PENGEMBANGAN APLIKASI BERBASIS WEBSITE DETEKSI PENYAKIT PARU-PARU MENGGUNAKAN METODE TRANSFER LEARNING DENGAN ARSITEKTUR DENSENET-169

Muhammad Rizky Sandyra[1], Ahmaddul Hadi[2], Dony Novaliendry[3], Yeka Hendriyani[4] Irvan Medison[5]

[1,2,3,4]*Universitas Negeri Padang*
E-mail : MuhammadRizkyS@student.unp.ac.id

ABSTRAK

Penelitian ini dilatarbelakangi oleh kebutuhan akan sistem pendeteksi penyakit paru-paru berbasis kecerdasan buatan yang mampu menggabungkan informasi dari citra X-ray dada dan gejala klinis pasien secara simultan. Tujuan dari penelitian ini adalah mengembangkan sistem diagnosis otomatis menggunakan pendekatan multimodal berbasis model deep learning DenseNet-169 yang dilatih dengan teknik two-phase training, yaitu pretraining dan fine-tuning, serta mengevaluasi performa model menggunakan metrik Area Under Curve (AUC) dengan target minimal 0.7 agar hasil diagnosis dapat diandalkan dalam konteks medis. Jenis penelitian ini merupakan penelitian rekayasa perangkat lunak dengan pendekatan kuantitatif. Model dilatih menggunakan dataset citra X-ray publik yang berisi 11 label penyakit paru-paru, serta data tambahan berupa 13 jenis gejala klinis. Sistem diimplementasikan dalam bentuk aplikasi web berbasis Laravel dan Flask, yang memungkinkan pengguna mengunggah gambar X-ray serta memilih gejala klinis untuk mendapatkan hasil diagnosis berbentuk prediksi penyakit beserta tingkat probabilitasnya. Evaluasi internal dilakukan melalui pengujian fungsionalitas sistem dan uji interpretasi terhadap empat sampel kasus uji. Hasil evaluasi menunjukkan bahwa sistem dapat memberikan output diagnosis yang bervariasi dan responsif terhadap kombinasi input gejala dan citra, dengan nilai AUC model mencapai 0.7586, melampaui ambang batas minimal AUC sebesar 0.7. Dapat disimpulkan bahwa sistem diagnosis penyakit paru-paru yang dikembangkan dalam penelitian ini telah berhasil mengintegrasikan data multimodal dan menghasilkan prediksi yang informatif, serta menunjukkan potensi untuk dikembangkan lebih lanjut dalam konteks medis digital.

Kata Kunci : *Diagnosis Paru-Paru, Model Multimodal, DenseNet-169, Two-Phase Training, Citra X-ray, Gejala Klinis.*

PENDAHULUAN

Penyakit paru-paru merupakan salah satu masalah kesehatan global yang memerlukan deteksi dini untuk mengurangi dampaknya. Salah satu metode diagnostik yang umum digunakan adalah analisis citra X-ray dada. Namun, interpretasi manual oleh radiolog memiliki keterbatasan, seperti waktu yang lama dan potensi kesalahan subjektif (Amir et al., 2023). Teknologi saat ini belum sepenuhnya mampu mengatasi masalah ini secara efisien.

Di Indonesia, fasilitas kesehatan seringkali kekurangan tenaga ahli radiologi untuk menganalisis citra X-ray secara cepat dan akurat (Jawaz & Rahmadewi, 2024). Hal ini menyebabkan penundaan diagnosis dan penanganan pasien, terutama di daerah terpencil. Kurangnya teknologi yang dapat membantu interpretasi citra X-ray menjadi tantangan utama. Solusi berbasis kecerdasan buatan (AI) dapat menjadi jawaban untuk masalah ini.

Dataset NIH Chest X-ray merupakan salah satu dataset publik terbesar yang berisi 112.120 citra X-ray dengan 14 label penyakit. Dataset ini sangat relevan untuk penelitian karena menyediakan citra X-ray berkualitas tinggi dengan variasi kondisi paru-paru yang beragam. Namun, untuk meningkatkan akurasi diagnosis dan relevansi klinis, penelitian ini menggunakan pendekatan pelabelan manual yang dilakukan dengan supervisi dokter spesialis paru-paru. Pendekatan ini memastikan standar medis yang lebih tinggi dibandingkan pelabelan otomatis berbasis Natural Language Processing (NLP) yang memiliki tingkat kesalahan lebih besar (Wang et al., 2019).

Analisis citra X-ray secara manual memerlukan waktu yang lama dan keahlian khusus. Radiolog seringkali mengalami kelelahan saat harus menganalisis banyak citra dalam waktu singkat (Muller et al., 2020). Hal ini dapat mengurangi akurasi diagnosis dan memperlambat proses perawatan. Teknologi yang dapat membantu interpretasi citra X-ray secara otomatis sangat dibutuhkan.

Deep learning, khususnya transfer learning, telah menunjukkan potensi besar dalam analisis citra medis (Alzubaidi et al., 2021). Model yang telah dilatih pada dataset besar seperti ImageNet dapat diadaptasi untuk tugas spesifik seperti deteksi penyakit paru-paru. Pendekatan ini memungkinkan peningkatan akurasi dan efisiensi dalam diagnosis. Namun, implementasinya masih menghadapi beberapa tantangan.

Salah satu tantangan utama adalah kurangnya dataset yang besar dan berkualitas untuk melatih model deep learning (Samidin & Fadjeri, 2024). Dataset yang tersedia seringkali memiliki ketidakseimbangan kelas dan kesalahan label. Hal ini dapat memengaruhi performa model dalam mendeteksi penyakit. Preprocessing dan augmentasi data diperlukan untuk mengatasi masalah ini.

Arsitektur DenseNet-169 dipilih dalam penelitian ini karena kemampuannya dalam mengekstrak fitur dari citra medis. Arsitektur ini memiliki konektivitas yang padat antar lapisan, sehingga mengurangi risiko vanishing gradient. DenseNet-169 juga telah terbukti efektif dalam tugas klasifikasi citra medis (Kalpana et al., 2022). Penggunaan transfer learning dengan arsitektur ini diharapkan dapat meningkatkan akurasi deteksi.

