merekomendasikan penggunaan perangkat lunak *Computer-Aided Detection* (CAD) berbasis kecerdasan buatan (*Artificial Intelligence/AI*) sebagai pengganti pembacaan manusia untuk interpretasi CXR, mengingat keterbatasan jumlah radiolog dan tingginya variabilitas antar-pengamat dalam diagnosis manual [4].

Penerapan *Deep Learning* (DL), khususnya algoritma *Convolutional Neural Network* (CNN), telah menunjukkan potensi luar biasa dalam analisis citra medis. Studi prospektif oleh Khan et al. menunjukkan bahwa perangkat lunak berbasis DL mampu memenuhi standar minimum WHO untuk triase TB dengan sensitivitas mencapai 93% pada populasi


HIV-negatif, meskipun kinerjanya dapat menurun pada kasus TB dengan *smear-negative* [5]. Perkembangan arsitektur CNN terus berevolusi, mulai dari model klasik hingga model yang sangat dalam (*deep*). Namun, tren penggunaan model yang semakin kompleks dan *over-parameterized* memunculkan isu efisiensi komputasi. Bhowmick et al. menyoroti pentingnya pengembangan model yang *lightweight* (ringan) dan hemat energi, seperti *Spiking Neural Network* (SNN), untuk aplikasi medis agar dapat dijalankan pada perangkat dengan sumber daya terbatas [6]. Sejalan dengan itu, Raicevic dalam penelitian terbarunya juga mengeksplorasi penggunaan arsitektur CNN kustom yang lebih sederhana untuk deteksi TB, namun model yang terlalu sederhana seringkali memiliki keterbatasan dalam menangkap variasi fitur patologi yang subtil [7]. Berbagai penelitian terdahulu telah mengeksplorasi kinerja CNN untuk klasifikasi citra. Irfansyah dkk. mengimplementasikan arsitektur AlexNet untuk klasifikasi penyakit pada citra daun tanaman kopi dan membuktikan bahwa arsitektur klasik ini masih sangat relevan. Keunggulan AlexNet terletak pada kemampuannya menangani deformasi citra input (seperti translasi, rotasi, dan skala) serta penerapan teknik *Dropout Regularization* dan fungsi aktivasi ReLU yang efektif mengurangi parameter bebas tanpa memerlukan pra-pemrosesan yang rumit, sehingga mampu memberikan akurasi yang baik (81,6%) [8], [9]. Di sisi lain, Aldiansyah dan Soleh melakukan eksperimen variasi jumlah hidden layer pada CNN untuk klasifikasi TB pada citra X-ray, di mana model dengan 5 *hidden layer* menghasilkan akurasi terbaik sebesar 98%, menunjukkan bahwa kedalaman jaringan harus dioptimalkan secara spesifik sesuai karakteristik data, bukan sekadar diperdalam secara sembarangan [10].

Terdapat perdebatan menarik dalam literatur mengenai perbandingan kinerja antara arsitektur dangkal (seperti AlexNet) dan arsitektur dalam (seperti ResNet) pada kasus yang berbeda. Falahkhi et al. membandingkan AlexNet dan ResNet pada klasifikasi citra bunga, di mana ResNet terbukti superior dengan akurasi 97,3% dibandingkan AlexNet yang hanya 90,2% [11]. Superioritas ini disebabkan oleh inovasi arsitektur ResNet yang menggunakan *residual block* dengan koneksi *skip* (*shortcut connection*). Mekanisme ini memungkinkan aliran gradien langsung melewati lapisan-lapisan tertentu, sehingga efektif mengatasi masalah gradien yang menghilang (*vanishing gradient*) yang sering terjadi pada jaringan yang sangat dalam, sekaligus memfasilitasi pembelajaran fitur yang lebih kompleks [12]. Namun, temuan kontradiktif dilaporkan oleh Nicholas et al. pada kasus spesifik deteksi Tuberkulosis menggunakan citra X-ray. Penelitian mereka justru menemukan bahwa model AlexNet mengungguli ResNet dengan akurasi validasi 88,33% berbanding 83,10% [13]. Hal ini mengindikasikan adanya fenomena anomali di mana arsitektur yang lebih sederhana dan lebih tua bisa jadi lebih efektif dalam menangkap fitur global pada citra medis tertentu dibandingkan arsitektur yang lebih kompleks. Sementara itu, Gupta dan Sharma memperluas evaluasi dengan membandingkan model VGG19 menggunakan variasi optimizer, di mana penggunaan *optimizer* standar seperti SGD terkadang menghasilkan konvergensi yang lambat dibandingkan metode adaptif [14]. Selain itu, Ejiyi et al. mengusulkan modifikasi ResNet dengan mekanisme atensi (ResfEANet) untuk meningkatkan akurasi deteksi TB hingga 97,59%, namun mengakui bahwa ResNet standar memiliki beban komputasi yang berat [15]. Berdasarkan tinjauan literatur tersebut, kami merumuskan sebuah *research gap*. Sebagian besar penelitian saat ini terpaku pada penggunaan model terbaru atau modifikasi kompleks, namun belum banyak yang melakukan investigasi mendalam mengenai mengapa model klasik seperti AlexNet bisa mengungguli model modern seperti ResNet pada dataset TB tertentu, dan bagaimana posisi kinerja arsitektur transisi seperti ZFNet di antara keduanya. ZFNet sendiri merupakan penyempurnaan dari AlexNet yang dirancang untuk mengatasi hilangnya fitur unik pada lapisan awal. Dengan memperkecil ukuran filter (dari 11 x 11 menjadi 7 x 7) dan *stride* (dari 4 menjadi 2) pada lapisan konvolusi pertama, ZFNet mampu mempertahankan lebih banyak informasi fitur spasial yang mendetail dibandingkan pendahulunya, yang secara teoritis menawarkan keseimbangan antara ekstraksi fitur dan kompleksitas [16].

