



Penerapan Deep Learning Untuk Deteksi Penyakit Pada Citra Rontgen Paru-paru

Edesius Mario Gase Amekae

Primakara University

Jl. Tukad Badung No.135 80226 Denpasar Selatan Bali

Email: mariogazee@gmail.com

Abstrak

Penyakit paru-paru seperti *pneumonia*, *tuberkulosis*, dan *pneumotoraks* masih menjadi masalah kesehatan yang serius di banyak negara. Deteksi dini sangat penting agar pasien bisa mendapatkan penanganan lebih cepat dan peluang sembuh menjadi lebih tinggi. Pemeriksaan menggunakan citra rontgen memang umum digunakan, tetapi proses pembacaannya secara manual kadang terkendala oleh kelelahan tenaga medis atau kualitas gambar yang kurang baik. Penelitian ini membuat sistem pendeteksi penyakit paru-paru menggunakan metode deep learning dengan model *Convolutional Neural Network* (CNN). Sistem ini dirancang untuk mengenali empat kondisi, yaitu normal, *pneumonia*, *tuberkulosis*, dan *pneumotoraks*, serta dipersiapkan agar dapat digunakan melalui aplikasi berbasis web sehingga lebih mudah diakses. Pengembangan sistem dilakukan mengikuti tahapan CRISP-DM, mulai dari memahami masalah, mengumpulkan dan menyiapkan data, membangun dan melatih model, hingga mengevaluasi hasilnya. Model CNN yang dibuat mampu mencapai akurasi 93%, dengan nilai presisi 90%, recall 92%, dan F1-score 91%. Hasil penelitian menunjukkan bahwa website deteksi penyakit paru-paru berbasis deep learning yang dikembangkan dapat digunakan sebagai alat bantu deteksi awal yang efektif serta mendorong pemanfaatan teknologi web dalam bidang kesehatan.

Kata Kunci: Deep Learning; Convolutional Neural Network; Deteksi Penyakit Paru-Paru; Citra Rontgen; Aplikasi Web

PENDAHULUAN

Penyakit paru-paru adalah salah satu penyebab utama kematian di dunia. Menurut (World Health Organization, 2022), menyatakan bahwa pneumonia menjadi penyebab infeksi paling mematikan pada anak di bawah usia 5 tahun, membunuh sekitar 740.180 anak pada tahun 2019, setara dengan 14% dari seluruh kematian anak balita menyebabkan banyak kematian setiap tahunnya.

Namun, perlu dipahami bahwa penyakit paru-paru bukan hanya pneumonia. Ada penyakit paru lain yang juga memiliki tingkat keparahan dan risiko kematian tinggi jika tidak dideteksi sejak dini, yaitu tuberkulosis (TB) menurut (Dipdo PWidjaya dkk., 2014) dan pneumotoraks menurut (Viktoria Thanita, 2024). Itulah mengapa penulis memutuskan untuk tidak hanya fokus pada pneumonia, tetapi juga memasukkan

tuberkulosis dan pneumotoraks, supaya sistem yang penulis kembangkan bisa lebih bermanfaat dalam membantu deteksi berbagai penyakit paru-paru yang beresiko tinggi.

Salah satu metode utama yang digunakan dalam diagnosis penyakit paru-paru adalah pencitraan medis, khususnya rontgen paru-paru. Rontgen paru-paru digunakan secara luas oleh tenaga medis untuk mengidentifikasi kelainan pada paru-paru. Namun, analisis citra rontgen masih memiliki beberapa tantangan, seperti adanya kemungkinan kesalahan membaca gambar karena kelelahan dokter, perbedaan kualitas gambar, ataupun faktor subjektivitas lainya dalam penilaian. Kesalahan dalam diagnosis dapat menyebabkan keterlambatan penanganan yang berakibat fatal bagi pasien.

Seiring dengan kemajuan teknologi dalam bidang kecerdasan buatan, khususnya deep learning, berbagai model telah dikembangkan untuk membantu dalam analisis pencitraan medis. Deep learning, yang merupakan bagian dari machine learning, memiliki kemampuan dalam mengenali pola dan fitur kompleks dalam citra dengan tingkat akurasi yang tinggi. Berbagai penelitian telah menunjukkan bahwa model deep learning, seperti Convolutional Neural Networks (CNN), dapat mencapai kinerja yang setara atau bahkan lebih baik dibandingkan dengan tenaga medis dalam mendeteksi berbagai jenis penyakit dari citra rontgen (Ahmad Izzan Kautsar dkk., 2017).

Beberapa penelitian terdahulu telah membuktikan efektivitas penerapan deep learning dalam bidang radiologi. Misalnya, penelitian yang dilakukan oleh Pranav Rajpurkar dan teman-temanya mengembangkan model CNN bernama CheXNet yang mampu mendeteksi pneumonia dengan akurasi lebih tinggi dibandingkan dengan radiologis manusia (Pranav Rajpurkar dkk., 2017).

Penelitian yang dilakukan oleh Indah (Indah Kurniawati dkk., 2024) membuktikan bahwa penerapan model Convolutional Neural Network (CNN) untuk identifikasi pneumonia pada citra rontgen balita mampu mencapai akurasi tinggi hingga 91%, dengan waktu analisis yang jauh lebih cepat dibandingkan dokter, yakni hanya 0,2 detik per citra. Hal ini menunjukkan bahwa metode deep learning tidak hanya akurat tetapi juga sangat efisien, dan dapat menjadi solusi potensial untuk membantu tenaga medis dalam mempercepat proses diagnosis.

Pada jurnal yang dibuat oleh (Perani Rosyani dkk., 2024) juga menunjukkan bahwa penerapan Convolutional Neural Network (CNN) dalam klasifikasi penyakit paru-paru dari citra X-ray mampu mengidentifikasi penyakit seperti influenza, bronkitis, asma, TBC, PPOK, dan pneumonia dengan akurasi tinggi. Sistem ini terbukti mampu membantu

proses diagnosis dini dan meringankan beban kerja tenaga medis dalam analisis citra medis.