Integrasi informasi gejala klinis dengan analisis citra radiologis merupakan pendekatan komprehensif dalam diagnosis penyakit paru-paru. Gejala seperti batuk, sesak napas, nyeri dada, dan demam memberikan konteks penting yang dapat meningkatkan akurasi interpretasi hasil X-ray. Kombinasi antara temuan radiologis dan manifestasi klinis terbukti memberikan prediksi klinis yang lebih baik dibandingkan analisis citra saja, sehingga dapat mengurangi risiko false positive maupun false negative dalam deteksi penyakit paru-paru (Homayounieh et al., 2020).

Pendekatan holistik ini sangat penting dalam praktik klinis, di mana dokter selalu mempertimbangkan kondisi pasien secara menyeluruh, termasuk keluhan dan hasil pemeriksaan penunjang.

Sistem yang dikembangkan dalam penelitian ini bertujuan untuk memudahkan tenaga medis dalam menganalisis citra X-ray. Website sederhana akan diintegrasikan dengan model deep learning untuk memberikan hasil diagnosis secara cepat. Pengguna dapat mengunggah citra X-ray dan mendapatkan prediksi penyakit dalam waktu singkat. Sistem ini diharapkan dapat mengurangi beban kerja radiolog.

Permasalahan teknologi dalam analisis citra X-ray juga mencakup kurangnya alat yang dapat memberikan interpretasi otomatis. Radiolog seringkali harus mengandalkan pengalaman dan pengetahuan pribadi dalam menganalisis citra. Hal ini dapat menyebabkan variasi dalam hasil diagnosis. Sistem berbasis AI dapat memberikan konsistensi dan akurasi yang lebih tinggi (Nugroho et al., 2021).

Selain itu, teknologi saat ini belum sepenuhnya mampu mengatasi masalah ketidakseimbangan kelas dalam dataset. Beberapa penyakit paru-paru memiliki jumlah kasus yang lebih sedikit dibandingkan yang lain. Hal ini dapat membuat model cenderung bias terhadap kelas mayoritas (Hellín et al., 2024). Pendekatan seperti pembobotan loss function dan augmentasi data diperlukan untuk mengatasi masalah ini.

Pengembangan sistem deteksi penyakit paru-paru berbasis AI juga menghadapi tantangan dalam hal kecepatan dan akurasi. Model deep learning memerlukan waktu komputasi yang cukup lama untuk memproses citra X-ray. Namun, dengan optimasi dan penggunaan hardware yang tepat, waktu komputasi dapat dikurangi. Akurasi model juga perlu ditingkatkan untuk memastikan keandalan diagnosis (Lee et al., 2023).

Website yang dikembangkan dalam penelitian ini dirancang untuk memudahkan akses dan penggunaan sistem deteksi penyakit paru-paru dengan alur yang komprehensif. Pengguna dapat mengunggah citra X-ray, memasukkan informasi gejala klinis melalui sistem checkbox, dan mendapatkan hasil interpretasi klinis yang menggabungkan temuan radiologis dengan analisis gejala. Website ini menyediakan dashboard interpretasi yang menjelaskan korelasi antara gejala yang dialami pasien dengan temuan pada citra X-ray. Hal ini membantu tenaga medis dalam memahami hubungan antara manifestasi klinis dan gambaran radiologis secara komprehensif.

Implementasi sistem ini dapat meningkatkan efisiensi diagnosis penyakit paru-paru (Yang et al., 2024). Dengan bantuan AI, radiolog dapat fokus pada kasus-kasus yang lebih kompleks. Sistem ini juga dapat digunakan di daerah terpencil yang kekurangan tenaga ahli. Dengan demikian, distribusi layanan kesehatan dapat lebih merata.

Penelitian ini bertujuan untuk mengatasi permasalahan teknologi dalam analisis citra X-ray dengan mengembangkan sistem berbasis AI. Model deep learning yang digunakan diharapkan dapat meningkatkan akurasi dan kecepatan diagnosis. Website yang dikembangkan akan memudahkan tenaga medis dalam menggunakan sistem ini. Hasil penelitian diharapkan dapat memberikan kontribusi signifikan dalam bidang kesehatan.

Secara keseluruhan, penelitian ini berfokus pada pengembangan sistem deteksi penyakit paru-paru berbasis AI yang dapat diakses melalui website. Dengan memanfaatkan dataset NIH Chest X-ray dan arsitektur DenseNet-169, diharapkan sistem ini dapat memberikan solusi untuk masalah interpretasi citra X-ray. Implementasi sistem ini diharapkan dapat meningkatkan efisiensi dan akurasi diagnosis. Dengan demikian, penelitian ini memiliki potensi besar untuk diterapkan dalam praktik klinis.

METHOD

Penelitian ini berjenis Research and Development (R&D) yang bertujuan untuk mengembangkan sistem deteksi penyakit paru-paru berbasis transfer learning dengan arsitektur DenseNet-169. R&D terdiri dari tiga tahap utama: (1) studi pendahuluan, (2) pengembangan model dan sistem, dan (3) evaluasi dan validasi. Tahap studi pendahuluan meliputi kajian literatur dan analisis dataset, sedangkan tahap pengembangan meliputi desain model, pelatihan, dan implementasi sistem. Tahap evaluasi meliputi pengujian performa model dan sistem berdasarkan metrik yang telah ditentukan. Jenis ini dipilih karena sesuai untuk menghasilkan produk berbasis teknologi yang dapat langsung digunakan. Dengan pendekatan ini, seluruh proses pengembangan model dan sistem dilakukan secara sistematis dan dapat dievaluasi secara bertahap untuk memperoleh hasil yang maksimal.