Sebagian besar penelitian sebelumnya, cenderung berfokus pada perbandingan arsitektur secara langsung atau penggunaan parameter *default* tanpa melakukan optimalisasi *hyperparameter* yang sistematis. Selain itu, evaluasi seringkali hanya bergantung pada pembagian data statis (*hold-out*) yang rentan terhadap bias, serta kurang mendalamnya analisis mengenai "jalur evolusi" arsitektur dari model klasik ke modern dalam konteks dataset TBC yang sama. Ketidadaan penerapan teknik validasi silang (*cross-validation*) dan pencarian parameter otomatis (*grid search*) menyebabkan ketidakpastian apakah performa yang dihasilkan benar-benar optimal atau hanya kebetulan semata. Hal ini menjadi kesenjangan (*gap*) penelitian yang krusial untuk dijawab guna mendapatkan model diagnosis yang benar-benar *robust*. Berdasarkan latar belakang di atas, penelitian ini bertujuan untuk melakukan analisis komparasi kinerja tiga arsitektur fundamental CNN, yaitu AlexNet, ZFNet, dan ResNet, dalam mengklasifikasikan citra Sinar-X dada untuk deteksi Tuberkulosis. Pemilihan ketiga model ini merepresentasikan evolusi arsitektur CNN, di mana ZFNet hadir sebagai penyempurnaan dari AlexNet (dengan ukuran filter dan stride yang lebih kecil untuk mempertahankan fitur spasial [16]), dan ResNet sebagai solusi untuk jaringan dalam. Penelitian ini berusaha mengisi celah penelitian terdahulu dengan menerapkan strategi *Hyperparameter Tuning* menggunakan *Grid Search* dan evaluasi K-Fold *Cross Validation* untuk memastikan konsistensi hasil. Hasil dari penelitian ini diharapkan dapat memberikan rekomendasi empiris mengenai arsitektur mana yang paling optimal baik dari segi performa diagnostik maupun efisiensi sumber daya untuk diimplementasikan dalam sistem diagnosis berbantuan komputer.

2. METODOLOGI PENELITIAN

Alur penelitian ini disusun secara sistematis untuk menjamin validitas proses ekstraksi informasi dari citra medis. Tahapan penelitian yang dilakukan dalam studi ini mengacu pada kerangka kerja terstruktur untuk mengolah data mentah menjadi pengetahuan diagnostik yang bermanfaat, sebagaimana diilustrasikan pada Gambar 1.




Gambar 1. Tahapan *knowledge discovery in databases* (KDD)

Penelitian ini menerapkan kerangka kerja *Knowledge Discovery in Databases* (KDD) sebagaimana ditunjukkan pada Gambar 1, untuk mengekstraksi pola dan pengetahuan diagnostik dari data citra medis. KDD merupakan proses terstruktur yang mengubah data mentah menjadi informasi yang berguna melalui serangkaian tahapan sistematis [17]. Dalam konteks analisis citra medis untuk deteksi Tuberkulosis (TB), tahapan KDD yang diadaptasi meliputi: (1) *Data Collection* (Pengumpulan Data), (2) *Preprocessing* (Pra-pemrosesan), (3) *Modeling* (Pembentukan Model), (4) *Evaluation* (Evaluasi), dan (5) *Analysis of Comparative Results* (Analisis Perbandingan Hasil). Alur penelitian ini dirancang untuk memastikan validitas eksperimen dalam membandingkan kinerja arsitektur CNN.

2.1 Pengumpulan Data

Data yang digunakan dalam penelitian ini bersumber dari repositori publik Tuberculosis (TB) Chest X-ray Database yang dikelola oleh peneliti dari Qatar University dan University of Dhaka [18], bekerja sama dengan tenaga medis dari Hamad Medical Corporation [19]. Dataset ini dipilih karena memiliki validasi klinis yang kuat dan telah digunakan sebagai standar benchmark dalam berbagai studi deteksi TB berbasis Deep Learning. Sebelum dilakukan pemrosesan lebih lanjut, penting untuk memahami karakteristik visual dari data yang digunakan. Perbedaan morfologi antara kondisi paru-paru normal dan yang terinfeksi bakteri *Mycobacterium tuberculosis* disajikan sebagai referensi visual. Contoh citra sinar-X dada (CXR) pada database publik tersebut ditampilkan pada Gambar 2



Gambar 2. Contoh citra sinar-X dada (CXR) pada database publik

Penelitian ini menggunakan 4.200 gambar sinar-X dari dada yang terdiri dari 700 gambar kategori TB Positif dan 3.500 gambar kategori Normal seperti yang ditampilkan pada Gambar. 2. Dengan mempertimbangkan ketidakseimbangan dalam distribusi data yang memiliki rasio 1:5, kinerja model akan dinilai dengan metrik evaluasi yang dapat mengatasi masalah ketidakseimbangan kelas tersebut. Selanjutnya, dataset dibagi menggunakan metode hold-out dengan proporsi 80:20, yang memisahkan data menjadi set pelatihan untuk pembangunan model dan set pengujian untuk memastikan generalisasi model pada data baru.