Pada jurnal internasional yang dibuat oleh (Siddhanth Tripathi dkk., 2021) mereka menunjukkan bahwa penggunaan deep CNN dengan arsitektur VGG dan teknik preprocessing seperti spatial transformer menghasilkan akurasi rata-rata 89,77% dalam klasifikasi multi-penyakit paru-paru dari dataset ChestX-ray14, menjadikan model ini efektif untuk digunakan dalam deteksi penyakit thorax secara otomatis.

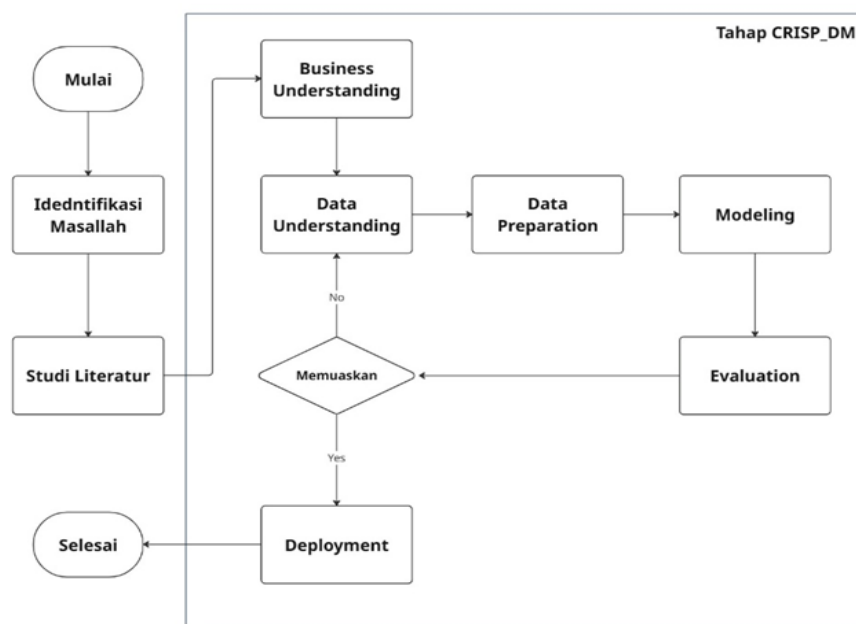
Dalam penelitian ini, teknologi berbasis web dimanfaatkan sebagai media untuk melakukan analisis penyakit paru-paru dari citra rontgen. Platform web ini mengintegrasikan model deep learning yang telah dikembangkan dengan tampilan antarmuka yang bisa diakses secara daring. Dengan sistem ini, pengguna seperti tenaga medis dapat mengunggah citra rontgen dan memperoleh hasil analisis secara otomatis melalui web. Pendekatan ini memberikan kemudahan akses tanpa perlu menginstal perangkat lunak tambahan di komputer lokal, sehingga mempercepat dan mempermudah proses diagnosis penyakit paru-paru.

Berdasarkan latar belakang ini, penelitian yang penulis buat bertujuan untuk menerapkan deep learning dalam mendeteksi penyakit paru-paru dari citra rontgen paru-paru. Dengan memanfaatkan teknologi ini, diharapkan dapat dihasilkan model yang mampu membantu tenaga medis dalam diagnosis penyakit paru-paru dengan lebih cepat, akurat, dan efisien. Oleh karena itu, penelitian ini memiliki urgensi tinggi dalam mendukung sistem kesehatan, terutama dalam meningkatkan deteksi dini dan penanganan penyakit paru-paru.

METODE PENELITIAN

Metode yang digunakan dalam penelitian ini adalah CRISP-DM. CRISP-DM merupakan metodologi standar yang digunakan secara luas dalam proyek-proyek data mining dan analisis berbasis data, termasuk dalam pengembangan sistem berbasis kecerdasan buatan seperti deep learning.

Alur penelitian ini disusun berdasarkan enam tahapan dalam metode CRISP-DM. Berikut adalah penjelasan masing-masing tahapan yang diterapkan dalam gambar 1 untuk penelitian ini:



Gambar 1. Alur Penelitian

Pada tahap identifikasi masalah, penulis fokus pada pemahaman awal terhadap permasalahan yang ingin diselesaikan, yaitu perlunya sistem yang mampu mendeteksi penyakit paru-paru dari citra rontgen secara otomatis, cepat, dan akurat.

Pada tahap studi literatur, penulis menelusuri berbagai sumber ilmiah seperti jurnal, artikel, dan laporan penelitian yang berkaitan dengan penerapan teknologi deep learning dalam bidang medis, khususnya untuk deteksi penyakit paru-paru melalui citra rontgen. Studi ini bertujuan untuk memahami pendekatan-pendekatan yang telah dilakukan sebelumnya, algoritma yang umum digunakan, serta performa dari berbagai model klasifikasi citra dalam konteks diagnosis penyakit.

Tahap pertama adalah memahami permasalahan yang ingin diselesaikan dari sudut pandang bisnis atau kebutuhan praktis. Dalam penelitian ini, fokusnya adalah bagaimana membantu proses deteksi penyakit paru-paru seperti pneumonia, tuberkulosis, dan pneumotoraks dengan memanfaatkan citra rontgen dan teknologi deep learning.

Tahap ini bertujuan untuk memahami karakteristik data yang akan digunakan, termasuk jenis data, jumlah data, distribusi, serta potensi masalah seperti ketidakseimbangan data antar kelas penyakit.

Pada tahap ini dilakukan proses persiapan data agar siap digunakan untuk pelatihan model. Proses ini meliputi pembersihan data, normalisasi citra, augmentasi, dan pembagian data ke dalam data latih (train), validasi (val), dan uji (test).

Setelah data siap, tahap ini adalah proses pembangunan dan pelatihan model deep learning, dalam hal ini adalah CNN yang dirancang untuk mengklasifikasikan citra rontgen ke dalam kategori penyakit yang telah ditentukan.

Tahap akhir adalah penerapan sistem yang telah dikembangkan ke dalam bentuk aplikasi, dalam penelitian ini berupa aplikasi web. Aplikasi web ini memungkinkan pengguna mengunggah citra rontgen dan mendapatkan hasil prediksi penyakit secara otomatis.

