



Penerapan Inception V3 Untuk Deteksi Penyakit Tuberkulosis Berdasarkan Citra Rontgen Dada Melalui Sistem Berbasis Web

Davit Saputra Purba^{1*}, Juliansyah Putra Tanjung¹, Juanda Putra Sinaga¹, Febrianta Tarigan¹, Mhd Allifi Rifqi¹

¹Program Studi Teknik Informatika, Universitas Prima Indonesia, Indonesia.

Artikel Info

Kata Kunci:

Inception V3;
Komputer Vision;
Pembelajaran Mesin;
Sistem Deteksi;
Tuberkolosis.

Keywords:

Inception v3;
Computer vision;
Machine learning;
Sistem detection;
Tuberculosis.

Riwayat Article:

Submitted: 04 Juli 2025
Accepted: 01 Oktober 2025
Published: 01 Oktober 2025

Abstrak: Tuberkulosis (TB) merupakan penyakit menular yang masih menjadi masalah serius di sektor kesehatan, khususnya di Indonesia. Proses diagnosis melalui citra rontgen dada sering mengalami kendala karena keterbatasan jumlah radiolog dan kemiripan visual antara TB dan gangguan paru lainnya. Penelitian ini menerapkan model deep learning dengan arsitektur Inception V3 untuk mendeteksi TB berdasarkan citra rontgen dada. Model dikembangkan dalam sistem berbasis web menggunakan framework Django, sehingga dapat digunakan secara interaktif oleh pengguna. Dataset diambil dari platform Kaggle, terdiri atas 4.200 citra yang terbagi dalam dua kelas, yaitu Normal dan Tuberculosis. Proses fine-tuning dilakukan dengan 30 epoch, learning rate sebesar 0,0001, dan dropout rate 0,5. Model diuji menggunakan confusion matrix untuk menilai performa klasifikasinya. Hasil pelatihan menunjukkan akurasi sebesar 97% dengan loss 0,08, sedangkan pengujian menghasilkan akurasi 98,57%. Nilai precision, recall, dan f1-score rata-rata mencapai 0,99, menunjukkan kemampuan model yang sangat baik dalam membedakan citra paru normal dan terinfeksi TB. Sistem ini diharapkan dapat membantu proses diagnosis awal secara cepat dan akurat, serta menjadi dasar pengembangan teknologi deteksi penyakit berbasis pembelajaran mendalam di bidang medis.

Abstract: *Tuberculosis (TB) is an infectious disease that remains a serious public health concern, particularly in Indonesia. The diagnostic process using chest X-ray images often faces challenges due to the limited number of radiologists and the visual similarity between TB and other pulmonary disorders. This study applies a deep learning model with the Inception V3 architecture to detect TB based on chest X-ray images. The model is developed within a web-based system using the Django framework, allowing interactive use by end-users. The dataset, obtained from the Kaggle platform, consists of 4,200 images divided into two classes: Normal and Tuberculosis. The fine-tuning process was carried out with 30 epochs, a learning rate of 0.0001, and a dropout rate of 0.5. The model was evaluated using a confusion matrix to assess its classification performance. The training phase achieved an accuracy of 97% with a loss value of 0.08, while testing yielded an accuracy of 98.57%. The average precision, recall, and F1-score reached 0.99, indicating excellent model performance in distinguishing between normal and TB-infected lung images. This system is expected to assist in early TB diagnosis efficiently and accurately, as well as to serve as a foundation for the development of deep learning-based disease detection technologies in the medical field.*

Corresponding Author:

Davit Saputra Purba
Email: davidpurba990@gmail.com

PENDAHULUAN

Tuberkulosis (TB) masih menjadi permasalahan kesehatan masyarakat yang signifikan di Indonesia. Berdasarkan data global, Indonesia menempati peringkat kedua tertinggi dalam jumlah kasus TBC setelah India (Kartini, et al., 2024). Paru-paru, sebagai organ utama dalam sistem pernapasan, berperan penting dalam proses pertukaran gas dengan menyimpan oksigen serta menyaring udara yang masuk ke dalam tubuh (Rasyid, et al., 2023). Ketika fungsi paru-paru terganggu akibat kontaminasi atau infeksi, dapat timbul gejala serius seperti kesulitan bernapas dan hemoptisis (Adhanty & Syarif et al., 2023). Salah satu penyebab utama gangguan tersebut adalah penyakit TB paru, yang disebabkan oleh infeksi bakteri *mycobacterium tuberculosis*. Bakteri ini bersifat menular dan dapat menyebar melalui percikan udara atau kontak langsung dengan individu yang terinfeksi (Adhanty, et al., 2023).

Hingga saat ini, TB masih banyak ditemukan di banyak negara, khususnya di Indonesia. Pada tahun 2020-2021 jumlah sampel yang ditemukan sebanyak 8.025 kasus dan tingkat partisipasi sebesar 88,6% (Deviernur & Adnan et al., 2023). Kekurangan ahli radiologi dan peralatan medis, penyakit TB memiliki dampak yang lebih besar di negara-negara dengan beban TB yang tinggi. Deteksi infeksi paru-paru dapat dilakukan melalui pemeriksaan radiologis seperti citra sinar-X, dan kondisi ini umumnya dapat ditangani melalui terapi yang sesuai (Dewi, 2021) (Adzkia, et al., 2022). Meski demikian, terdapat dua tantangan utama mendeteksi TB. Pertama, sulit bagi ahli radiologi membedakan tuberkulosis dan kanker paru-paru karena keduanya terlihat serupa (Aribowo, et al., 2022). Kedua, kurangnya tenaga ahli yang mampu menganalisis data TB. Oleh karena itu, sistem deteksi TB otomatis diperlukan untuk membantu petugas kesehatan mengambil keputusan diagnosis (Achmad, et al., 2023).