2.2 Pra-pemrosesan Data

Tahap persiapan data memiliki peranan penting dalam meningkatkan mutu data masukan dan mencegah terjadinya overfitting, terutama dalam arsitektur *Convolutional Neural Network* (CNN) yang rumit. Mengingat sifat citra medis yang rentan terhadap perubahan pencahayaan dan posisi, penelitian ini menggunakan berbagai teknik untuk augmentasi data dan normalisasi statistik. Proses yang dilakukan selama fase pelatihan (*traintransforms*) dirancang untuk membantu model

dalam mengenali karakteristik Tuberkulosis (TB) dengan cara yang tidak terpengaruh oleh perubahan spasial dan visual. Teknik augmentasi yang digunakan termasuk *random resized crop* yang mengubah ukuran ke dimensi input standar, dengan tujuan memberikan variasi skala dan area perhatian secara acak kepada model, serta *random horizontal flip* dengan probabilitas 0.5 untuk meniru perubahan posisi pasien. Selain itu, Color Jitter diterapkan dengan cara mengubah kecerahan dan kontras sebesar 0.1, bertujuan agar model menjadi lebih tangguh menghadapi perbedaan kualitas pada mesin sinar-X. Sebagai langkah akhir, citra diubah menjadi tensor dan dinormalisasi menggunakan rata-rata [0,485; 0,456; 0,406] serta deviasi standar [0,229; 0,224; 0,225] dari distribusi data ImageNet, yang sangat membantu dalam mempercepat konvergensi gradien selama pelatihan. Berbeda dengan data pelatihan, citra yang digunakan untuk validasi dan pengujian hanya dikenakan proses Resize untuk mencapai ukuran target dan Normalization tanpa ada augmentasi acak, agar konsistensi data tetap terjaga saat mengevaluasi kinerja model.

2.3 Pembagian Data

Pada penelitian ini, dataset citra rontgen toraks dibagi menjadi tiga subset independen dengan rasio skema 80:10:10 untuk data latih (*training*), data validasi (*validation*), dan data uji (*testing*). Teknik *stratified random sampling* diterapkan dalam proses pembagian ini untuk memastikan distribusi kelas yang seimbang (Normal dan Tuberculosis) pada setiap subset, sehingga mencegah bias pada model akibat ketimpangan data [7]. Sebanyak 80% dari total dataset dialokasikan sebagai data latih yang digunakan untuk proses pembelajaran bobot model. Pada fase pelatihan ini, diterapkan juga metode *K-Fold Cross Validation* yang terintegrasi dengan *Grid Search* untuk mencari kombinasi *hyperparameter* yang optimal dan memastikan model tidak hanya menghafal pola data tertentu. Selanjutnya, 10% data dialokasikan sebagai data validasi yang berfungsi sebagai pembandingan selama proses pelatihan (*training history*) untuk memantau performa model di setiap *epoch* serta mencegah terjadinya *overfitting*. Sisa 10% data dialokasikan sebagai data uji (*test set*) yang sepenuhnya terisolasi dan tidak pernah dilihat oleh model selama proses pelatihan maupun validasi. Subset ini digunakan secara eksklusif pada tahap evaluasi akhir untuk mengukur performa generalisasi model yang objektif, menghasilkan metrik akurasi, presisi, *recall*, dan F1-score yang dilaporkan pada hasil penelitian [19]. Pendekatan pembagian 80:10:10 ini telah terbukti efektif dalam penelitian medis serupa untuk menyeimbangkan kebutuhan data pelatihan yang cukup dengan validasi yang reliabel.

2.4 Pemodelan

Tahap ini adalah bagian fundamental dari proses data mining, di mana tiga jenis arsitektur *Convolutional Neural Network* (CNN) yang berbeda digunakan untuk mengekstraksi fitur spasial dari citra paru, yaitu AlexNet, ZFNet, dan ResNet. AlexNet, yang merupakan pelopor *deep CNN*, memiliki 5 lapisan konvolusi dan 3 lapisan *fully connected* yang menggunakan fungsi aktivasi ReLU serta teknik dropout untuk menghindari *overfitting*. Arsitektur ini dipilih karena terbukti efektif dalam mengekstraksi fitur pada dataset medis dengan ukuran kecil Nicholas et al. [13]. Selanjutnya, ZFNet (Zeiler dan Fergus Net) digunakan sebagai pengembangan dari AlexNet, terutama dengan modifikasi filter pada lapisan awal dari 11 x 11 menjadi 7 x 7 dan pengurangan stride. Perubahan ini bertujuan untuk menangkap rincian fitur yang lebih halus dalam citra radiologis yang mungkin tidak terdeteksi oleh filter yang lebih besar. Terakhir, ResNet (*residual network*) diperkenalkan sebagai model yang menangani masalah *vanishing gradient* dalam jaringan yang sangat dalam dengan menerapkan konsep residual learning melalui *skip connections*. Penelitian menunjukkan bahwa arsitektur yang didasarkan pada ResNet efektif dalam menangkap fitur hirarkis yang kompleks, seperti tekstur lesi paru, yang sangat penting untuk membedakan Tuberkulosis dari kondisi lainnya Sharma et al. [20].

2.5 Hyperparameter Tuning

Untuk mengoptimalkan kinerja arsitektur AlexNet, ZFNet, dan ResNet18, penelitian ini menerapkan strategi *hyperparameter tuning* menggunakan metode *Grid Search* yang terintegrasi dengan *K-Fold Cross Validation* ($k=5$). Pendekatan ini bertujuan untuk mengeksplorasi ruang parameter secara sistematis guna menemukan konfigurasi yang menghasilkan akurasi validasi tertinggi dan generalisasi model yang paling stabil [21]. Parameter utama yang diuji dalam eksperimen ini meliputi *learning rate* dan *batch size*, karena kedua parameter tersebut memiliki dampak paling signifikan terhadap konvergensi gradien dan stabilitas pelatihan model CNN. Ruang pencarian (*search space*) yang didefinisikan mencakup variasi nilai *learning rate* pada himpunan {0,0001; 0,0005; 0,001} serta variasi *batch size* yang dikonfigurasi sebesar 16 dan 32. Seluruh kombinasi parameter tersebut dilatih menggunakan *optimizer* Adam (*adaptive moment estimation*) yang dipilih karena kemampuannya dalam menyesuaikan laju pembelajaran secara adaptif untuk setiap bobot parameter, sehingga mempercepat konvergensi pada permukaan *loss function* yang kompleks [13]. Fungsi kerugian yang digunakan adalah *cross-entropy loss* dengan jumlah *epoch* ditetapkan sebanyak 10 untuk setiap iterasi percobaan. Konfigurasi dengan rata-rata akurasi validasi terbaik dari proses *cross-validation* kemudian dipilih sebagai model final untuk tahap pengujian (*testing*).