Penelitian ini menggunakan citra X-ray dari NIH Chest X-ray Dataset, namun hanya memanfaatkan gambar X-ray mentah tanpa menggunakan label dan bounding box bawaan. Proses pelabelan dilakukan secara manual dengan bantuan dan supervisi dokter spesialis paru-paru, untuk memastikan akurasi diagnosis yang lebih tinggi dan relevansi klinis yang lebih kuat. Dengan pendekatan ini, sistem deteksi yang dikembangkan mengandalkan label-label validasi medis langsung, yang lebih dapat dipercaya daripada hasil pelabelan otomatis berbasis NLP dari dataset aslinya. Teknik analisis data digunakan untuk mengukur hasil belajar pada aspek pengetahuan, sikap, dan keterampilan. Untuk menilai ketuntasan hasil belajar individu, digunakan rumus berikut.

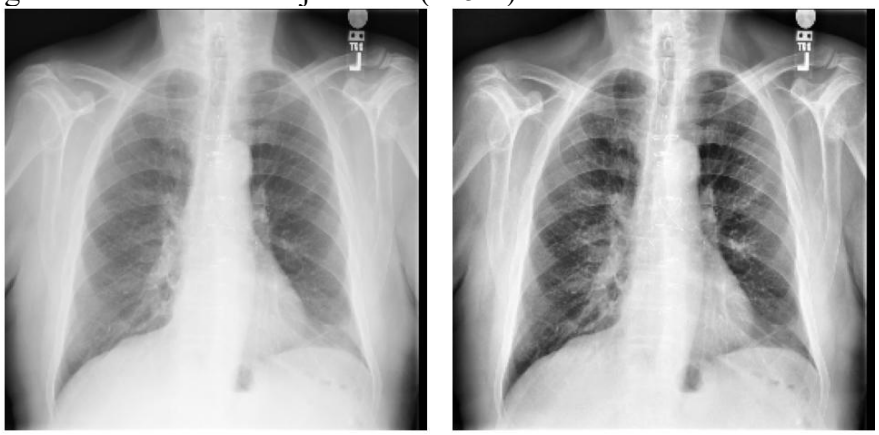
1. Pendekatan Dataset
   a. Pengambilan Citra: Hanya menggunakan citra X-ray dada dari dataset NIH tanpa menggunakan label otomatis yang ada.
   b. Pelabelan Manual: Proses pelabelan dilakukan secara manual dengan bantuan dan supervisi dokter spesialis paru-paru untuk memastikan akurasi diagnosis yang tinggi.
   c. Validasi Medis: Setiap citra X-ray akan dievaluasi dan diberi label oleh dokter spesialis paru-paru berdasarkan standar diagnosis medis yang berlaku.
2. Keunggulan Pendekatan
   a. Akurasi Label Tinggi: Label yang dibuat oleh dokter spesialis memiliki akurasi yang lebih tinggi dibandingkan label otomatis dari NLP (>95% vs 90%).
   b. Standar Medis: Pelabelan mengikuti standar diagnosis medis internasional yang berlaku.
   c. Relevansi Klinis: Label yang dihasilkan lebih relevan dengan kondisi klinis sebenarnya.
   d. Reduksi Bias: Mengurangi bias yang mungkin terjadi pada pelabelan otomatis.
3. Proses Pelabelan
   a. Seleksi Citra: Memilih subset citra X-ray dari dataset NIH berdasarkan kualitas dan kejelasan citra.
   b. Review Medis: Dokter spesialis paru-paru melakukan review terhadap setiap citra terpilih.
   c. Kategorisasi: Memberikan label penyakit berdasarkan temuan radiologis yang teridentifikasi.
   d. Validasi Silang: Validasi dilakukan oleh satu dokter spesialis paru-paru untuk memastikan akurasi pelabelan berdasarkan standar medis.
4. Preprocessing Dataset
   e. Normalisasi Intensitas Piksel: Berdasarkan mean dan standar deviasi dataset ImageNet.

f. Peningkatan Kontras: Menggunakan CLAHE (Contrast Limited Adaptive Histogram Equalization).
g. Resizing: Citra diubah ukurannya menjadi 224x224 piksel dengan interpolasi bilinear.

5. Augmentasi Data

Augmentasi data dilakukan untuk meningkatkan variasi data dan mengatasi ketidakseimbangan kelas, dengan teknik berikut:

a. Random rotation (±10°)
b. Random horizontal flip
c. Random brightness and contrast adjustment (±15%)

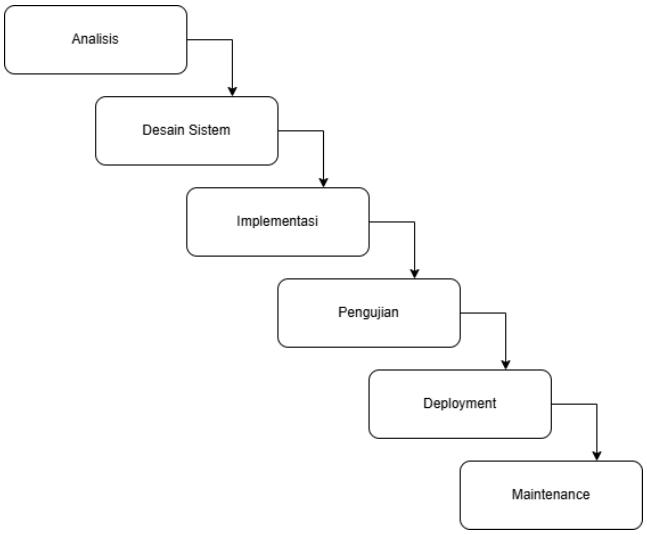


Gambar 1. Sebelum dan Sesudah Pre Processing

Pengembangan sistem dalam penelitian ini menggunakan metode Waterfall, yang terdiri dari enam tahap berurutan: (1) analisis kebutuhan, (2) desain sistem, (3) implementasi, (4) pengujian, (5) deployment, dan (6) pemeliharaan (Hasanah & Untari, 2020). Metode ini dipilih karena sifatnya yang sistematis dan cocok untuk proyek dengan kebutuhan yang telah ditentukan secara jelas sejak awal. Dalam konteks penelitian ini, ruang lingkup sistem sudah ditetapkan sejak awal, yakni berupa integrasi antara model deep learning berbasis DenseNet-169 dengan website sederhana untuk mendeteksi penyakit paru-paru melalui citra X-ray. Kebutuhan sistem seperti jenis penyakit yang dideteksi, format input, serta fitur utama website sudah didefinisikan secara rinci, sehingga pendekatan Waterfall dapat digunakan secara optimal.