Diagnosis TB dapat dilakukan dengan menggunakan Sinar-X, cara ini biasanya digunakan tidak terlalu memakan banyak biaya dan memberikan hasil langsung yang membedakan antara infeksi TB positif dan tidak positif (Nusantara, & Akbar, 2024). Di Indonesia, masih banyak ahli radiologi yang masih belum mampu membaca dan mendiagnosa gambar sinar-X. Kondisi tersebut berpotensi mengakibatkan kesalahan dalam penegakan diagnosis serta menunda pemberian pengobatan yang tepat. Hasil klasifikasi tergantung pada proses segmentasi citra (Raras, et al., 2023). Kebutuhan mendesak untuk mengembangkan sistem otomatis untuk diagnosis TB yang lebih cepat dan akurat (Mutasodirin, et al., 2024).

Inception v3 dikenal karena memungkinkan fitur multiskala melalui konvolusi yang dimodifikasi. Ini dipilih untuk melihat seberapa efektifnya terhadap tekstur yang relatif besar. Inception v3 memiliki layer terstruktur yang mudah mengenali data ekstraksi, dirancang untuk secara otomatis mengidentifikasi fitur-fitur penting dari data citra. Jika dibandingkan dengan arsitektur seperti DenseNet, ResNet, MobileNet dan beberapa lainnya, Inception v3 menunjukkan efisiensi komputasi yang lebih tinggi, baik dalam hal jumlah parameter jaringan yang dihasilkan maupun penggunaan memori dan sumber daya lainnya.

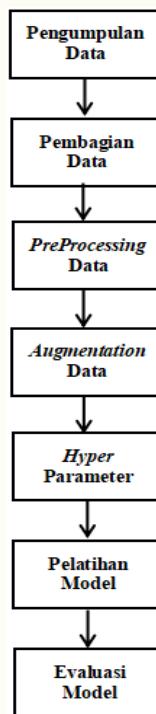
Penelitian terdahulu yang pernah dilakukan oleh (Said, et al., 2021) menggunakan fitur ekstraksi dari fungsi penyaringan GLCM dan GABOR, dengan judul Identifikasi TB Berdasarkan X-Rayografi Dada, dengan rata-rata *accuracy* mencapai 84.82%, *precision* mencapai 86.13%, dan *recall* mencapai 83.48%. Penelitian oleh (Vivin, et al., 2020) Klasifikasi Penyakit TB menggunakan Metode Extreme Learning Machine (ELM) dari hasil laporan matrix menunjukkan hasil akurasi mencapai 99,33%. Data digolongkan menjadi 2 (dua), data pelatihan dan pengujian, dengan rasio 70 banding 30, serta penerapan fungsi aktivasi sigmoid biner. Penelitian oleh (Abidin et al., 2023) berjudul Klasifikasi Penyakit Tuberculosis Menggunakan Metode Naive Bayes, Berdasarkan hasil dan pengujian dengan data latih dan uji 90 banding 10 dengan tibgkat akurasi adalah 87,5%, Sedangkan untuk data latih dan uji rasio 70 banding 30, dengan tingkat akurasi adalah 90,9%. Penelitian oleh (Husen, et al., 2022) memanfaatkan Atribusi Modu dalam penelitiannya, Berdasarkan hasil pengujian bahwa metode SVM mencapai akurasi tertinggi sebesar 92,5%, sedangkan JST dengan akurasi mencapai 91,66%. Namun, saat menerapkan validasi k-fold tingkat akurasi mencapai 85,08%. Studi lain oleh (Rachmadhany, et al., 2024). Yaitu mengidentifikasi Penyakit TB Pada Paru-Paru menggunakan Algoritma K-Means dan Knearest Neighbors Untuk Identifikasi Penyakit TB Pada Paru-Paru, menunjukkan akurasi tertinggi 93%

menggunakan distribusi data latih dan uji rasio 80 banding 20 pada parameter $k = 1$. Penelitian yang sudah diuraikan diatas, pada penelitian ini akan melakukan pengolahan gambar untuk mendeteksi tuberculosis menggunakan model inception v3. Dengan demikian, hasilnya akan lebih objektif dibandingkan dengan survei yang dilakukan, karena berdasarkan review penelitian terkait, arsitektur inception v3 belum diterapkan untuk klasifikasi gambar rontgen dada.

Tujuan penelitian ini adalah merancang sistem deteksi TB otomatis berbasis pembelajaran mendalam yang dapat diakses melalui platform web. Sistem tersebut dirancang untuk mempercepat proses diagnosis sekaligus meningkatkan akurasi deteksi TB. Selain itu, penelitian ini melakukan evaluasi terhadap kinerja arsitektur InceptionV3 dalam klasifikasi citra rontgen dada guna mendukung identifikasi penyakit tersebut.

METODE

Pada penelitian ini ada beberapa tahapan yang dilakukan, terdiri dari, pengumpulan data, pembagian data, *pre-processing* data, *augmentation* data, *hyper* parameter, pelatihan model, dan evaluasi model.