2.6 Evaluasi Model

Untuk menilai kinerja model secara objektif dan menyeluruh, terutama dengan mempertimbangkan adanya ketidakseimbangan kelas dalam dataset, penelitian ini menggunakan *confusion matrix* sebagai dasar perhitungan. Matriks ini memetakan hasil prediksi menjadi empat kategori: *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan

False Negative (FN). Berdasarkan elemen-elemen tersebut, kinerja model diukur menggunakan metrik evaluasi utama berikut:

a. *Accuracy* (Akurasi)

Akurasi merupakan rasio prediksi yang benar (positif dan negatif) terhadap keseluruhan data. Metrik ini memberikan gambaran umum mengenai seberapa sering model melakukan prediksi yang tepat secara keseluruhan.

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

b. *Precision* (Presisi)

Presisi mengukur tingkat ketepatan prediksi positif. Metrik ini sangat penting untuk meminimalkan kesalahan diagnosis positif palsu (*False Positive*), yaitu ketika pasien sehat didiagnosis menderita TB.

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

c. *Recall* (Sensitivitas) *Recall* atau sensitivitas mengukur kemampuan model dalam mengidentifikasi seluruh kasus TB positif yang sebenarnya. Dalam dunia medis, nilai *recall* yang tinggi sangat diutamakan untuk menghindari pasien TB yang tidak terdeteksi (*False Negative*).

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

d. *F1-Score*

F1-Score adalah rata-rata harmonis antara Presisi dan *Recall*. Metrik ini memberikan perspektif tunggal mengenai kinerja model, yang sangat berguna dalam konteks dataset yang tidak seimbang di mana akurasi saja bisa menjadi bias.

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

Selain metrik yang menggunakan satu threshold, penelitian ini juga melakukan analisis *Receiver Operating Characteristic* (ROC) dan *Area Under the Curve* (AUC). Kurva ROC menunjukkan hubungan antara tingkat True Positive dan False Positive pada berbagai batas klasifikasi. Sementara itu, AUC adalah angka skalar yang menggambarkan luas wilayah di bawah kurva ROC, yang dengan efektif menilai kemampuan model untuk membedakan antara kelas TB positif dan Normal, tanpa memandang threshold yang digunakan. Penekanan penggunaan AUC-ROC penting karena metrik ini memberikan penilaian yang lebih mendalam tentang probabilitas dalam prediksi biner dibanding hanya mempertimbangkan akurasi Novalia et al. [17]. Hal ini sejalan dengan studi lain yang menggunakan AUC sebagai parameter utama untuk menilai ketahanan model CNN dalam mendeteksi kelainan pada paru-paru melalui citra medis yang kompleks.

e. *ROC dan AUC*

Kurva ROC memvisualisasikan *trade-off* antara *True Positive Rate* (TPR) pada sumbu Y dan *False Positive Rate* (FPR) pada sumbu X pada berbagai batas klasifikasi.

$$\text{Sumbu Y: True Positive Rate (TPR)} = TPR \frac{TP}{TP + FN} \quad (5)$$

$$\text{Sumbu X: False Positive Rate (FPR)} = FPR \frac{FP}{FP + TN} \quad (6)$$

$$\text{Nilai AUC} = AUC \int_0^1 TPR(FPR) d(FPR) \quad (7)$$

Keterangan:

TP (*True Positive*): Jumlah data positif (TB) yang diprediksi benar sebagai positif.

TN (*True Negative*): Jumlah data negatif (Normal) yang diprediksi benar sebagai negatif.

FP (*False Positive*): Jumlah data negatif yang salah diprediksi sebagai positif.

FN (*False Negative*): Jumlah data positif yang salah diprediksi sebagai negatif.

3. HASIL DAN PEMBAHASAN

Bab ini memaparkan hasil eksperimen yang dilakukan menggunakan skenario pengujian yang telah dirancang pada metodologi penelitian. Analisis dilakukan terhadap proses pelatihan model, evaluasi kinerja menggunakan confusion matrix, serta pembahasan komparatif antara arsitektur AlexNet, ZFNet, dan ResNet18 dalam mendeteksi TB.

3.1 Hasil Evaluasi Model

Ringkasan hasil akhir pelatihan dapat dilihat pada Tabel 1. Proses pelatihan dilakukan terhadap tiga arsitektur model, yaitu AlexNet, ZFNet, dan ResNet18, menggunakan konfigurasi *hyperparameter* yang telah ditetapkan pada sub-bab sebelumnya. Pelatihan dijalankan sebanyak 10 *epoch* untuk setiap model guna mengamati pola konvergensi dan stabilitas pembelajaran fitur dari dataset citra *X-Ray*. Hasil pemantauan kinerja model selama proses pelatihan diukur berdasarkan

dua parameter utama: nilai *Loss* (tingkat kesalahan) dan *Accuracy* (tingkat ketepatan prediksi) pada data latih (*train*) maupun data validasi (*validation*).