Setiap tahapan dalam metode Waterfall memungkinkan pengembangan dilakukan secara berurutan dan terdokumentasi dengan baik, yang penting untuk menjaga ketertelusuran dan validitas dalam penelitian akademik. Tahap analisis kebutuhan difokuskan untuk menggali fitur dan fungsi utama sistem; tahap desain sistem bertujuan menyusun rancangan teknis berupa arsitektur sistem, alur data, dan antarmuka pengguna; sementara implementasi akan merealisasikan rancangan tersebut dalam bentuk kode program dan model AI. Tahapan pengujian dilakukan untuk mengevaluasi akurasi model dan fungsionalitas sistem, sebelum akhirnya sistem dideploy dan dipelihara sesuai kebutuhan pengguna. Struktur bertahap ini membantu meminimalkan risiko perubahan di tengah pengembangan, dan mempermudah proses evaluasi di setiap fase.

Dengan demikian, metode Waterfall dianggap sebagai pilihan yang tepat dalam penelitian ini karena mendukung proses pengembangan yang terarah, terdokumentasi, dan sesuai dengan karakteristik sistem yang memiliki ruang lingkup spesifik dan kebutuhan yang stabil sejak awal.



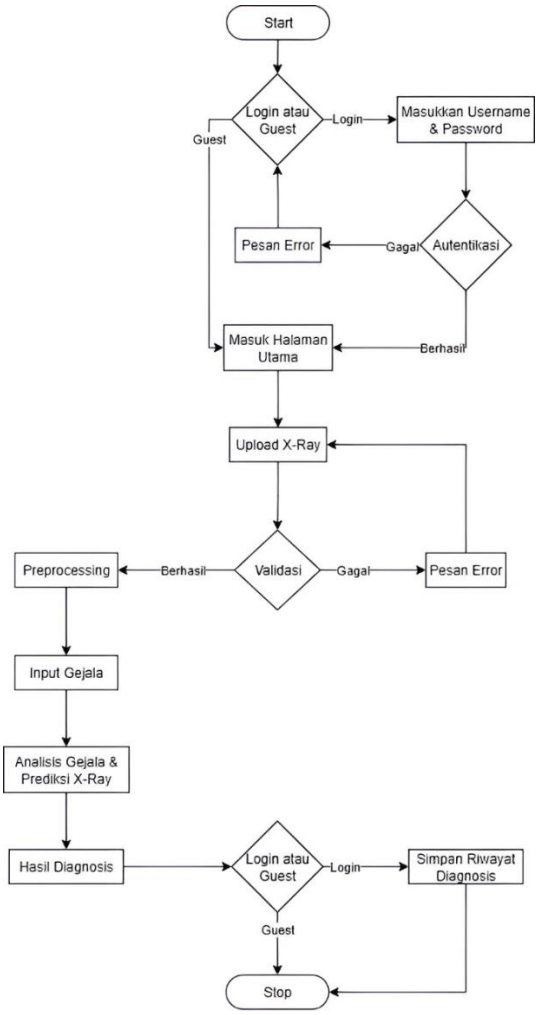
Gambar 2. Tahapan Metode Waterfall

ERD di atas menggambarkan struktur basis data sistem deteksi penyakit paru-paru yang terdiri dari empat entitas utama, yaitu Users, Diagnosis, Diagnosis_Label, dan Diagnosis_Symptom. Entitas Users menyimpan informasi pengguna dengan atribut utama berupa user_id (primary key), username, password, email, dan created_at. Entitas Diagnosis mencatat setiap proses diagnosa yang dilakukan pengguna dengan atribut diagnosis_id (primary key), user_id sebagai foreign key yang merujuk ke Users, dan diagnosis_date sebagai tanggal pelaksanaan diagnosis.

Entitas Diagnosis_Label menyimpan hasil klasifikasi penyakit dari model deep learning dalam bentuk multi-label. Setiap label penyakit disimpan dalam atribut label_name dengan tingkat kepercayaannya disimpan pada atribut label_cscore. Diagnosis_Label memiliki atribut label_id sebagai primary key, dan diagnosis_id sebagai foreign key yang menghubungkannya dengan Diagnosis. Satu diagnosis dapat memiliki lebih dari satu label penyakit.

Sementara itu, entitas Diagnosis_Symptom mencatat gejala-gejala klinis yang diinput oleh pengguna melalui checkbox. Atribut symptom_name menyimpan nama gejala seperti batuk, demam, atau sesak napas. Diagnosis_Symptom memiliki symptom_id sebagai primary key dan diagnosis_id sebagai foreign key yang menghubungkannya dengan Diagnosis. Satu diagnosis dapat mencatat lebih dari satu gejala, atau bahkan tidak ada sama sekali jika pengguna memilih untuk melewati input gejala.

Hubungan antara Users dan Diagnosis bersifat one-to-many, artinya satu pengguna dapat memiliki banyak diagnosis, tetapi setiap diagnosis hanya terkait dengan satu pengguna. Hubungan Diagnosis dengan Diagnosis_Label dan Diagnosis_Symptom juga bersifat one-to-many, sehingga memungkinkan satu diagnosis memiliki banyak label penyakit serta banyak gejala klinis.



Gambar 3. Flowchart Penggunaan Sistem

Flowchart penggunaan sistem di atas menggambarkan proses utama yang dilalui pengguna dari awal hingga akhir dalam menggunakan sistem deteksi penyakit paru-paru berbasis website. Proses dimulai saat pengguna mengakses sistem dan diberikan opsi untuk login atau lanjut sebagai tamu. Jika memilih login, pengguna akan memasukkan kredensial untuk proses autentikasi. Jika login gagal, sistem akan menampilkan pesan kesalahan dan kembali ke menu login. Jika berhasil, atau pengguna memilih untuk melanjutkan sebagai tamu, maka akan diarahkan ke halaman unggah citra X-ray.