Tahap akhir adalah penerapan sistem yang telah dikembangkan ke dalam bentuk aplikasi, dalam penelitian ini berupa aplikasi web. Aplikasi web ini memungkinkan pengguna mengunggah citra rontgen dan mendapatkan hasil prediksi penyakit secara otomatis.

HASIL DAN PEMBAHASAN

Hasil

Pada tahap identifikasi masalah, penulis fokus pada pemahaman awal terhadap permasalahan yang ingin diselesaikan, yaitu perlunya sistem yang mampu mendeteksi penyakit paru-paru dari citra rontgen secara otomatis, cepat, dan akurat. Permasalahan ini muncul karena keterbatasan tenaga ahli radiologi di beberapa wilayah serta tingginya kebutuhan akan diagnosis dini yang dapat diakses secara luas.

Penulis menganalisis kebutuhan akan solusi berbasis teknologi yang tidak hanya mampu melakukan klasifikasi penyakit paru-paru secara efektif, tetapi juga dapat diimplementasikan dalam bentuk aplikasi website yang mudah digunakan. Berdasarkan hal tersebut, dirumuskan masalah utama dalam penelitian ini: bagaimana membangun model deep learning yang dapat mengklasifikasikan penyakit paru-paru dari citra rontgen, serta menerapkannya dalam aplikasi website sebagai alat bantu diagnosis awal.

3.2 Studi Literatur

Pada Pada tahap studi literatur, penulis melakukan penelusuran terhadap berbagai publikasi ilmiah berupa jurnal nasional dan internasional yang membahas penerapan teknologi deep learning dalam bidang medis, khususnya pada analisis citra rontgen dada untuk deteksi penyakit paru-paru. Beberapa penelitian menunjukkan bahwa pendekatan deep learning mampu memberikan performa yang lebih baik dibandingkan metode konvensional dalam klasifikasi citra medis, sehingga banyak digunakan sebagai dasar pengembangan sistem pendukung diagnosis berbasis kecerdasan buatan (Geert Litjens dkk., 2017; Yann Lecun dkk., 2016)

Hasil studi literatur menunjukkan bahwa Convolutional Neural Network (CNN) merupakan metode yang paling banyak digunakan dalam pengolahan citra rontgen dada karena kemampuannya dalam mengekstraksi fitur visual secara otomatis tanpa memerlukan rekayasa fitur manual. Penerapan CNN pada citra rontgen paru-paru terbukti efektif dalam mengenali pola visual khas dari berbagai penyakit paru-paru, termasuk pneumonia (Ahmad Izzan Kautsar dkk., 2017; Indah Kurniawati dkk., 2024).

Beberapa penelitian yang dijadikan rujukan dalam skripsi ini masih berfokus pada klasifikasi biner, yaitu membedakan antara kondisi paru-paru normal dan satu jenis penyakit tertentu. Pendekatan tersebut dilaporkan mampu mencapai tingkat akurasi yang tinggi, namun memiliki keterbatasan dalam merepresentasikan kondisi klinis yang lebih kompleks, karena pada praktiknya citra rontgen paru-paru dapat menunjukkan kemiripan pola antar berbagai jenis penyakit (Pranav Rajpurkar dkk., 2017).

Seiring dengan perkembangan penelitian, beberapa studi mulai menerapkan klasifikasi multi-kelas untuk mendeteksi lebih dari satu jenis penyakit paru-paru secara bersamaan. Pendekatan ini dinilai lebih relevan dengan kebutuhan diagnosis medis karena mampu memberikan informasi yang lebih komprehensif terkait kondisi paru-paru pasien. Namun demikian, beberapa penelitian juga melaporkan adanya tantangan dalam menjaga keseimbangan performa antar kelas, terutama ketika dataset yang digunakan memiliki distribusi data yang tidak seimbang (Perani Rosyani dkk., 2024; Siddhant Tripathi dkk., 2021).

Selain metode klasifikasi, jurnal-jurnal yang digunakan dalam skripsi ini juga membahas pentingnya teknik pra-pemrosesan data, seperti data augmentation, dalam meningkatkan performa dan kemampuan generalisasi model CNN. Teknik augmentasi data dilaporkan mampu mengurangi risiko overfitting serta meningkatkan ketahanan model terhadap variasi citra rontgen ((Hantian Dong dkk., 2022; Saman Motamed dkk., 2021; Shorten & Khoshgoftaar, 2019).

State of the art dalam penelitian deteksi penyakit paru-paru berbasis citra rontgen menunjukkan kecenderungan pengembangan model CNN yang lebih efisien dan ringan, terutama untuk mendukung implementasi pada sistem berbasis web. Model dengan arsitektur yang terlalu kompleks dilaporkan membutuhkan sumber daya komputasi yang tinggi dan kurang optimal untuk aplikasi yang menuntut kecepatan inferensi serta kemudahan akses (Mienye dkk., 2025; Pebri Andhi Herry Pratama dkk., 2021).

Berdasarkan hasil studi literatur tersebut, penelitian ini mengadopsi pendekatan CNN custom yang dirancang secara sederhana dan efisien untuk melakukan klasifikasi multi-kelas citra rontgen dada. Penelitian ini berfokus pada pendeteksian empat kondisi paru-paru, yaitu normal, pneumonia, tuberkulosis, dan pneumotoraks, dengan memanfaatkan dataset rontgen dada yang tersedia secara publik (Paul Mooney, 2018; Tawsifur Rahman, 2021; vbookshelf, 2020). Pendekatan ini dipilih untuk mencapai keseimbangan antara performa klasifikasi yang baik dan kemudahan implementasi model ke dalam aplikasi berbasis web.

3.3 Business Understanding

Pada tahap ini, penulis melakukan pemetaan ulang terhadap kebutuhan utama penelitian untuk memastikan bahwa sistem yang dikembangkan benar-benar menjawab permasalahan diagnosis penyakit paru-paru secara akurat dan efisien. Business Understanding pada bab ini difokuskan pada bagaimana model deep learning dapat diterapkan secara praktis sebagai alat bantu analisis citra rontgen.