Tabel 3. Perbandingan hasil akhir tahap pelatihan (*Epoch* 10)

Model	Accuracy	Recall	Precision	F1-Score	AUC
AlexNet	0,9928	0,9571	1,0000	0,9781	0,9994
ZFNet	0,9952	1,0000	0,9722	0,9859	1,0000
ResNet18	1,0000	1,0000	1,0000	1,0000	1,0000

Efektivitas dari ketiga arsitektur model dalam mempelajari fitur dari dataset dievaluasi berdasarkan pencapaian metrik performa di akhir iterasi. Hasil komparasi metrik akurasi, presisi, recall, F1-Score, dan AUC pada tahap pelatihan dirangkum secara komprehensif dalam Tabel 1. Berdasarkan data tersebut, terlihat bahwa ResNet18 telah mencapai performa puncak dibandingkan model lainnya. Proses pencarian parameter optimal dilakukan secara sistematis melalui *Grid Search*. Hasil penentuan *hyperparameter* terbaik beserta performa rata-rata pada setiap arsitektur dirangkum dalam Tabel 4. Berdasarkan Tabel 4, ResNet18 tidak hanya mencapai akurasi tertinggi, tetapi juga memiliki standar deviasi terkecil ($\pm 0,0039$), yang membuktikan stabilitas model yang sangat tinggi terhadap variasi data dibandingkan AlexNet dan ZFNet. Secara visual, dinamika perubahan akurasi dan penurunan *loss* selama 10 *epoch* dapat dilihat pada Gambar 3 dan 4.

Tabel 4. Hasil optimasi *hyperparameter* dan validasi K-Fold pada tahap pelatihan

Model	Best Hyperparameters	Best Grid Acc	K-Fold Acc Mean	K-Fold Acc Std
AlexNet	{'lr': 0,0005, 'bs': 32}	0,9928	0,9610	$\pm 0,0300$
ZFNet	{'lr': 0,0001, 'bs': 16}	0,9952	0,9717	$\pm 0,0240$
ResNet18	{'lr': 0,0001, 'bs': 32}	1,0000	0,9969	$\pm 0,0039$



Gambar 3. Gambar grafik perbandingan akurasi pelatihan dan validasi ketiga model



Gambar 4. Grafik Perbandingan *Training Loss* Ketiga Model


Berdasarkan hasil eksperimen yang dirangkum pada Gambar 3 dan Gambar 4, terlihat dinamika performa yang signifikan antar arsitektur yang diuji. Model ResNet18 menunjukkan stabilitas pelatihan dan konvergensi yang paling superior dibandingkan dua model lainnya. Hal ini terindikasi dari lonjakan akurasi validasi yang signifikan sejak *epoch* ke-2 yang langsung mencapai 99% dan terus meningkat secara konsisten hingga titik optimal 100% pada akhir pelatihan. Kurva *loss* pada ResNet18 juga memperlihatkan penurunan yang tajam dan stabil, yang mengonfirmasi bahwa mekanisme *residual connection* pada arsitektur ini bekerja sangat efektif dalam meminimalisir degradasi gradien selama

proses *backpropagation*, sehingga memungkinkan model untuk mempelajari fitur-fitur representatif dari citra tuberkulosis dengan sangat cepat dan akurat. Sebaliknya, arsitektur AlexNet dan ZFNet menunjukkan pola pembelajaran yang cenderung identik satu sama lain namun tertinggal dibandingkan ResNet18. Kedua model ini memulai fase pelatihan dengan akurasi validasi yang relatif lebih rendah, berkisar antara 80% hingga 86% pada *epoch* awal, dan memerlukan iterasi yang lebih panjang untuk mengejar ketertinggalan tersebut secara bertahap. Hingga akhir pelatihan, *Training Accuracy* kedua model ini masih berada di kisaran 99% hingga 99,50%, belum mampu menyamai capaian ResNet18. Fenomena ini mengindikasikan bahwa arsitektur yang lebih dangkal seperti AlexNet dan ZFNet memiliki keterbatasan kapasitas dalam menangkap fitur-fitur kompleks secara instan dibandingkan arsitektur yang lebih dalam (*deep*) seperti ResNet. Analisis lebih lanjut terhadap kurva akurasi memperlihatkan fenomena menarik di mana nilai *Validation Accuracy* cenderung lebih tinggi dibandingkan *Training Accuracy* pada seluruh model. Kondisi ini lazim terjadi akibat penerapan teknik *Data Augmentation* yang agresif seperti *random crop* dan *color jitter* pada data latih, yang membuat variasi data latih menjadi lebih sulit diprediksi dibandingkan data validasi yang bersifat statis. Kendati demikian, ResNet18 tetap menunjukkan kemampuan generalisasi (*robustness*) terbaik, ditandai dengan selisih *loss* yang sangat kecil antara *training* dan *validation* (0,14 vs 0,02), jauh lebih stabil dibandingkan *gap* yang dihasilkan oleh AlexNet dan ZFNet. Konsistensi hasil ini diperkuat melalui pengujian *5-Fold cross validation*, yang memastikan bahwa performa tinggi tersebut bukan kebetulan semata, melainkan hasil dari kemampuan model mengenali pola tuberkulosis secara objektif pada seluruh subset data uji yang berbeda. Hasil akurasi validasi dari setiap *fold* untuk ketiga model (AlexNet, ZFNet, dan ResNet18) dirangkum dalam Tabel 5. Hasil pada Tabel 5 menunjukkan bahwa ResNet18 memiliki performa yang sangat stabil dengan standar deviasi yang paling rendah ($\pm 0.1\%$), mengindikasikan bahwa model ini *robust* terhadap variasi data. Berbeda dengan AlexNet dan ZFNet yang memiliki variasi performa lebih lebar antar-*fold*. Berdasarkan hasil ini, model dari Fold ke-1 pada ResNet18 dipilih sebagai model final untuk evaluasi mendalam pada subbab berikutnya.