Gambar 1. Alur tahapan penelitian

Pengumpulan Data

Dataset yang digunakan dalam penelitian ini diperoleh dari platform Kaggle, yang menyediakan basis data gambar rontgen dada sesuai dengan kebutuhan studi. Data tersebut terbagi ke dalam dua kategori utama, yaitu Normal dan TB. Pelabelan dilakukan dengan mengelompokkan gambar ke dalam folder berdasarkan kategori masing-masing, terdiri dari sekitar 3.500 gambar untuk kategori Normal dan 700 gambar untuk kategori TB. Total keseluruhan dataset mencapai 4.200 gambar.

Pembagian Data

Data yang telah diberi label diklasifikasikan ke dalam tiga subset, yaitu pelatihan, validasi, dan pengujian, dengan pembagian dilakukan secara manual berdasarkan rasio 80:10:10. Untuk kategori normal, masing-masing subset terdiri atas 2.800 citra untuk pelatihan, 350 untuk validasi, dan 350 untuk pengujian. Sementara itu, kategori TB mencakup 560 citra pelatihan, 70 validasi, dan 70 pengujian. Proporsi ini dirancang untuk memberikan ruang pembelajaran yang memadai bagi model Inception

V3, dengan dominasi data pelatihan guna memperkuat kemampuan model dalam mengenali pola. Dataset validasi digunakan untuk memantau performa model selama proses pelatihan, sedangkan dataset pengujian difungsikan pada tahap akhir guna mengukur kemampuan generalisasi terhadap data yang belum pernah diakses sebelumnya.

PreProcessing Data

Dalam penelitian ini, model deep learning Inception V3 digunakan untuk tugas klasifikasi citra. Sebelum citra dapat digunakan sebagai input, diperlukan serangkaian tahap praproses agar data sesuai dengan spesifikasi model (Azam, & Darujati, 2022). Tahapan ini mencakup beberapa langkah utama.

1. Setiap citra dalam dataset yang telah dilabeli diubah ukurannya menjadi 224×224 piksel, sesuai dengan ukuran input standar yang diterima oleh arsitektur InceptionV3. Penyesuaian ini penting karena model yang telah dilatih sebelumnya hanya dapat menerima input dalam resolusi tersebut.
2. Citra dikonversi menjadi array NumPy berdimensi tiga, yang memungkinkan representasi numerik untuk diproses lebih lanjut oleh TensorFlow. Ketiga, dimensi batch ditambahkan untuk membentuk array berdimensi empat, sesuai dengan format input yang digunakan dalam pelatihan dan inferensi oleh TensorFlow, bahkan ketika hanya satu citra yang diolah.
3. Normalisasi dilakukan dengan mengubah skala nilai piksel dari rentang $[0, 255]$ menjadi $[-1, 1]$, agar sesuai dengan skema pra-pelatihan model. Transformasi ini esensial untuk menjaga konsistensi distribusi input dan meningkatkan kemampuan model dalam mengekstraksi fitur, karena model telah dibiasakan terhadap pola data yang diolah dalam skala tersebut.

Augmentation Data

Augmentasi data merupakan komponen krusial dalam pemrosesan citra yang bertujuan memperluas variasi data serta memitigasi risiko overfitting (Sanjaya, et al., 2020). Prosedur ini mencakup berbagai transformasi terhadap citra asli, seperti rotasi, pencerminan (flipping), perbesaran (zooming), translasi, serta penyesuaian kontras dan pencahayaan. Transformasi tersebut digunakan untuk mensimulasikan variasi kondisi visual yang mungkin muncul dalam situasi nyata. Dengan menyediakan representasi fitur yang lebih beragam, augmentasi meningkatkan kemampuan generalisasi model terhadap data yang sebelumnya tidak dikenal. Pendekatan ini menjadi semakin penting ketika dataset berskala kecil atau menunjukkan ketidakseimbangan distribusi kelas. Selain itu, augmentasi memperkuat ketahanan model dalam mengenali objek yang sama dalam berbagai kondisi pencahayaan, orientasi, atau posisi. Dalam penelitian ini, augmentasi diterapkan sebelum proses pelatihan, dengan tujuan memperluas jumlah data latih serta meningkatkan robustitas model dalam mengenali pola visual yang bervariasi.

HyperParameter

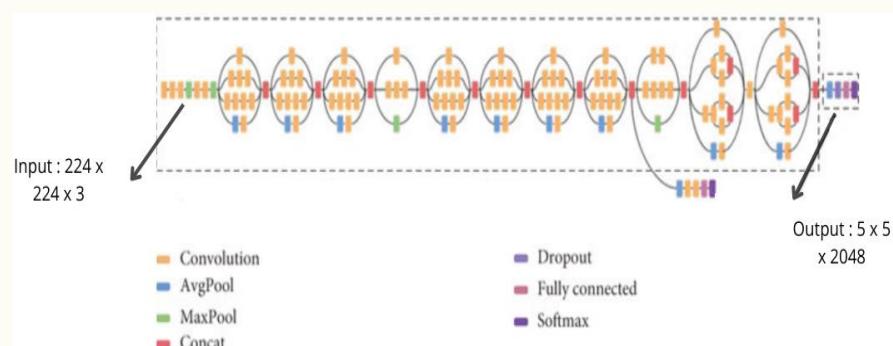
Tahap ini dilakukan sebelum proses pelatihan dimulai dan tidak mengalami perubahan selama pelatihan berlangsung. Penentuan nilai hyperparameter yang optimal merupakan aspek penting dalam pengembangan model, karena berdampak langsung terhadap performa akhir, baik dalam hal akurasi maupun kecepatan konvergensi. Pemilihan kombinasi hyperparameter didasarkan pada hasil evaluasi terhadap data validasi, dengan tujuan untuk memperoleh model yang tidak hanya memiliki performa baik pada data pelatihan, tetapi juga mampu mempertahankan akurasi yang tinggi terhadap data yang belum pernah diakses sebelumnya. Rincian nilai hyperparameter yang digunakan dalam penelitian ini disajikan pada Tabel 1.