Setelah pengguna mengunggah citra, sistem akan memvalidasi apakah file sesuai dengan format dan ukuran yang ditentukan. Jika citra tidak valid, sistem akan menampilkan pesan kesalahan. Jika valid, proses pra-pemrosesan citra (preprocessing) akan dilakukan untuk menyesuaikan ukuran dan intensitas piksel dengan standar input model DenseNet-169.

Setelah proses praproses selesai, pengguna akan diarahkan ke halaman input gejala yang berisi daftar checkbox gejala klinis. Pengguna dapat memilih gejala yang dirasakan, atau melewati tahap ini jika tidak mengalami gejala apapun. Sistem tetap akan melanjutkan proses diagnosis berdasarkan citra X-ray yang telah diunggah, meskipun tanpa input gejala.

Sistem kemudian menjalankan proses prediksi klasifikasi penyakit menggunakan model DenseNet-169, dan secara bersamaan menganalisis data gejala klinis yang telah diinput. Hasil dari

kedua analisis tersebut digabungkan untuk menghasilkan interpretasi diagnosis dalam bentuk deskriptif klinis, yang menjelaskan kemungkinan penyakit berdasarkan citra X-ray dan gejala yang dialami pasien.

Jika pengguna telah login, hasil diagnosis akan disimpan secara otomatis ke dalam database sebagai riwayat yang dapat diakses kembali. Namun jika pengguna tidak login, sistem hanya menampilkan hasil diagnosis tanpa menyimpan data. Seluruh proses dirancang untuk berjalan dengan cepat dan efisien, dengan mempertimbangkan keamanan data dan kemudahan penggunaan, sehingga dapat mendukung kebutuhan diagnosis klinis secara praktis di berbagai lingkungan layanan kesehatan.

HASIL PENELITIAN DAN PEMBAHASAN

Lingkungan Pengembangan dan Pengujian

Pada tahap implementasi sistem deteksi penyakit paru-paru berbasis transfer learning dengan arsitektur DenseNet-169, proses pelatihan model dan pengembangan website dilakukan dengan memanfaatkan perangkat keras dan perangkat lunak yang mendukung kebutuhan komputasi tinggi serta integrasi sistem berbasis web.

1. Spesifikasi Perangkat Keras

Seluruh proses pelatihan model deep learning dilakukan menggunakan layanan Google Colaboratory dengan dukungan GPU berbasis Tesla T4. Spesifikasi teknis dari lingkungan pelatihan dapat dilihat pada Tabel 4.1 berikut:

Tabel 1. Spesifikasi Lingkungan Pelatihan

Komponen	Spesifikasi
Platform	Google Colaboratory (Colab Pro)
GPU	NVIDIA Tesla T4
RAM	13 GB
Penyimpanan	100 GB (shared cloud environment)
Processor	Intel Xeon (Cloud Hosted)

Sementara itu, pengembangan dan pengujian sistem website dilakukan secara lokal menggunakan perangkat laptop pribadi dengan spesifikasi yang tercantum pada Tabel 4.2.

Tabel 2. Spesifikasi Pengembangan dan Pengujian

Komponen	Spesifikasi
Sistem Operasi	Windows 10 64-bit
Prosesor	Intel Core i5-1035G1 @ 1.00GHz
RAM	8 GB
Penyimpanan	SSD 512 GB

2. Spesifikasi Perangkat Lunak

Lingkungan perangkat lunak yang digunakan dalam proses pelatihan model dan pengembangan website terdiri dari beberapa perangkat utama seperti Python, library deep learning, serta framework Laravel untuk website. Rincian spesifikasinya dapat dilihat pada Tabel 4.3 berikut:

Tabel 3. Tabel Spesifikasi Perangkat Lunak

Komponen	Versi / Teknologi
Bahasa Pemrograman	Python 3.10
Library Deep Learning	PyTorch 2.0, torchvision 0.15
Library Pendukung	pandas, numpy, matplotlib, scikit-learn
Framework Web	Laravel 10.x
Backend	PHP 8.x
Frontend	Blade Template, Bootstrap
Platform Pengujian Web	XAMPP + MySQL
Komponen	Versi / Teknologi

3. Deployment Sistem

Dalam penelitian ini, sistem tidak di-deploy ke platform hosting daring, melainkan diimplementasikan dan diuji secara lokal dengan menjalankan dua komponen sistem pada perangkat pengembang.

a. Website Deteksi (Laravel): Komponen frontend dikembangkan menggunakan framework Laravel, dan dijalankan pada server lokal dengan alamat http://127.0.0.1:8000. Website ini menyediakan antarmuka bagi pengguna untuk mengunggah citra X-ray dan memilih gejala klinis yang dialami. Setelah data diinput, website akan mengirimkannya ke API backend untuk diproses. Laravel juga menangani penyimpanan data diagnosis ke dalam database MySQL lokal, serta pengelolaan sesi pengguna yang login.
b. API Prediksi (Flask + TensorFlow): Komponen backend merupakan API prediksi yang dibangun dengan framework Flask dan memanfaatkan model deep learning yang telah dilatih dalam format .h5. API ini dijalankan secara lokal di http://127.0.0.1:5000. Saat menerima permintaan dari frontend, API akan memproses input citra dan gejala klinis, menjalankan model multimodal, dan mengembalikan hasil diagnosis dalam format JSON.

Seluruh komunikasi antara frontend dan backend dilakukan melalui protokol HTTP lokal (API), sehingga mencerminkan struktur sistem sesungguhnya seolah telah dihosting secara daring. Pendekatan ini tidak hanya mempercepat proses pengujian, tetapi juga menjamin keamanan data karena tidak meninggalkan perangkat pengembang.