Tahap ini menegaskan kembali bahwa proses diagnosis manual masih memiliki keterbatasan, seperti subjektivitas penilaian, keterbatasan tenaga ahli, dan tingginya beban kerja radiolog. Kondisi tersebut menjadi alasan utama diperlukannya sistem otomatis yang mampu memberikan prediksi cepat dan konsisten. Oleh karena itu, metode Convolutional Neural Network (CNN) dipilih sebagai pendekatan yang paling sesuai karena telah terbukti efektif dalam ekstraksi fitur visual dan klasifikasi citra medis.

Melalui pemahaman ini, tujuan utama penelitian diarahkan untuk membangun model CNN yang dapat mengklasifikasikan empat kelas citra rontgen yaitu Normal, Pneumonia, Tuberkulosis, dan Pneumotoraks serta mengintegrasikannya ke dalam aplikasi web agar mudah diakses dan digunakan dalam proses deteksi dini.

3.4 Data Understanding

Tahap Data Understanding bertujuan untuk memahami karakteristik dan kondisi dataset yang digunakan dalam penelitian ini. Pemahaman yang baik terhadap data sangat penting agar proses pelatihan model CNN dapat dilakukan secara optimal dan menghasilkan performa yang baik.

Dataset yang digunakan dalam penelitian ini diperoleh dari platform Kaggle, yaitu repositori data terbuka yang menyediakan berbagai dataset medis, termasuk citra rontgen dada (Chest X-Ray Images). Dataset ini dipilih karena memiliki kualitas citra yang

baik, jumlah data yang memadai, serta telah banyak digunakan dalam penelitian-penelitian sebelumnya terkait deteksi penyakit paru-paru.

Secara keseluruhan, dataset terdiri dari citra rontgen dengan empat kelas kondisi paru-paru, yaitu Normal sebanyak 3.174 citra, Pneumonia sebanyak 8.546 citra, Tuberkulosis sebanyak 2.752 citra, dan Pneumotoraks sebanyak 3.205 citra. Distribusi jumlah data yang berbeda pada setiap kelas menunjukkan adanya ketidakseimbangan data (class imbalance), yang menjadi perhatian penting dalam proses pengolahan dan pelatihan model.

Oleh karena itu, pemahaman terhadap distribusi data ini menjadi dasar dalam menentukan strategi data preparation, seperti augmentasi data, agar model CNN yang dikembangkan mampu belajar secara optimal dan tidak bias terhadap kelas tertentu.

3.5 Data Preparation

Tahap Data Preparation merupakan proses persiapan data agar citra rontgen paru-paru dapat digunakan dengan optimal dalam pelatihan model CNN. Pada tahap ini dilakukan beberapa proses penting, yaitu pembagian dataset, penyesuaian ukuran citra, dan augmentasi citra. Seluruh proses dapat dilihat sebagai berikut:

3.5.1 Pembagian Dataset

Pada tahap ini, data yang digunakan dibagi menjadi empat kategori utama, yaitu Normal, Pneumonia, Tuberkulosis, dan Pneumotoraks. Namun sebelum membagi dataset, perlu dilakukan pemilihan jumlah dataset. Dataset asli yang diperoleh dari Kaggle terdiri dari total 17.677 citra rontgen dengan distribusi kelas yang tidak seimbang. Sehingga penulis memutuskan untuk memilih jumlah dataset yang digunakan agar relative seimbang pada masing-masing kelas dan dapat dilihat pada tabel 1.

Tabel. 1. Jumlah Dataset yang Digunakan

| Kelas Penyakit | Dataset Asli | Data Training (80%) | Data Validation (10%) | Data Testing (10%) |
|-----------------------|---------------------|----------------------------|------------------------------|---------------------------|
| Normal | 3.174 | 2.000 | 250 | 250 |
| Pneumonia | 8.546 | 2.000 | 250 | 250 |
| Tuberkulosis | 2.752 | 2.000 | 250 | 250 |
| Pneumotoraks | 3.205 | 2.000 | 250 | 250 |
| Total | 17.677 | 8.000 | 1.000 | 1.000 |

Secara keseluruhan, dataset terdiri dari 10.000 citra rontgen, yang dibagi menjadi 80% untuk data pelatihan (training), 10% untuk data validasi (validation), dan 10% untuk data pengujian (testing). Pembagian proporsi data ini umum digunakan dalam penelitian machine learning karena mampu memberikan keseimbangan antara proses pembelajaran model dan evaluasi performa secara objektif.

Kesimpulan berdasarkan hasil tahapan data preparation, dapat disimpulkan bahwa seluruh citra rontgen telah berhasil diseragamkan ukurannya, dinormalisasi, dan diperbanyak secara buatan melalui augmentasi. Proses ini memastikan bahwa model CNN memiliki data yang cukup bervariasi untuk dipelajari, sehingga dapat menghasilkan performa yang lebih stabil dan akurat

3.5.2 Penyesuaian Ukuran Citra

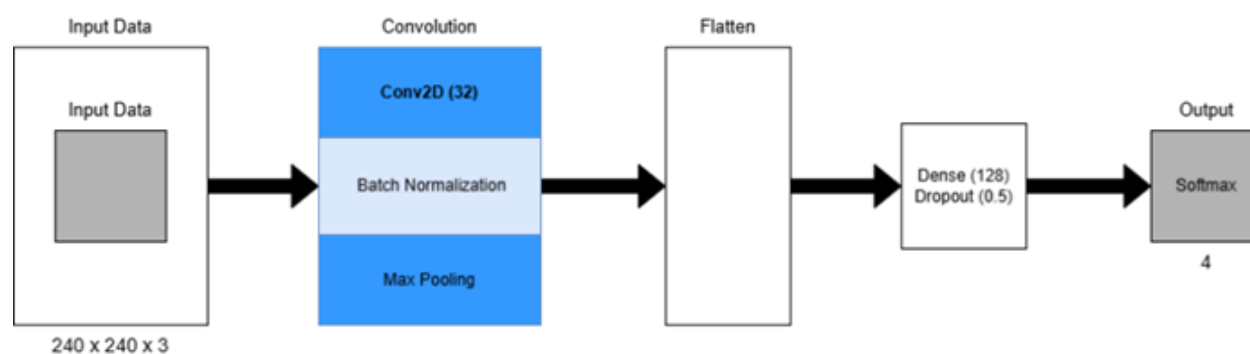
Citra rontgen paru-paru yang diperoleh dari dataset Kaggle memiliki ukuran yang bervariasi, sehingga perlu dilakukan proses penyeragaman ukuran (resizing) sebelum digunakan oleh model CNN. Pada penelitian ini, setiap citra diubah menjadi ukuran 640 × 640 piksel, dengan tujuan agar resolusi cukup tinggi untuk mempertahankan detail visual yang penting, seperti bercak putih atau bayangan gelap abnormal pada paru-paru, namun tetap efisien untuk diproses menggunakan GPU.