Tabel 1. Nilai parameter model

Label	Parameter
Optimizer	Adam
Learning Rate	0.00001
Dropout Rate	0.5
Dense	1024
Epoch	30

Pelatihan Model

Pengembangan model *machine learning* dan *deep learning* dalam penelitian ini memanfaatkan berbagai pustaka Python, seperti TensorFlow, Pandas, NumPy, OpenCV, dan Scikit-learn. Dengan menggunakan pustaka tersebut, proses perancangan model dapat dilakukan secara efisien melalui penyesuaian parameter tertentu, seperti jenis *optimizer*, jumlah *epoch*, serta konfigurasi dataset. Tujuan utama pelatihan adalah untuk mempelajari karakteristik data dan mengelompokkannya sesuai dengan label kelas yang tersedia. Arsitektur yang digunakan dalam pelatihan adalah Inception-v3, salah satu varian *Convolutional Neural Network* (CNN) yang dikembangkan oleh Google. Arsitektur ini merupakan pengembangan dari versi Inception sebelumnya dengan peningkatan efisiensi komputasi dan akurasi klasifikasi. Model menerima citra masukan berukuran $224 \times 224 \times 3$ (tinggi \times lebar \times kanal warna) dan menghasilkan keluaran dengan dimensi $5 \times 5 \times 2048$. Keluaran ini kemudian diteruskan ke lapisan *fully connected* dan *softmax* untuk proses klasifikasi akhir. Struktur internal model terdiri atas beberapa blok konvolusi dan modul Inception yang saling terintegrasi, membentuk fondasi utama dari arsitektur ini. Visualisasi arsitektur Inception-v3 disajikan pada Gambar 2.



Gambar 2. Model arsitektur v3 (Ramaneswaran, et al., 2021)

Berikut ini adalah penjelasan dari lapisan-lapisan yang di gunakan dalam model inception v3.

1. Convolution

Convolution adalah proses inti dalam jaringan saraf konvolusional (CNN) yang berfungsi untuk mengekstraksi fitur penting dari citra input, seperti tepi, pola, atau tekstur. Proses ini dilakukan dengan menggeser sebuah filter (kernel) ke seluruh area citra dan menghitung hasil perkalian antara nilai-nilai piksel dan bobot filter tersebut. Proses ini menghasilkan peta fitur (feature map) yang merepresentasikan informasi lokal dari citra.

2. Average Pooling

Average pooling merupakan teknik pengurangan dimensi data yang bertujuan untuk merangkum informasi dari area tertentu dalam citra dengan menghitung nilai rata-rata dari setiap blok piksel. Teknik ini membantu menyederhanakan data sambil mempertahankan informasi penting, serta mengurangi kompleksitas perhitungan pada lapisan-lapisan berikutnya.

3. Max Pooling

Max pooling adalah metode penyederhanaan data dengan cara memilih nilai terbesar dari suatu wilayah kecil dalam peta fitur. Dengan cara ini, hanya informasi paling menonjol dari area tersebut yang dipertahankan, sehingga model menjadi lebih fokus terhadap fitur-fitur dominan dan mengurangi sensitivitas terhadap gangguan atau noise.

4. Concatenate

Operasi concatenate digunakan untuk menggabungkan dua atau lebih peta fitur atau tensor menjadi satu, baik secara horizontal maupun vertikal, tergantung pada dimensi yang ditentukan. Proses ini berguna untuk menggabungkan informasi dari beberapa jalur atau lapisan yang berbeda dalam arsitektur jaringan, sehingga model memperoleh representasi fitur yang lebih kaya dan beragam.

5. Dropout

Dropout adalah metode regularisasi yang digunakan selama pelatihan untuk menghindari model menjadi terlalu menghafal data (*overfitting*). Teknik ini dilakukan dengan cara menonaktifkan secara acak sejumlah neuron dalam suatu lapisan selama satu kali iterasi pelatihan, sehingga model belajar untuk tidak bergantung pada satu jalur spesifik dalam jaringan.

6. Fully Connected Layer

fully connected, atau lapisan terhubung penuh, adalah bagian dari jaringan saraf di mana setiap neuron terhubung ke seluruh neuron di lapisan sebelumnya. Lapisan ini biasanya digunakan pada tahap akhir model, dan berfungsi untuk mengintegrasikan semua iterasi yang telah diekstraksi sebelumnya menjadi representasi akhir yang siap untuk diklasifikasikan.

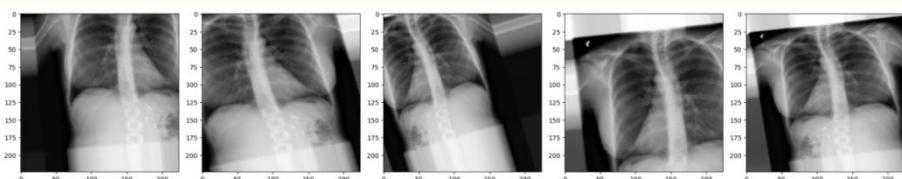
7. Softmax

Softmax adalah aktivasi yang digunakan pada lapisan output untuk mengubah skor akhir dari model menjadi bentuk probabilitas. Fungsi ini membandingkan nilai-nilai output dan mengonversinya menjadi persentase kemungkinan untuk masing-masing kelas, sehingga totalnya menjadi 1. Kelas dengan nilai tertinggi akan dianggap sebagai prediksi utama dari model.