Tabel 5. Hasil akurasi validasi dari setiap *fold*

Fold	AlexNet	ZFNet	ResNet18
fold-1	0,9785	0,9857	0,9988
fold-2	0,9845	0,9833	0,9976
fold-3	0,9786	0,9952	0,9988
fold-4	0,9833	0,9857	0,9810
fold-5	0,9821	0,9881	0,9988

Selain menggunakan metrik evaluasi statis, dilakukan analisis terhadap kemampuan model dalam membedakan kelas target pada berbagai ambang batas klasifikasi. Evaluasi kemampuan diskriminasi model secara komprehensif melalui perbandingan tingkat sensitivitas dan spesifisitas disajikan dalam bentuk kurva *Receiver Operating Characteristic* (ROC) pada Gambar 5.



Gambar 5. Kurva ROC menunjukkan nilai AUC mendekati 1.0 untuk seluruh model arsitektur

Berdasarkan visualisasi pada Gambar 5, terlihat bahwa seluruh arsitektur model memiliki kurva yang sangat mendekati sudut kiri atas dengan nilai *Area Under the Curve* (AUC) mencapai 1.0. Hal ini mengindikasikan bahwa baik AlexNet, ZFNet, maupun ResNet18 memiliki probabilitas yang sangat tinggi untuk mengklasifikasikan citra pasien TB secara benar dibandingkan citra normal. Nilai AUC yang mendekati sempurna ini menegaskan bahwa sistem *Computer-Aided Diagnosis* (CAD) yang dikembangkan sangat *robust* dan memiliki tingkat kepercayaan tinggi untuk digunakan dalam membantu praktisi klinis melakukan skrining awal penyakit Tuberkulosis.


3.1.1 Analisis Performa Model Terbaik

Setelah model final terbentuk, dilakukan pengujian menggunakan data uji yang belum pernah dilihat sebelumnya untuk mengukur kemampuan generalisasi. Perbandingan performa final dari ketiga arsitektur pada data uji ditampilkan pada Tabel 6.

Tabel 6. Perbandingan hasil akhir tahap pelatihan (*Epoch* 10)

Model	Accuracy	Recall	Precision	F1-Score	AUC
AlexNet	0,9809	0,9857	1,0000	0,9928	0,9996
ZFNet	0,9476	0,9857	1,0000	0,9928	1,0000
ResNet18	0,9928	1,0000	1,0000	1,0000	1,0000

Berdasarkan hasil pengujian yang dirangkum pada Tabel 6. Hasil ini menjadi landasan utama dalam menentukan model yang paling reliabel untuk sistem diagnosis. ResNet18 menghasilkan performa yang superior ditunjukkan oleh semua nilai metrik pengukuran. Berdasarkan hasil komparasi kuantitatif, arsitektur ResNet18 terbukti menjadi model paling superior dengan tingkat akurasi mencapai 99,28% dan presisi 100%. Untuk memvalidasi kualitas prediksi model secara mendalam, visualisasi *Confusion Matrix* pada Gambar 6 digunakan untuk memetakan distribusi prediksi benar (*True Positive/True Negative*) dan prediksi salah (*False Positive/False Negative*).



Gambar 6. Confusion matrix model ResNet18 pada data uji

Keberhasilan mencapai akurasi sempurna ini dapat dikausalisasikan pada dua faktor utama. Pertama, kedalaman arsitektur ResNet dengan mekanisme *residual learning* memungkinkan model mengekstraksi fitur hirarkis yang sangat distingtif (khas) dari citra rontgen, mulai dari tepi (*edges*) hingga pola patologis kompleks TBC. Mekanisme *skip connection* pada ResNet18 memungkinkan aliran informasi gradien yang lebih lancar selama proses pelatihan, sehingga jaringan yang dalam dapat mempelajari fitur representasi hirarkis yang sangat kompleks tanpa mengalami degradasi kinerja [13]. Hal ini memvalidasi bahwa untuk tugas klasifikasi citra medis dengan pola visual yang rumit seperti sinar-X paru, penggunaan arsitektur yang dalam (*deep architecture*) dengan *residual learning* memberikan keuntungan signifikan dibandingkan arsitektur sekuensial yang lebih dangkal seperti AlexNet [9]. Kedua, efektivitas strategi *hyperparameter tuning* dengan *optimizer* Adam yang berhasil membawa model menuju konvergensi global yang optimal. Hasil ini membuktikan bahwa model ResNet18 sangat *robust* dan dapat diandalkan sebagai alat bantu diagnosis (CAD) dengan tingkat kepercayaan yang sangat tinggi.

3.2 Pembahasan

Penelitian ini berfokus pada pengembangan model deteksi dini TB yang presisi menggunakan pendekatan *deep learning*. Berdasarkan hasil eksperimen, arsitektur ResNet18 dengan optimasi *hyperparameter* berbasis *Grid Search* terbukti menghasilkan kinerja paling superior dibandingkan arsitektur lain yang diuji. Untuk memvalidasi kontribusi dan posisi penelitian ini dalam ranah akademis, hasil terbaik yang diperoleh dikomparasikan dengan metode serupa yang telah dipublikasikan pada dataset sejenis dalam kurun waktu dua tahun terakhir. Perbandingan ini disajikan secara komprehensif pada Tabel 7. Analisis pada Tabel 7 memperlihatkan bahwa metode yang diusulkan berhasil melampaui capaian akurasi penelitian-penelitian terdahulu secara signifikan. Peningkatan performa yang paling mencolok terlihat jika dibandingkan dengan penelitian Nicholas et al. [13] yang juga mengeksplorasi arsitektur CNN klasik, di mana terdapat selisih kenaikan akurasi sebesar +10.84%.

Tabel 7. Komparasi hasil dengan penelitian terdahulu

Peneliti (Tahun)	Metode/Arsitektur	Akurasi	Keterangan
Nicholas et al. [13] (2024)	AlexNet (Manual Tuning)	88,33%	Model <i>shallow</i> (dangkal), akurasi terbatas pada fitur kompleks.