3.5.1 Augmentasi Data

Tahap berikutnya adalah augmentasi data, yaitu proses memperbanyak variasi citra secara buatan tanpa menambah jumlah data asli. Teknik ini membantu mencegah overfitting (kondisi di mana model machine learning terlalu menghafal data pelatihan) dengan cara menghasilkan berbagai versi baru dari citra yang sama melalui transformasi acak. Kombinasi dari berbagai transformasi seperti rescale, rotation_range, width_shift_range, height_shift_range, zoom_range, dan horizontal_flip menghasilkan dataset pelatihan yang jauh lebih bervariasi tanpa menghilangkan makna medis pada citra rontgen paru-paru. Dengan jumlah awal sekitar 8.000 citra dengan masing-masing 2.000 citra per kelas untuk Normal, Pneumonia, Tuberkulosis, dan Pneumotoraks. Setelah proses augmentasi diterapkan, jumlah data pelatihan bertambah signifikan menjadi 48.000 citra, sehingga setiap kelas kini memiliki 12.000 citra. Peningkatan ini membuat model CNN yang dibangun menjadi lebih adaptif dalam mengenali berbagai kondisi visual dan lebih mampu menggeneralisasi pola pada data baru, karena dilatih dengan dataset yang jauh lebih kaya dan beragam.

3.6 Modeling

Pada proses pemodelan ini, langkah pertama yang penulis lakukan adalah menguji model CNN dengan 1 lapisan konvolusi sebagai baseline. Pemilihan arsitektur paling sederhana ini bertujuan untuk melihat sejauh mana kemampuan dasar CNN dalam mengekstraksi fitur penting dari citra rontgen paru-paru. Namun, hasil pengujian menunjukkan bahwa CNN 1 lapis hanya mampu mencapai akurasi sebesar 79%, sehingga tidak memenuhi tolak ukur yang telah ditetapkan. Rendahnya performa ini disebabkan oleh keterbatasan model yang terlalu dangkal, sehingga tidak mampu menangkap pola visual kompleks pada citra medis. Alur arsitektur CNN 1 lapis yang digunakan pada penelitian ini dapat dilihat pada gambar 2.



Gambar 2. Alur Kerja CNN 1 Lapis

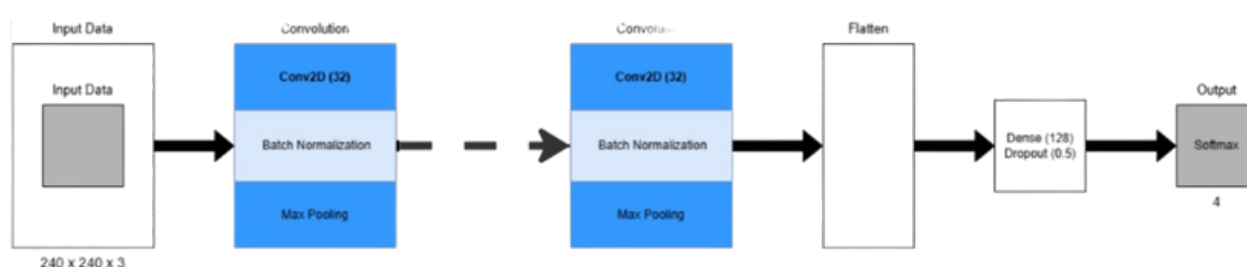
Arsitektur CNN yang digunakan pada tahap ini terdiri dari beberapa tahapan utama seperti pada gambar 4.3. Proses dimulai dengan input citra rontgen berukuran $240 \times 240 \times 3$, yang kemudian diproses oleh lapisan Conv2D dengan 32 filter berukuran 3×3 dan fungsi aktivasi ReLU. Lapisan ini berfungsi untuk mengekstraksi fitur dasar seperti tepi dan pola tekstur awal pada citra. Selanjutnya, hasil konvolusi dinormalisasi menggunakan Batch Normalization untuk menstabilkan distribusi nilai aktivasi dan mempercepat proses pelatihan model. Setelah itu, diterapkan MaxPooling berukuran 2×2 untuk mengurangi dimensi spasial citra sekaligus mempertahankan fitur-fitur yang paling dominan. Output dari lapisan konvolusi kemudian diratakan menggunakan Flatten, sehingga membentuk vektor satu dimensi yang dapat diproses oleh lapisan fully connected. Vektor ini selanjutnya masuk ke lapisan Dense dengan 128 neuron dan fungsi aktivasi ReLU, yang berperan dalam mengombinasikan fitur-fitur yang telah diekstraksi sebelumnya. Untuk mengurangi risiko overfitting, digunakan Dropout dengan nilai 0,5, sebelum akhirnya data diproses oleh lapisan output Dense dengan 4 neuron dan fungsi

aktivasi Softmax. Lapisan ini menghasilkan probabilitas untuk masing-masing kelas penyakit paru-paru yang diteliti.

Karena akurasi awal tersebut belum memadai, penulis kemudian melanjutkan eksperimen dengan menambah jumlah lapisan CNN untuk mencari arsitektur yang memberikan hasil paling optimal. Penulis melakukan percobaan bertahap mulai dari 2 lapisan, 3 lapisan, 4 lapisan, hingga 5 lapisan CNN.

3.6.1 Eksperimen Jumlah Lapisan CNN

Eksperimen ini dilakukan untuk mengetahui pengaruh jumlah lapisan konvolusi terhadap performa CNN dalam mendeteksi penyakit paru-paru dari citra rontgen. Tujuannya adalah mencari struktur arsitektur CNN yang paling efektif dalam mengekstraksi fitur visual, seperti tepi, bercak putih, atau area abnormal pada citra rontgen paru-paru.