Implementasi Model

Model yang digunakan dalam penelitian ini dirancang untuk melakukan klasifikasi multi-label terhadap citra X-ray dada dengan mengintegrasikan informasi visual dari citra dan informasi non-visual berupa gejala klinis pasien. Implementasi dilakukan menggunakan pendekatan transfer learning dengan backbone DenseNet-169 yang telah dilatih sebelumnya pada dataset ImageNet, kemudian disesuaikan (fine-tuned) dengan data medis yang tersedia.

1. Arsitektur Model

Model dibangun berdasarkan arsitektur DenseNet-169 sebagai ekstraktor fitur visual dari citra X-ray berukuran 224×224 piksel. Di luar alur konvolusional utama, sistem juga menerima input berupa 14 vektor gejala klinis yang dikodekan dalam bentuk biner (1: ada gejala, 0: tidak ada). Kedua jenis input ini, yaitu citra dan gejala, kemudian digabungkan pada bagian atas model melalui fully connected layers, memungkinkan model melakukan prediksi dengan pendekatan multimodal.

Secara matematis, penggabungan dua jenis input ini dapat diformulasikan sebagai berikut:

$$\mathbf{z} = f\left([\mathbf{x}_{\text{img}} \,\|\, \mathbf{x}_{\text{clin}}]\right)$$

dengan:

- $\mathbf{x}_{\text{img}}$: vektor fitur hasil ekstraksi dari citra X-ray melalui DenseNet-169,
- $\mathbf{x}_{\text{clin}}$: vektor gejala klinis dalam bentuk biner,
- $[\cdot\|\cdot]$: operasi penggabungan vektor (concatenation),
- $f(\cdot)$: fungsi representasi lanjutan berupa beberapa lapisan dense.

Output akhir dari model berupa:

$$\hat{\mathbf{y}} = \sigma(\mathbf{W}\mathbf{z} + \mathbf{b})$$

dengan:

- $\hat{\mathbf{y}}$: vektor prediksi probabilitas dari masing-masing penyakit paru,
- σ : fungsi aktivasi sigmoid,
- $\mathbf{W}, \mathbf{b}$: parameter (bobot dan bias) yang dilatih oleh model.

Output akhir dari model berupa 11 neuron dengan aktivasi sigmoid, yang masing-masing mewakili kemungkinan keberadaan salah satu dari 11 kondisi penyakit paru-paru: Atelectasis, Bronchitis, Bronkiektasis, Cardiomegaly, Consolidation, Effusion, Emphysema, Fibrosis, Infiltration, Mass, dan Pneumothorax. Pendekatan multimodal seperti ini telah terbukti efektif dalam meningkatkan akurasi model karena mampu menggabungkan informasi dari dua sumber berbeda, yaitu citra medis dan data gejala, menjadi representasi yang lebih bermakna (Baltrusaitis et al., 2019).

2. Tahapan Pelatihan

Pelatihan model dilakukan dalam dua fase untuk mengoptimalkan generalisasi model terhadap data medis:

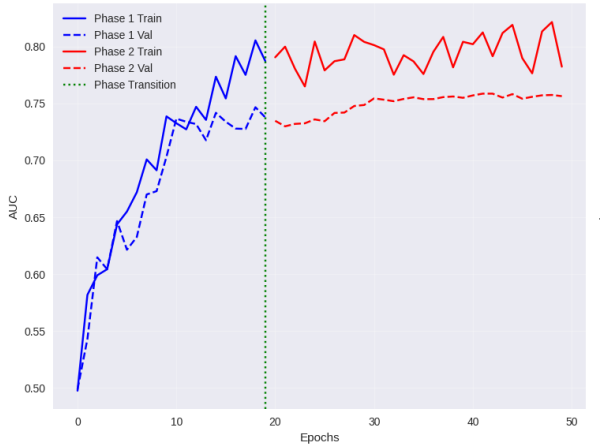
a. Phase 1 – Frozen Backbone

Pada fase ini, seluruh layer DenseNet dibekukan, dan hanya lapisan klasifikasi akhir yang dilatih. Pelatihan dilakukan selama 20 epoch dan berhasil mencapai AUC sebesar 0.6883 pada data validasi.

b. Phase 2 – Fine-Tuning Backbone

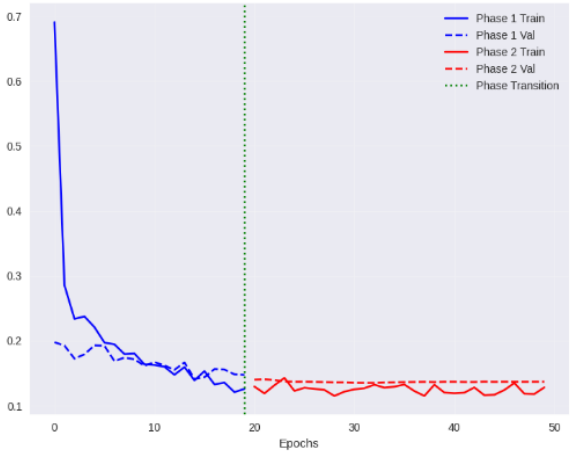
Pada fase ini, beberapa layer akhir dari DenseNet dibuka untuk dilatih bersama dengan layer klasifikasi. Pelatihan dilanjutkan hingga epoch ke-30 dan menghasilkan peningkatan performa menjadi AUC 0.6972, atau peningkatan sebesar 1.3% dari fase sebelumnya.