Raicevic [7] (2025)	Custom CNN (3-Layer)	97,55%	Efisien namun kurang <i>robust</i> dibanding <i>deep</i> CNN.
Gupta & Sharma [14] (2024)	VGG19 + SGD Optimizer	98,00%	Menggunakan optimizer standar, konvergensi lebih lambat.
Metode yang diusulkan pada penelitian ini	ResNet18 + Grid Search	99,28%	<i>Optimalisasi hyperparameter & residual learning.</i>

Keunggulan performa model usulan ini dapat didistribusikan pada dua faktor teknis utama. Pertama, penerapan arsitektur *Residual Network* (ResNet) yang memiliki kedalaman 50 *layer* memungkinkan model untuk menangkap fitur representatif citra paru-paru secara berjenjang, mulai dari tekstur halus hingga anomali patologi yang kompleks. Keberadaan *skip connection* pada ResNet mengatasi masalah *vanishing gradient* yang sering menghambat kinerja model CNN konvensional atau model yang lebih dangkal seperti yang digunakan pada penelitian Raicevic [7]. Kedua, strategi optimasi *hyperparameter* memegang peranan krusial. Berbeda dengan penelitian Gupta dan Sharma [14] yang menggunakan optimizer SGD (*Stochastic Gradient Descent*) standar, penelitian ini menerapkan algoritma Adam dengan parameter yang telah disetel secara presisi melalui metode *grid search*. Kombinasi ini memungkinkan model mencapai titik minimum global pada fungsi kerugian (*loss function*) dengan lebih efisien, menghasilkan konvergensi yang sempurna (akurasi 100%) tanpa terjebak pada *local minima*. Secara keseluruhan, hasil ini membuktikan bahwa integrasi antara pemilihan arsitektur yang tepat (ResNet18) dan strategi *tuning* yang sistematis mampu menghasilkan sistem *Computer Aided Diagnosis* (CAD) yang sangat reliabel untuk membantu tenaga medis dalam skrining awal penyakit Tuberkulosis.

4. KESIMPULAN

Berdasarkan serangkaian eksperimen dan analisis komparatif yang telah dilakukan terhadap arsitektur AlexNet, ZFNet, dan ResNet18 untuk klasifikasi Tuberkulosis pada citra sinar-X dada, penelitian ini menyimpulkan bahwa kedalaman arsitektur jaringan memiliki korelasi positif yang signifikan terhadap performa diagnostik. Model ResNet18 terbukti menjadi arsitektur paling superior dengan pencapaian akurasi 99,28% dan nilai presisi, *recall*, *F1-score* dan AUC-ROC yang mencapai 100% pada data uji, mengungguli AlexNet dan ZFNet yang merupakan arsitektur lebih dangkal. Keberhasilan ResNet18 ini menegaskan efektivitas mekanisme *residual learning* (koneksi *skip*) dalam menangani masalah degradasi gradien pada jaringan dalam, sehingga memungkinkan model untuk mengekstraksi fitur patologi paru-paru yang kompleks dan subtil dengan sangat akurat tanpa mengalami *overfitting*. Selain faktor arsitektur, penerapan strategi optimasi *hyperparameter* menggunakan metode *Grid Search* yang dikombinasikan dengan *K-Fold Cross Validation* terbukti menjadi langkah krusial dalam mencapai konvergensi model yang optimal. Penemuan parameter terbaik, yaitu penggunaan optimizer Adam dengan *learning rate* yang disesuaikan, berhasil meningkatkan stabilitas pelatihan dibandingkan penggunaan parameter *default*. Hal ini menjawab celah penelitian terdahulu yang seringkali mengabaikan proses *tuning* sistematis, sekaligus membuktikan bahwa integrasi antara model *Deep Learning* modern dan teknik optimasi yang tepat dapat menghasilkan sistem *Computer-Aided Diagnosis* (CAD) yang sangat reliabel untuk mendukung tenaga medis dalam skrining awal penyakit Tuberkulosis. Meskipun hasil yang diperoleh sangat memuaskan, penelitian ini masih memiliki keterbatasan pada penggunaan dataset tunggal yang mungkin memiliki karakteristik homogen. Untuk pengembangan selanjutnya, disarankan agar dilakukan validasi eksternal menggunakan dataset dari berbagai rumah sakit atau sumber geografis yang berbeda guna menguji generalisasi model pada variasi kualitas citra rontgen yang lebih beragam. Selain itu, penelitian masa depan dapat berfokus pada implementasi model ke dalam *platform* aplikasi berbasis *mobile* atau *web* yang ringan (*deployment*), serta penambahan fitur *Explainable AI* (seperti Grad-CAM) untuk memvisualisasikan area infeksi pada paru-paru, sehingga hasil prediksi model dapat lebih mudah dipahami dan dipercaya oleh praktisi klinis.

REFERENCES

- [1] Geneva: World Health Organization, "World Health Organization, Global Tuberculosis Report 2023." Accessed: Feb. 18, 2026. [Online]. Available: <https://www.who.int/teams/global-tuberculosis-programme/tb-reports/global-tuberculosis-report-2023>
- [2] J. Estill et al., "Tuberculosis screening among children and adolescents in China: insights from a mathematical model," *Intelligent Medicine*, vol. 3, no. 3, pp. 157–163, Aug. 2023, doi: 10.1016/j.imed.2022.09.001.
- [3] A. Dippenaar et al., "Nanopore Sequencing for Mycobacterium tuberculosis: a Critical Review of the Literature, New Developments, and Future Opportunities," 2022. [Online]. Available: <https://doi.org/10>
- [4] S. Hansun et al., "Diagnostic Performance of Artificial Intelligence–Based Methods for Tuberculosis Detection: Systematic Review," *J. Med. Internet Res.*, vol. 27, 2025, doi: 10.2196/69068.
- [5] F. A. Khan et al., "Chest x-ray analysis with deep learning-based software as a triage test for pulmonary tuberculosis: a prospective study of diagnostic accuracy for culture-confirmed disease," *Lancet Digit. Health*, vol. 2, no. 11, pp. e573–e581, Nov. 2020, doi: 10.1016/S2589-7500(20)30221-1.
- [6] S. Bhowmick, A. Saha, S. Deb, A. De, and A. Srivastava, "Medical Image Classification Using Lightweight Deep Spiking Neural Network," *Iranian Journal of Science and Technology - Transactions of Electrical Engineering*, vol. 49, no. 2, pp. 589–600, Jun. 2025, doi: 10.1007/s40998-025-00808-3.
- [7] M. Raičević, N. Kavarić, T. Popović, D. Babić, and I. Jovović, "Tuberculosis Detection from Chest X- Rays Using Convolutional Neural Network," in 2025 29th International Conference on Information Technology, IT 2025, Institute of Electrical and Electronics Engineers Inc., 2025. doi: 10.1109/IT64745.2025.10930261.