Gambar 3. Alur Arsitektur CNN


Gambar 3 merupakan gambar arsitektur Convolutional Neural Network (CNN) yang digunakan dalam penelitian ini untuk mendeteksi penyakit paru-paru dari citra rontgen. Arsitektur ini menggambarkan alur pemrosesan data mulai dari input citra, proses ekstraksi fitur melalui lapisan konvolusi, hingga menghasilkan output klasifikasi dalam empat kelas, yaitu Normal, Pneumonia, Tuberkulosis, dan Pneumotoraks. Pada bagian Convolution N, huruf N menunjukkan jumlah lapisan konvolusi (CNN layers) yang digunakan dalam suatu eksperimen. Jumlah lapisan ini bersifat variatif, menyesuaikan skenario pengujian yang dilakukan, yaitu penggunaan CNN dengan 2, 3, 4, dan 5 lapisan konvolusi. Setiap satu lapisan CNN terdiri dari rangkaian Conv2D, Batch Normalization, dan Max Pooling, yang berfungsi untuk mengekstraksi fitur visual dari citra rontgen secara bertahap.

Pada eksperimen ini setiap percobaan dilakukan dengan menambah jumlah lapisan konvolusi secara bertahap, mulai dari 2 hingga 5 lapisan, menggunakan konfigurasi dasar yang sama pada optimizer, learning rate, dan batch size, agar

perbandingan performa tetap objektif. Pada tabel 2 menunjukkan hasil akurasi model berdasarkan jumlah lapisan CNN yang diuji :

Arsitektur CNN 1 Lapis

=== Grafik Matplotlib ===




=== Classification Report ===

| | Precision | recall | f1-score | support |
|--------------|-----------|--------|-------------|---------|
| NORMAL | 0.78 | 0.71 | 0.74 | 250 |
| PNEUMONIA | 0.72 | 0.86 | 0.78 | 250 |
| PNEUMOTORAKS | 0.83 | 0.89 | 0.86 | 250 |
| TUBERCULOSIS | 0.85 | 0.71 | 0.77 | 250 |
| accuracy | | | 0.79 | 1000 |
| macro avg | 0.80 | 0.79 | 0.79 | 1000 |
| weighted avg | 0.80 | 0.79 | 0.79 | 1000 |

Arsitektur CNN 2 Lapis

=== Grafik Matplotlib ===




=== Classification Report ===

| | Precision | recall | f1-score | support |
|--------------|-----------|--------|-------------|---------|
| NORMAL | 0.87 | 0.91 | 0.89 | 250 |
| PNEUMONIA | 0.89 | 0.89 | 0.89 | 250 |
| PNEUMOTORAKS | 0.79 | 0.98 | 0.87 | 250 |
| TUBERCULOSIS | 0.96 | 0.69 | 0.80 | 250 |
| accuracy | | | 0.87 | 1000 |
| macro avg | 0.88 | 0.87 | 0.86 | 1000 |
| weighted avg | 0.88 | 0.87 | 0.86 | 1000 |

Arsitektur CNN 3 Lapis


=== Grafik Matplotlib ===
=== Classification Report ===



| | Precision | recall | f1-score | support |
|--------------|-----------|--------|-------------|---------|
| NORMAL | 0.88 | 0.88 | 0.88 | 250 |
| PNEUMONIA | 0.87 | 0.88 | 0.88 | 250 |
| PNEUMOTORAKS | 0.65 | 1.00 | 0.78 | 250 |
| TUBERCULOSIS | 0.98 | 0.43 | 0.60 | 250 |
| accuracy | | | 0.80 | 1000 |
| macro avg | 0.84 | 0.80 | 0.78 | 1000 |
| weighted avg | 0.84 | 0.80 | 0.78 | 1000 |

Arsitektur CNN 4 Lapis

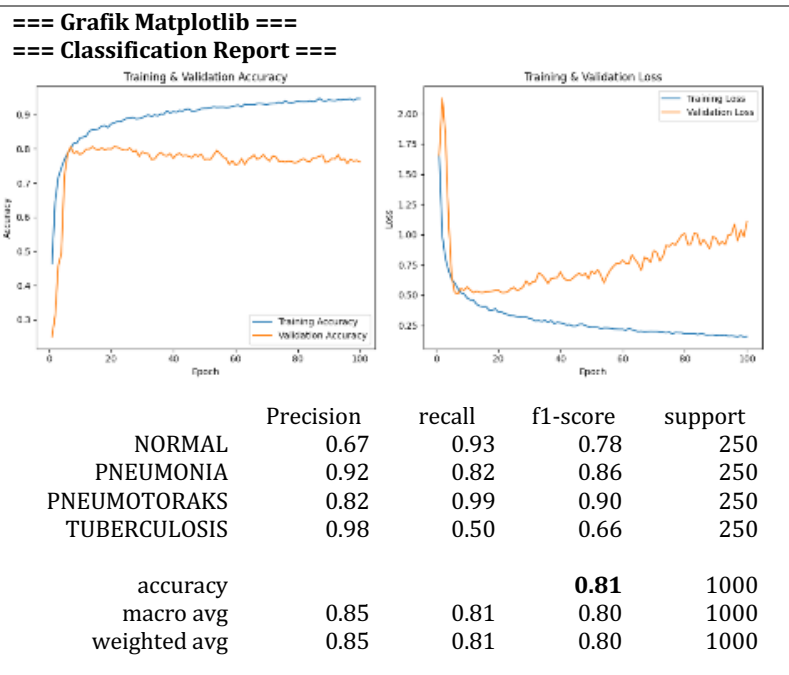
=== Grafik Matplotlib ===



=== Classification Report ===

| | Precision | recall | f1-score | support |
|--------------|-----------|--------|-------------|---------|
| NORMAL | 0.88 | 0.89 | 0.88 | 250 |
| PNEUMONIA | 0.87 | 0.90 | 0.88 | 250 |
| PNEUMOTORAKS | 0.81 | 0.98 | 0.88 | 250 |
| TUBERCULOSIS | 0.97 | 0.72 | 0.83 | 250 |
| accuracy | | | 0.87 | 1000 |
| macro avg | 0.88 | 0.87 | 0.87 | 1000 |
| weighted avg | 0.88 | 0.87 | 0.87 | 1000 |

Arsitektur CNN 5 Lapis



Berdasarkan hasil pada Tabel 2, terlihat bahwa model dengan dua dan empat lapisan CNN memberikan hasil akurasi tertinggi sebesar 87%, sedangkan model dengan satu tiga, dan lima lapisan menunjukkan akurasi yang lebih rendah. Hal ini menunjukkan bahwa penambahan lapisan konvolusi tidak selalu meningkatkan performa model, terutama jika jumlah lapisan yang digunakan terlalu sedikit atau terlalu banyak.