HASIL DAN PEMBAHASAN

Hasil *Augmentation*

Proses augmentasi yang diterapkan menghasilkan peningkatan variasi visual pada dataset. Citra yang semula homogen mengalami transformasi dalam aspek pencahayaan, sudut rotasi, skala, serta orientasi baik secara horizontal maupun vertikal. Variasi ini mencerminkan kondisi realistik citra medis, yang umumnya memiliki perbedaan dalam sudut pengambilan gambar dan kualitas visual. Dengan demikian, augmentasi memungkinkan model untuk belajar dari beragam representasi fitur, sehingga tidak terbatas pada pola citra statis. Model yang dilatih menggunakan data hasil augmentasi memiliki kemampuan yang lebih baik dalam mengenali fitur penting meskipun terjadi perubahan posisi atau pencahayaan objek. Hal ini berdampak langsung pada peningkatan generalisasi model terhadap data uji maupun data baru. Selain itu, augmentasi berkontribusi signifikan dalam menekan risiko *overfitting*, yaitu kondisi ketika model hanya menunjukkan performa tinggi pada data pelatihan, tetapi gagal melakukan klasifikasi yang akurat terhadap data yang belum pernah dikenali. Dalam konteks penelitian ini, augmentasi dilakukan untuk memperluas jumlah sampel secara efisien tanpa memerlukan penambahan data baru. Pendekatan ini sangat relevan, terutama ketika jumlah data asli terbatas. Hasil dari proses augmentasi memperkaya representasi data sekaligus meningkatkan ketahanan model terhadap variasi citra pada lingkungan nyata. Contoh visual dari hasil augmentasi ditampilkan pada Gambar 3.

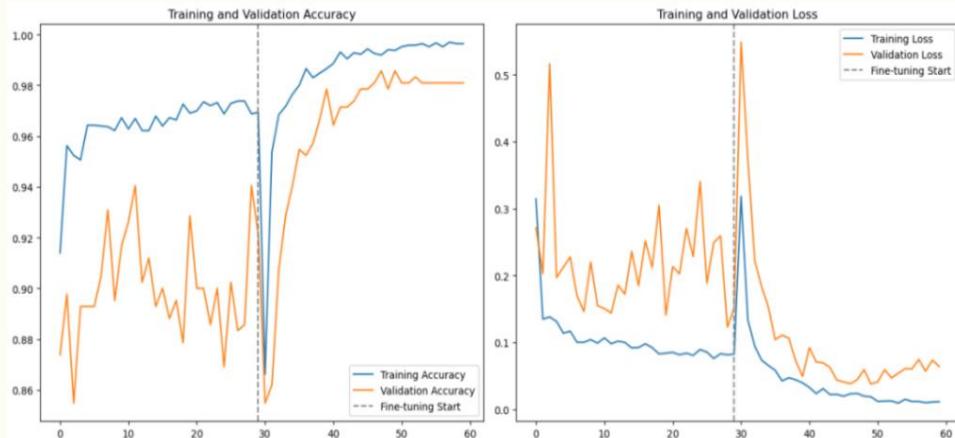


Gambar 3. Beberapa hasil setelah *augmentation*

Hasil Pengujian Model

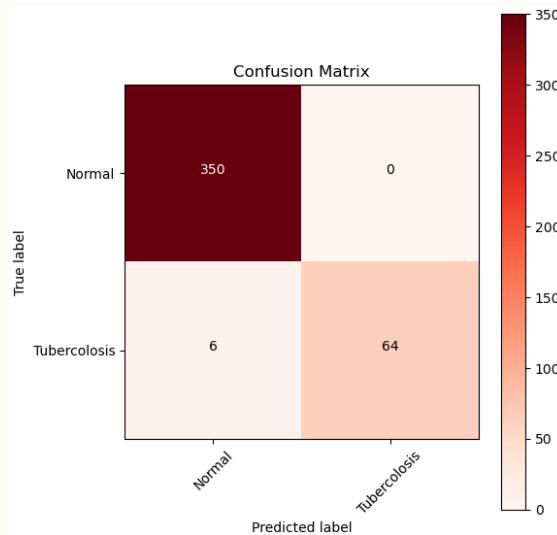
Model dilatih selama 30 *epoch* dengan menggunakan algoritma optimasi Adam. Pemilihan *optimizer* ini didasarkan pada kemampuannya dalam mempercepat proses konvergensi serta meningkatkan stabilitas selama pelatihan. Adam secara adaptif menyesuaikan laju pembelajaran untuk setiap parameter, sehingga dapat menangani gradien yang bervariasi secara efisien. Visualisasi hasil pelatihan disajikan dalam bentuk grafik yang menunjukkan tren akurasi dan *loss* pada data pelatihan

dan validasi selama proses pelatihan berlangsung. Grafik ini memberikan gambaran mengenai performa model serta kestabilan selama proses pembelajaran pada setiap epoch.