- [8] D. Irfansyah et al., “Arsitektur Convolutional Neural Network (CNN) Alexnet Untuk Klasifikasi Hama Pada Citra Daun Tanaman Kopi,” vol. 6, no. 2, 2021, [Online]. Available: <https://data.mendeley.com/datasets/c5yvn32dzg/2>.
- [9] A. Agarwal, K. Patni, and D. Rajeswari, “Lung Cancer Detection and Classification Based on Alexnet CNN,” in Proceedings of the 6th International Conference on Communication and Electronics Systems, ICCES 2021, Institute of Electrical and Electronics Engineers Inc., Jul. 2021, pp. 1390–1397. doi: 10.1109/ICCES51350.2021.9489033.
- [10] D. R. Aldiansyah and M. Soleh, “Analisa Performa Arsitektur Model Convolutional Neural Network Dengan Variasi Jumlah Hidden Layer Untuk Klasifikasi Tuberculosis Pada Citra X-Ray”, [Online]. Available: <https://www.kaggle.com/datasets/tawsifurrahman/tube>
- [11] B. Falahkhi, E. F. Achmal, M. Rizaldi, R. Rizki, and N. Yudistira, “Perbandingan Model AlexNet dan ResNet dalam Klasifikasi Citra Bunga Memanfaatkan Transfer Learning Comparison of AlexNet and ResNet Models in Flower Image Classification Utilizing Transfer Learning”, [Online]. Available: <http://journal.ipb.ac.id/index.php/jika>
- [12] Ankur, M. Gupta, R. Kumar, and P. Zanke, “A comprehensive Analysis on ResNet-Based Techniques for Brain Tumor Detection,” in Proceedings - 2024 1st International Conference on Technological Innovations and Advance Computing, TIACOMP 2024, Institute of Electrical and Electronics Engineers Inc., 2024, pp. 455–461. doi: 10.1109/TIACOMP64125.2024.00082.
- [13] A. Z. Putra, A. M. Husein, N. Nicholas, F. Wijaya, and A. Aribel, “Comparison of Tuberculosis Detection Using CNN Models (AlexNet and ResNet),” sinkron, vol. 8, no. 4, pp. 2309–2317, Oct. 2024, doi: 10.33395/sinkron.v8i4.13979.
- [14] S. F. Rabby, A. Hasan, Md. J. A. Soeb, G. P. Shirsho, and B. Talukdar, “Performance Analysis of Different Convolutional Neural Network (CNN) Models with Optimizers in Detecting Tuberculosis (TB) from Various Chest X-ray Images,” European Journal of Engineering and Technology Research, vol. 7, no. 4, pp. 21–30, Aug. 2022, doi: 10.24018/ejeng.2022.7.4.2861.
- [15] C. J. Ejiyi et al., “ResfEANet: ResNet-fused External Attention Network for Tuberculosis Diagnosis using Chest X-ray Images,” Computer Methods and Programs in Biomedicine Update, vol. 5, Jan. 2024, doi: 10.1016/j.cmpbup.2023.100133.
- [16] G. Vijaya, K. Ramesh, and G. Sathish Kumar, “ZFNet and deep Maxout network based cancer prediction using gene expression data,” Biomed. Signal Process. Control, vol. 100, Feb. 2025, doi: 10.1016/j.bspc.2024.107038.
- [17] V. Novalia, K. Ditha Tania, A. Meiriza, and A. Wedhasmara, “Knowledge Discovery of Application Review Using Word Embedding’s Comparison with CNN-LSTM Model on Sentiment Analysis,” in ICECOS 2024 - 4th International Conference on Electrical Engineering and Computer Science, Proceeding, Institute of Electrical and Electronics Engineers Inc., 2024, pp. 234–238. doi: 10.1109/ICECOS63900.2024.10791113.
- [18] “Tuberculosis (TB) Chest X-ray Database.” Accessed: Feb. 19, 2026. [Online]. Available: <https://www.kaggle.com/datasets/tawsifurrahman/tuberculosis-tb-chest-xray-dataset/data>
- [19] T. Rahman et al., “Reliable tuberculosis detection using chest X-ray with deep learning, segmentation and visualization,” IEEE Access, vol. 8, pp. 191586–191601, 2020, doi: 10.1109/ACCESS.2020.3031384.
- [20] V. Sharma, Nillmani, S. K. Gupta, and K. K. Shukla, “Deep learning models for tuberculosis detection and infected region visualization in chest X-ray images,” Intelligent Medicine, vol. 4, no. 2, pp. 104–113, May 2024, doi: 10.1016/j.imed.2023.06.001.
- [21] L. D. Wowor, “Implementation of Grid Search Method for Optimization in Convolutional Neural network Model Penerapan Grid Search Method Untuk Optimasi pada Model Convolutional Neural network,” Jurnal Teknik Informatika.