Pada model dengan dua lapisan CNN, akurasi meningkat (87%). Grafik menunjukkan peningkatan stabil baik pada akurasi pelatihan maupun validasi. Model juga mulai dapat mengenali pola visual yang lebih kompleks, seperti tekstur bercak putih khas pneumonia.

Pada model dengan tiga lapisan CNN, akurasi mulai menurun Kembali (80%). Hal ini disebabkan oleh kecenderungan overfitting, terlihat dari validation loss yang meningkat meskipun training accuracy terus naik. Model mulai terlalu menyesuaikan diri terhadap data pelatihan dan kehilangan kemampuan generalisasi.

Pada model dengan empat lapisan CNN, model dengan menunjukkan hasil terbaik (87%) dengan kurva accuracy yang stabil dan loss yang konvergen antara pelatihan dan validasi. Lapisan ini mampu menangkap fitur multi-level, dari tepi hingga tekstur halus, tanpa menyebabkan overfitting. Oleh karena itu, arsitektur dengan empat lapisan CNN dipilih sebagai model utama yang digunakan untuk tahap eksperimen berikutnya.

Pada model dengan lima lapisan CNN, akurasinya justru menurun menjadi 81% akibat meningkatnya kompleksitas jaringan yang dapat menyebabkan overfitting dan memperlambat proses pelatihan.

Hasil eksperimen ini menguatkan bahwa arsitektur dengan lapisan yang tidak terlalu dangkal namun juga tidak berlebihan memberikan keseimbangan terbaik dalam proses pembelajaran CNN. Dari seluruh percobaan, model CNN empat lapis terbukti sebagai arsitektur yang paling efektif, karena mampu menangkap pola visual secara lebih mendalam tanpa menimbulkan overfitting yang berlebihan. Oleh karena itu, penulis menetapkan CNN empat lapis sebagai model utama dan menjadikannya pondasi untuk eksperimen lanjutan terkait penentuan parameter pelatihan, yaitu pemilihan batch size dan image size yang paling optimal.

3.6.2 Eksperimen Parameter Tuning

Setelah arsitektur dengan empat lapisan konvolusi ditetapkan sebagai model terbaik berdasarkan hasil eksperimen sebelumnya, langkah berikutnya adalah menentukan parameter pelatihan yang paling optimal. Dua parameter utama yang diuji pada tahap ini adalah batch size dan image size, karena keduanya memiliki pengaruh langsung terhadap waktu pelatihan dan performa akurasi model CNN.

Pemilihan variasi batch size dan image size pada tahap tuning parameter ini tidak dilakukan secara acak, melainkan mengacu pada praktik umum dan rekomendasi dalam penelitian deep learning, khususnya pada klasifikasi citra medis. Menurut (Heaton, 2018b), batch size berpengaruh terhadap stabilitas proses optimasi dan kemampuan model dalam menemukan minimum yang baik, di mana batch size kecil cenderung menghasilkan pembaruan bobot yang lebih stabil dan mampu meningkatkan kemampuan generalisasi model, sedangkan batch size yang lebih besar dapat mempercepat proses pelatihan namun berisiko menyebabkan model terjebak pada minimum lokal.

Oleh karena itu, pada penelitian ini diuji batch size 8, 16, dan 32 yang merupakan rentang ukuran batch yang umum digunakan dalam penelitian klasifikasi citra medis berbasis CNN (Shorten & Khoshgoftaar, 2019). Batch size kecil seperti 8 dipilih untuk mengevaluasi kestabilan pembelajaran dan sensitivitas model terhadap detail fitur, sedangkan batch size 16 dan 32 digunakan untuk melihat pengaruh efisiensi pelatihan terhadap performa akurasi model.

Selain itu, variasi image size 240×240, 480×480, dan 640×640 dipilih untuk mengkaji pengaruh resolusi citra terhadap kemampuan model dalam mengekstraksi fitur visual. Menurut (Shorten & Khoshgoftaar, 2019), resolusi citra yang lebih tinggi dapat mempertahankan detail tekstur dan pola anatomi penting pada citra medis, namun juga meningkatkan kompleksitas komputasi dan risiko overfitting. Sebaliknya, resolusi citra yang terlalu rendah dapat mengurangi informasi visual yang dibutuhkan untuk membedakan kondisi patologis tertentu. Hasil lengkap eksperimen dapat dilihat pada tabel 3 berikut:

Tabel. 3. Tabel Eksperimen Parameter Tuning

| Batch | Image size | Accuracy | Precision | Recall | F1-Score | Time Training |
|-------|------------|------------|------------|------------|------------|--------------------------------|
| 8 | 240 | 90% | 80% | 80% | 80% | 7 jam 39 menit 20 detik |
| | 480 | 91% | 88% | 90% | 89% | 10 jam 27 menit 3 detik |
| | 640 | 93% | 90% | 92% | 91% | 11 jam 45 menit 9 detik |
| 16 | 240 | 76% | 81% | 76% | 75% | 7 jam 27 menit 31 detik |
| | 480 | 86% | 84% | 85% | 84% | 9 jam 25 menit 11detik |
| | 640 | 88% | 86% | 87% | 86% | 11 jam 30 menit 19 detik |
| 32 | 240 | 91% | 80% | 91% | 80% | 6 jam 49 menit 31 detik |
| | 480 | 88% | 90% | 88% | 88% | 11 jam 21 menit 38 detik |
| | 640 | 89% | 87% | 88% | 87% | 11 jam 16 menit 4 detik |

Berdasarkan hasil pada tabel 3, terlihat bahwa kombinasi antara batch size dan image size sangat berpengaruh terhadap kinerja model CNN.