Gambar 4. Grafik validasi akurasi dan validasi loss

Seperti ditunjukkan pada Gambar 4, akurasi validasi mengalami peningkatan yang signifikan setelah diterapkannya proses *fine-tuning*, dengan akurasi pelatihan mencapai 97% dan nilai *loss* validasi sebesar 0,08. Hasil ini menunjukkan bahwa model semakin mampu melakukan prediksi citra dengan tingkat ketepatan yang tinggi. Penurunan nilai *loss* validasi secara konsisten disertai dengan peningkatan akurasi mengindikasikan bahwa model tidak hanya belajar dengan efektif, tetapi juga mempertahankan kemampuan generalisasi terhadap data yang belum pernah dilihat sebelumnya. Setelah proses pelatihan dan pengujian selesai dilakukan, langkah evaluasi selanjutnya adalah menilai performa klasifikasi model menggunakan *confusion matrix*. Matriks ini memberikan informasi rinci mengenai jumlah prediksi yang benar dan salah untuk masing-masing kelas, serta membantu dalam mengidentifikasi potensi kesalahan klasifikasi. Hasil *confusion matrix* untuk model Inception V3 disajikan pada Gambar 5.



Gambar 5. *Confusion Matrix*

Evaluasi Model

Penelitian ini menyajikan evaluasi kinerja model melalui laporan metrik utama yang mencakup *loss* dan akurasi pada data pelatihan. Laporan ini menggambarkan tingkat kesalahan yang terjadi selama proses pelatihan dan pengujian. Evaluasi performa model Inception V3 dilakukan menggunakan metrik *precision*, *recall*, *f1-score*, dan *support* dapat dilihat pada Gambar 6.

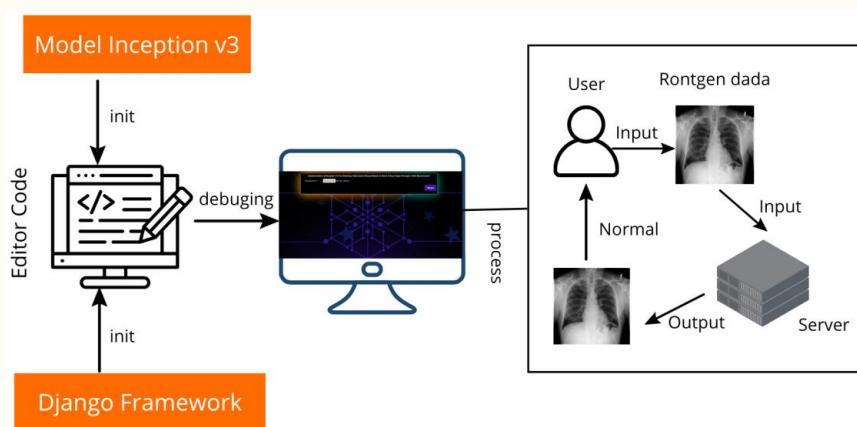
Classification Report:				
	precision	recall	f1-score	support
Normal	0.98	1.00	0.99	350
Tuberculosis	1.00	0.91	0.96	70
accuracy			0.99	420
macro avg	0.99	0.96	0.97	420
weighted avg	0.99	0.99	0.99	420

Gambar 6. Hasil klasifikasi model Inception V3

Gambar 6 menunjukkan bahwa model memiliki tingkat *precision* tinggi pada seluruh kelas, yaitu 0,98 untuk kategori normal dan 1,00 untuk tuberculosis. Nilai *recall*, yang mengukur kemampuan model dalam mendekripsi seluruh sampel positif, juga tinggi, yakni 1,00 untuk normal dan 0,91 untuk tuberculosis. F1-score, sebagai rata-rata harmonis dari *precision* dan *recall*, menunjukkan kinerja seimbang dengan nilai 0,99 untuk normal dan 0,96 untuk tuberculosis. Support mencerminkan jumlah data aktual pada setiap kelas, yaitu 350 untuk normal dan 70 untuk tuberculosis. Secara umum, model ini memperoleh akurasi f1-score sebesar 0,99. Rata-rata makro untuk *precision*, *recall*, dan *f1-score* masing-masing adalah 0,99; 0,96; dan 0,97. Sementara itu, rata-rata tertimbang (weighted average) untuk ketiga metrik tersebut adalah 0,99. Hasil ini mencerminkan performa yang sangat baik dalam klasifikasi citra pada seluruh kategori, dengan tingkat kesalahan yang minimal. Nilai-nilai akurasi, *recall*, *precision*, dan *f1-score* dari model Inception V3 disajikan pada Gambar 6.

Integrasi Model

Kode editor yang digunakan dalam proses pengembangan aplikasi web ini adalah Visual Studio Code (VSC), karena menyediakan integrasi yang baik dengan Python, Django, serta terminal untuk menjalankan server dan mengelola virtual environment. Integrasi dilakukan dengan menempatkan file model ke dalam struktur folder proyek Django, serta menambahkan endpoint dan fungsi backend yang dapat memproses gambar yang diunggah pengguna. Proses integrasi model dengan website dapat dilihat pada Gambar 7, yang menggambarkan alur penggabungan antara model deteksi citra berbasis Inception V3 dengan arsitektur Django. Model deep learning yang telah dilatih dan diuji sebelumnya disimpan dalam format .h5, kemudian dimuat ke dalam sistem menggunakan pustaka TensorFlow/Keras untuk digunakan dalam inferensi langsung pada server web.