Performa pelatihan per fase dapat dilihat pada Gambar berikut yang menunjukkan tren nilai AUC, loss, dan akurasi selama proses pelatihan berlangsung:



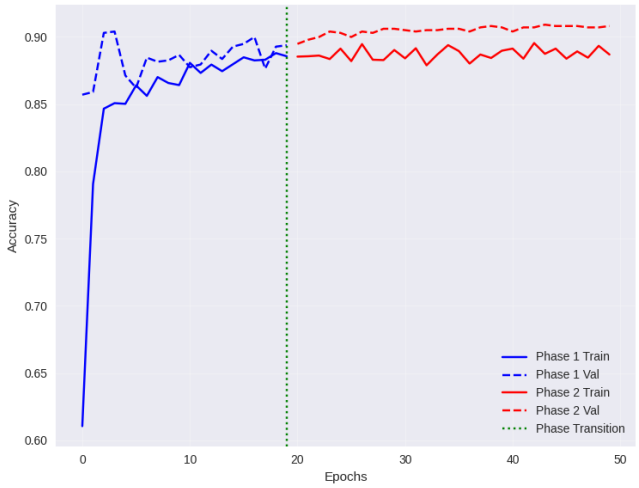
Gambar 4. Grafik Perkembangan AUC

Grafik ini menunjukkan perkembangan nilai AUC (Area Under the Curve) selama 50 epoch pelatihan yang terbagi menjadi dua fase. Pada Phase 1 (epoch 1-20), terlihat bahwa AUC training (garis biru solid) mengalami peningkatan yang signifikan dari sekitar 0.50 hingga mencapai puncak di sekitar 0.80, sementara AUC validation (garis biru putus-putus) meningkat lebih gradual dari 0.62 hingga sekitar 0.75. Transisi ke Phase 2 (epoch 21-50) ditandai dengan garis vertikal putus-putus, di mana AUC training (garis merah solid) mengalami sedikit fluktuasi namun tetap stabil di kisaran 0.78-0.82, sedangkan AUC validation (garis merah putus-putus) relatif stabil di sekitar 0.75, menunjukkan bahwa fine-tuning berhasil mempertahankan performa model pada data yang belum pernah dilihat.



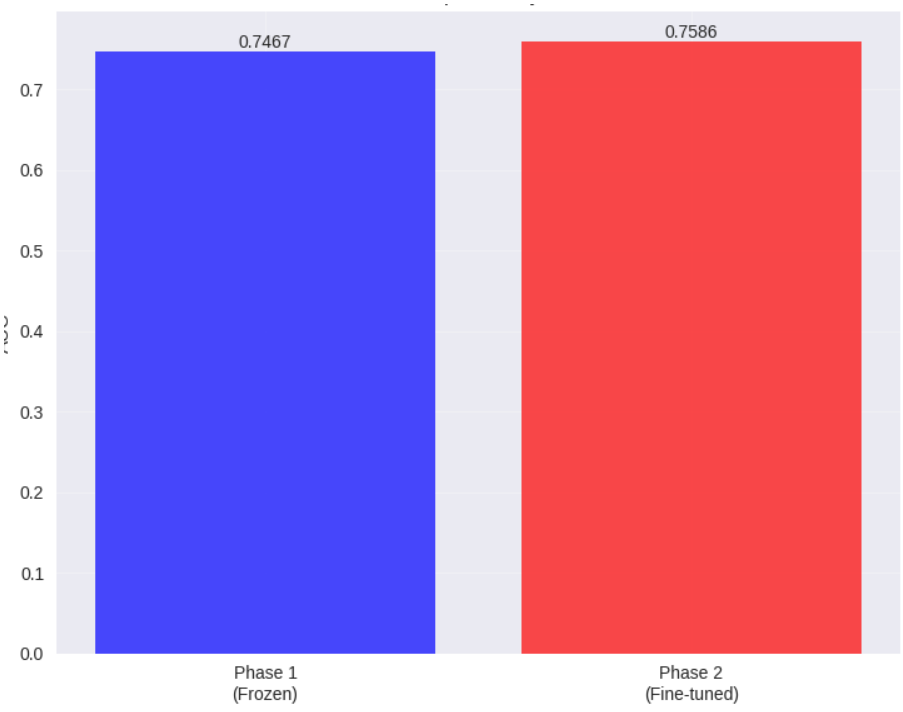
Gambar 5. Grafik Loss

Grafik loss menampilkan tren penurunan nilai loss selama pelatihan berlangsung. Pada Phase 1, loss training (garis biru solid) mengalami penurunan yang drastis dari sekitar 0.69 menjadi 0.15, sementara loss validation (garis biru putus-putus) juga menurun secara konsisten dari sekitar 0.20 hingga 0.15. Ketika memasuki Phase 2, loss training (garis merah solid) dan loss validation (garis merah putus-putus) keduanya tetap stabil di kisaran 0.13-0.14. Pola ini menunjukkan bahwa model tidak mengalami overfitting yang signifikan dan proses fine-tuning berjalan dengan baik.



Gambar 6. Grafik Akurasi

Grafik akurasi menunjukkan performa model dalam memprediksi label dengan benar. Pada Phase 1, akurasi training (garis biru solid) meningkat dengan cepat dari sekitar 0.61 menjadi 0.88, sementara akurasi validation (garis biru putus-putus) juga mengalami peningkatan yang konsisten hingga mencapai sekitar 0.90. Pada Phase 2, akurasi training (garis merah solid) tetap stabil di kisaran 0.88, sedangkan akurasi validation (garis merah putus-putus) juga konsisten di sekitar 0.90. Hal ini menunjukkan bahwa model mampu mempertahankan tingkat akurasi yang tinggi pada kedua fase pelatihan.



Gambar 7. Perbandingan AUC per Fase

Grafik perbandingan ini menampilkan nilai AUC akhir dari masing-masing fase dalam bentuk bar chart. Phase 1 (frozen) menghasilkan AUC sebesar 0.7467, sedangkan Phase 2 (fine-tuned) mencapai AUC sebesar 0.7586. Peningkatan sebesar 0.0119 atau sekitar 1.59% ini

menunjukkan bahwa strategi fine-tuning pada layer akhir DenseNet-169 berhasil memberikan kontribusi positif terhadap kemampuan diskriminatif model, meskipun peningkatannya relatif modest namun tetap signifikan dalam konteks aplikasi medis. Dari grafik tersebut terlihat bahwa proses fine-tuning berhasil mempertahankan dan sedikit meningkatkan kinerja model, dengan nilai AUC validasi yang stabil dan konsisten.

Hasil Implementasi

Pada tahap ini, sistem deteksi penyakit paru-paru berbasis citra X-ray dan gejala klinis diimplementasikan ke dalam bentuk aplikasi web untuk memudahkan pengguna non-teknis seperti tenaga medis dalam mengakses fungsi deteksi tanpa harus berinteraksi langsung dengan kode program atau model AI.

1. Arsitektur Sistem Web

Sistem ini terdiri dari dua komponen utama yang dipisahkan secara logis dan fungsional:

a. Frontend Website

Dibangun menggunakan framework Laravel, website ini berfungsi sebagai antarmuka pengguna untuk mengunggah citra X-ray dan memilih gejala klinis yang dialami pasien dalam bentuk checkbox. Antarmuka dirancang sederhana dan responsif untuk memudahkan penggunaan oleh tenaga medis.

b. API Backend (Flask)

Model AI yang telah dilatih diintegrasikan dalam aplikasi Flask API dan di-deploy terpisah menggunakan layanan Render. Website akan mengirim permintaan prediksi berupa data citra dan gejala ke API ini, lalu menerima hasil klasifikasi dalam bentuk daftar kemungkinan penyakit.

Kedua komponen di-deploy secara daring, sehingga pengguna dapat mengakses sistem ini kapan saja tanpa perlu menjalankan program secara lokal.

2. Fitur Utama Website

Website deteksi ini menyediakan beberapa fitur inti, yaitu:

a. Unggah citra X-ray secara langsung dari komputer pengguna
b. Pilih gejala klinis dari daftar yang telah ditentukan (berjumlah 14 gejala)
c. Kirim data ke model dan menampilkan hasil prediksi penyakit dalam waktu singkat
d. Menyediakan daftar 11 kemungkinan penyakit paru-paru yang bisa dideteksi sistem

KESIMPULAN

Penelitian ini berhasil mengembangkan sistem deteksi penyakit paru-paru berbasis website yang mengintegrasikan model deep learning DenseNet-169 dengan pendekatan transfer learning serta analisis gejala klinis. Sistem mampu mendeteksi sebelas jenis penyakit paru-paru dari citra X-ray yang telah melalui proses pelabelan manual oleh dokter spesialis, sehingga memastikan akurasi label yang tinggi secara medis. Proses pelatihan model dilakukan dalam dua fase, yaitu transfer learning dan fine-tuning, yang menunjukkan peningkatan nilai AUC dari 0.6883 menjadi 0.7586. Website yang dirancang memberikan antarmuka yang mudah digunakan oleh pengguna untuk mengunggah citra X-ray, memasukkan gejala klinis, dan menerima hasil interpretasi diagnosis secara cepat dan deskriptif. Evaluasi kinerja sistem menunjukkan tingkat akurasi dan nilai AUC yang cukup baik, meskipun terdapat variasi performa antar kelas penyakit. Dengan pendekatan multimodal yang menggabungkan data citra dan gejala klinis, sistem ini mampu menghasilkan interpretasi diagnosis yang lebih komprehensif dan relevan secara klinis. Secara keseluruhan, sistem yang dikembangkan berpotensi menjadi solusi yang bermanfaat untuk

mendukung proses diagnosis penyakit paru-paru secara otomatis, terutama di daerah dengan keterbatasan tenaga medis.

DAFTAR PUSTAKA

Ahmad, S., Geiger, C. D., & Fuller, B. T. (2020). Resist: reconstruction of irises from templates..

Alzubaidi, L., Al-Amidie, M., Al-Asadi, A., Humaidi, A., Al-Shamma, O., Fadhel, M., Zhang, J., Santamaría, J., Duan, Y., Farahani, K., & Yousefi, B. (2021). Novel Transfer Learning Approach for Medical Imaging with Limited Labeled Data. Cancers, 13.

Chen, I. D. S., Yang, C., Chen, M., Chen, M., Weng, R., & Yeh, C. (2023). Deep learning-based recognition of periodontitis and dental caries in dental x-ray images. Bioengineering, 10(8), 911.

Chen, J. (2023). Model Algorithm Research based on Python Fast API. Frontiers in Science and Engineering.

Endut, N., Hamzah, W. M. A. F. W., Ismail, I., Yusof, M. K., Baker, Y. A., & Yusoff, H. (2022). A systematic literature review on multi-label classification based on machine learning algorithms. TEM Journal, 658-666.

Girdhar, N., Sinha, A., & Gupta, S. (2022). Densenet-ii: an improved deep convolutional neural network for melanoma cancer detection. Soft Computing, 27(18), 13285-13304.

Hosmer, D. W., Lemeshow, S., & Sturdivant, R. X. (2013). Applied Logistic Regression (3rd ed.). John Wiley & Sons.

Jawaz, I. and Rahmadewi, R. (2024). Sistem deteksi pneumonia paru-paru dengan pengolahan citra digital dan machine learning. Electron Jurnal Ilmiah Teknik Elektro, 5(1).

Kaur, R., Ginige, J. A., & Obst, O. (2021). A systematic literature review of automated icd coding and classification systems using discharge summaries..

Lee, J., Hong, H., Nam, G., Hwang, E., & Park, C. (2023). Effect of Human-AI Interaction on Detection of Malignant Lung Nodules on Chest Radiographs.. Radiology, 307 5, e222976.

Li, Y. and Song, P. (2022). Review of transfer learning in medical image classification. Journal of Image and Graphics, 27(3), 672-686.

Shi, Z., Chen, M., & Wu, Z. (2023). Hyperspectral image classification based on dual-scale dense network with efficient channel attentional feature fusion. Electronics, 12(13), 2991.

Sobhana, M., Ravi, S., Bodedla, J., Vemulapalli, S. R., & Jagathapurao, G. S. K. V. (2024). A comprehensive study: intracranial aneurysm detection via vgg16-densenet hybrid deep learning on dsa images. Informatyka, Automatyka, Pomiary W Gospodarce I Ochronie Środowiska, 14(1), 105-110.