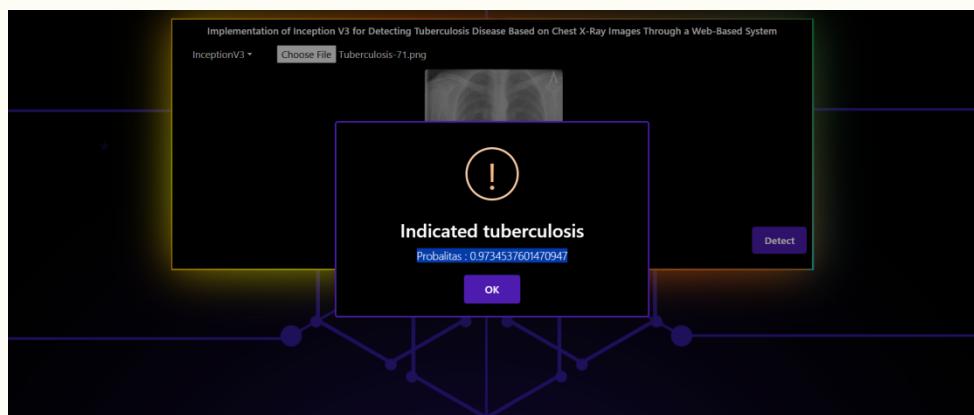


Gambar 7. Alur Integrasi Sistem

Situs web yang dibangun bertujuan sebagai antarmuka interaktif bagi pengguna untuk mengunggah gambar melalui form input file, lalu menerima hasil deteksi secara langsung pada halaman hasil. Contoh tampilan form input gambar dan hasil deteksi dapat dilihat pada Gambar 8 dan Gambar 9. Dengan integrasi ini, sistem tidak hanya berjalan pada level eksperimen model, tetapi juga memberikan kemudahan akses dan penggunaan oleh end-user melalui antarmuka web yang ramah pengguna.



Gambar 8. Input file gambar citra rontgen dada



Gambar 9. Output deteksi pada gambar citra rontgen dada.

KESIMPULAN

Penelitian ini merancang sebuah sistem deteksi penyakit TB berdasarkan citra rontgen dada dengan memanfaatkan arsitektur Inception V3. Sistem yang dikembangkan berfungsi sebagai alat bantu dalam proses diagnosis awal, yang berpotensi meningkatkan efisiensi skrining penyakit TB. Hasil evaluasi menunjukkan bahwa penerapan arsitektur Inception V3 mampu memberikan performa klasifikasi yang baik terhadap dua kategori, yaitu normal dan *tuberculosis*, berdasarkan citra paru-paru. Model mencapai akurasi pelatihan sebesar 0,97 dan nilai *loss* validasi sebesar 0,08. Hasil ini diperoleh setelah dilakukan fine-tuning terhadap model dasar, dengan menggunakan parameter terbaik, yakni *optimizer* Adam, 30 *epoch*, *learning rate* sebesar 0.00001, dan *dropout* sebesar 0,5. Untuk pengembangan penelitian selanjutnya, disarankan agar dilakukan perbandingan langsung dengan arsitektur lain seperti ResNet, DenseNet, maupun model hybrid (misalnya Inception + XGBoost) guna memperoleh evaluasi performa yang lebih komprehensif. Selain itu, perlu diperhatikan distribusi kelas dalam dataset, terutama ketika terdapat ketimpangan signifikan seperti 3.500 citra kategori normal dibandingkan dengan 700 citra *tuberculosis*. Ketidakseimbangan ini berpotensi menimbulkan bias dalam proses pelatihan model. Oleh karena itu, strategi penyeimbangan kelas seperti SMOTE (Synthetic Minority Over-sampling Technique), class reweighting, atau balanced sampling direkomendasikan guna meningkatkan performa klasifikasi serta kemampuan generalisasi model terhadap kelas minoritas.

DAFTAR PUSTAKA

- Abidin, A. A., Goejantoro, R., & Fathurahman, M. (2023). Klasifikasi Penyakit Tuberkulosis Menggunakan Metode Naive Bayes (Studi Kasus: Data Pasien Di Puskesmas Petung Kabupaten Penajam Paser Utara). *Eksponensial*, 14(1), 11. <https://doi.org/10.30872/ekspresional.v14i1.1031>.
- Achmad, W. H., Saurina, N., Chamidah, N., & Rulaningtyas, R. (2023). Pemodela Klasifikasi Tuberkulosis dengan Convolutional Neural Network. *Prosiding Seminar Implementasi Teknologi Informasi Dan Komunikasi*, 2(1), 9-15.
- Adhanty, S., & Syarif, S. (2023). Kepatuhan Pengobatan pada Pasien Tuberkulosis dan Faktor-Faktor yang Mempengaruhinya: Tinjauan Sistematis. *Jurnal Epidemiologi Kesehatan Masyarakat*, 6(1), 6-14. <https://doi.org/10.7454/epidkes.v7i1.6571>.
- Adzkia, M., Arland, F., & Setiawan, A. W. (2022). Deteksi Pneumonia Menggunakan Citra Sinar-X Paru berbasis Residual Network. *Jurnal Teknologi Informasi Dan Ilmu Komputer*, 9(2), 373-380. <https://doi.org/10.25126/jtiik.2022925626>.
- Aribowo, K., Medison, I., Mizarti, D., & Fitriana, D. W. (2022). Co-Existence Of Tuberculosis And Lung Cancer. *MAGNA MEDICA Berkala Ilmiah Kedokteran Dan Kesehatan*, 9(1), 51-61. <https://doi.org/10.26714/magnamed.9.1.2022.51-61>.
- Azam, M. N. A., & Darujati, C. (2022). Pengenalan Citra Wajah Frontal Menggunakan Hirarkikal Klaster berbasis Deep Learning Inception V3. *JREC (Journal of Electrical and Electronics)*, 9(2), 9-13. <https://doi.org/10.33558/jrec.v9i2.3187>.
- Deviernur, S. M., & Adnan, N. (2023). Analisis Survival: Hubungan Konversi Sputum Dengan Keberhasilan Pengobatan Pasien Tuberkulosis Resistan Obat Di Indonesia. *Jurnal Epidemiologi Kesehatan Masyarakat*, 7(1), 43-50. <https://doi.org/10.7454/epidkes.v7i1.6955>.
- Dewi, S. W. (2021). Upaya Pengendalian Tuberkulosis dengan Meningkatkan Kepatuhan Minum Obat Anti Tuberkulosis. *Media Kesehatan Masyarakat Indonesia*, 20(3), 200-205.
- Husen, A. H., Nur Afiah, A.S., Soesanti, S., & Tempola, F. (2022). Deteksi Dini Resiko Tuberkulosis di Kota Ternate: Pelacakan dan Implementasi Algoritma Klasifikasi. *Jurnal CoSciTech (Computer Science and Information Technology)*, 3(2), 217-225. <https://doi.org/10.37859/coscitech.v3i2.3986>.
- Kartini, P. R., Norachuriya, Z., Novitasari, K. S., Shintawati, S., & Wisnubroto, A. P. (2024). Kajian Perilaku Kepatuhan Medikasi Pasien Tuberculosis Paru di Kabupaten Ngawi: Sebuah Model Matematis. *Jurnal Epidemiologi Kesehatan Komunitas*, 9(2), 160-169. <https://doi.org/10.14710/jekk.v9i2.20982>.
- Mutasodirin, M. A., & Falakh, F. M. (2024). Efficient Weather Classification Using DenseNet and EfficientNet. *Jurnal Informatika: Jurnal Pengembangan IT*, 9(2), 173-179. <https://doi.org/10.30591/jpit.v9i2.7539>.
- Nurdiansyah, V. V., Cholissodin, I., & Adikara, P. P. (2020). Klasifikasi Penyakit Tuberkulosis (TB) menggunakan Metode Extreme Learning Machine (ELM). *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, 4(5), 1387-1393. <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/7237>.
- Nusantara, B. S., & Akbar, M. (2024). Klasifikasi Penyakit Tuberculosis Berdasarkan Citra Rontgen Thorax Menggunakan Multi-Scale Convolutional Neural Network. *Sudo Jurnal Teknik Informatika*, 3(1), 1-8. <https://doi.org/10.56211/sudo.v3i1.483>.
- Putri, F. N. R., Wibowo, N. C. H., & Mustofa, H. (2023). Clustering of Tuberculosis and Normal Lungs Based on Image Segmentation Results of Chan-Vese and Canny with K-Means. *Indonesian*

- Journal of Artificial Intelligence and Data Mining*, 6(1), 18-28.
<https://doi.org/10.24014/ijaidm.v6i1.21835>.
- Rasyid, A., & Heryawan, L. (2023). Klasifikasi Penyakit Tuberculosis (TB) Organ Paru Manusia Berdasarkan Citra Rontgen Thorax Menggunakan Metode Convolutional Neural Network (CNN). *Jurnal Manajemen Informasi Kesehatan Indonesia (JMIKI)*, 11(1), 35-44. <https://doi.org/10.33560/jmiki.v11i1.484>.
- Rachmadhany Iman, Basuki Rahmat, & Achmad Junaidi. (2024). Implementasi Algoritma K-Means dan Knearest Neighbors (KNN) Untuk Identifikasi Penyakit Tuberkulosis Pada Paru-paru. *Repeater: Publikasi Teknik Informatika Dan Jaringan*, 2(3), 12–25. <https://doi.org/10.62951/repeater.v2i3.77>.
- Ramaneswaran, S., Srinivasan, K., Vincent, P. M. D. R., & Chang, C. (2021). Hybrid Inception v3 XGBoost Model for Acute Lymphoblastic Leukemia Classification. *Computational and Mathematical Methods in Medicine*, 2021, 1–10. <https://doi.org/10.1155/2021/2577375>.
- Raras, C., Setiawan, P. ., & Komarasary, D. (2023). Pengaruh Segmentasi terhadap Diagnosis COVID-19 pada Citra X-Ray Paru. *CogITo Smart Journal*, 9(1), 171–180. <https://doi.org/10.31154/cogito.v9i1.471.171-180>.
- Said, Q., Ernawati, I., & Santoni, M. M. (2021). Identifikasi Tuberkulosis Paru Berdasarkan Foto Sinar-X Thorax Menggunakan Jaringan Syaraf Tiruan Backpropagation. *Informatik Jurnal Ilmu Komputer*, 17(1), 27-37. <https://doi.org/10.52958/iftk.v17i1.2222>.
- Sanjaya, J., & Ayub, M. (2020). Augmentasi Data Pengenalan Citra Mobil Menggunakan Pendekatan Random Crop, Rotate, dan Mixup. *Jurnal Teknik Informatika Dan Sistem Informasi*, 6(2), 311-323. <https://doi.org/10.28932/jutisi.v6i2.2688>