Model dengan batch size 8 dan image size 640×640 menghasilkan performa terbaik, dengan akurasi sebesar 93%, precision 90%, recall 92%, dan F1-score 91%. Meskipun membutuhkan waktu pelatihan paling lama yaitu 11 jam 45 menit 9 detik, konfigurasi ini mampu memberikan hasil yang paling stabil dan akurat dalam mengenali pola paru-paru pada citra rontgen.

Sementara itu, model dengan batch size yang lebih besar (16 dan 32) menunjukkan waktu pelatihan yang sedikit lebih cepat, namun dengan penurunan akurasi yang signifikan. Penurunan ini disebabkan oleh proses pembaruan bobot yang lebih jarang dilakukan dalam setiap epoch, sehingga kemampuan model dalam menyesuaikan parameter terhadap variasi citra menjadi berkurang.


Dari hasil eksperimen, dapat disimpulkan bahwa kombinasi batch size 8 dan image size 640×640 memberikan hasil paling optimal dengan keseimbangan antara akurasi, presisi, dan kemampuan generalisasi model terhadap data baru. Walaupun waktu pelatihannya lebih lama, konfigurasi ini menghasilkan model yang lebih stabil dan

akurat dibandingkan konfigurasi lainnya. Oleh karena itu, model dengan batch size 8 dan image size 640×640 dipilih sebagai konfigurasi final yang akan digunakan untuk pelatihan penuh dan evaluasi.

3.6.3 Arsitektur Model CNN Final

Setelah melalui rangkaian eksperimen yang sistematis, baik pada variasi jumlah lapisan CNN maupun parameter pelatihan seperti batch size dan image size, penulis menetapkan bahwa model CNN dengan empat lapisan konvolusi merupakan konfigurasi paling optimal untuk mendeteksi penyakit paru-paru. Model ini menggunakan batch size sebesar 8 dan image size 640×640 , yang berdasarkan hasil evaluasi memberikan performa paling konsisten, stabil, dan akurat dibandingkan dengan model-model lain yang diuji.

Model final ini mampu mencapai akurasi sebesar 93%, dengan nilai precision 90%, recall 92%, dan F1-score 91%, sehingga melampaui seluruh tolok ukur performa yang telah ditetapkan pada Bab 3. Capaian tersebut menunjukkan bahwa model tidak hanya mampu mengklasifikasikan citra rontgen secara tepat, tetapi juga memiliki kemampuan yang baik dalam mendeteksi kasus positif serta meminimalkan kesalahan prediksi.



Gambar 4. Alur Kerja CNN 4 Lapis

Alur kerja model CNN final ini dapat dilihat pada gambar 4 yang dimulai dengan proses input citra rontgen dada berukuran 640×640 piksel, yang kemudian diproses secara bertahap melalui empat lapisan konvolusi. Setiap lapisan konvolusi berfungsi untuk mengekstraksi fitur dengan tingkat kompleksitas yang semakin tinggi. Lapisan konvolusi awal berfokus pada fitur-fitur dasar seperti tepi dan pola tekstur kasar, sementara lapisan konvolusi selanjutnya menangkap pola visual yang lebih kompleks, seperti struktur jaringan paru-paru dan indikasi kelainan yang bersifat lebih halus.

Pada setiap lapisan konvolusi, diterapkan fungsi aktivasi ReLU untuk meningkatkan kemampuan non-linearitas model, diikuti oleh Batch Normalization yang berperan dalam menstabilkan distribusi nilai aktivasi serta mempercepat proses

konvergensi selama pelatihan. Selanjutnya, MaxPooling digunakan untuk mengurangi dimensi spasial citra secara bertahap, sehingga kompleksitas komputasi dapat ditekan tanpa menghilangkan informasi fitur yang penting. Setelah melewati keempat lapisan konvolusi, fitur-fitur hasil ekstraksi yang telah terorganisasi secara hierarkis kemudian diratakan menggunakan Flatten, sehingga membentuk vektor satu dimensi. Vektor ini selanjutnya diproses oleh lapisan fully connected (Dense) untuk menggabungkan seluruh fitur yang telah dipelajari menjadi representasi yang lebih komprehensif. Untuk mengurangi risiko overfitting, diterapkan Dropout, yang membantu meningkatkan kemampuan generalisasi model terhadap data baru. Tahap akhir dari alur kerja CNN empat lapisan ini adalah lapisan output dengan fungsi aktivasi Softmax, yang menghasilkan probabilitas untuk setiap kelas penyakit paru-paru. Kelas dengan probabilitas tertinggi dipilih sebagai hasil prediksi akhir model.

Pemilihan arsitektur CNN dengan empat lapisan konvolusi dilakukan karena mampu memberikan keseimbangan terbaik antara kedalaman jaringan dan efisiensi proses pembelajaran. Model dengan jumlah lapisan yang lebih sedikit terbukti belum mampu menangkap kompleksitas pola visual pada citra rontgen, sementara model yang terlalu dalam cenderung mengalami overfitting dan tidak memberikan peningkatan performa yang signifikan. Dengan empat lapisan konvolusi, model dapat mengekstraksi fitur secara bertahap dan mendalam tanpa mengorbankan stabilitas pelatihan.

Selain itu, struktur arsitektur ini terbukti menghasilkan representasi fitur yang lebih kuat, menjaga konsistensi hasil prediksi pada berbagai kondisi citra, serta meningkatkan kemampuan generalisasi terhadap data yang belum pernah dilihat sebelumnya. Keseimbangan antara akurasi, efisiensi, dan generalisasi inilah yang menjadikan CNN empat lapisan sebagai model final yang digunakan dalam penelitian ini. Secara keseluruhan, model final ini memberikan fondasi yang kokoh bagi sistem deteksi penyakit paru-paru berbasis deep learning dan menjadi konfigurasi paling ideal untuk diintegrasikan ke dalam tahap evaluasi lanjutan serta implementasi pada sistem LungCare

3.7 Deployment

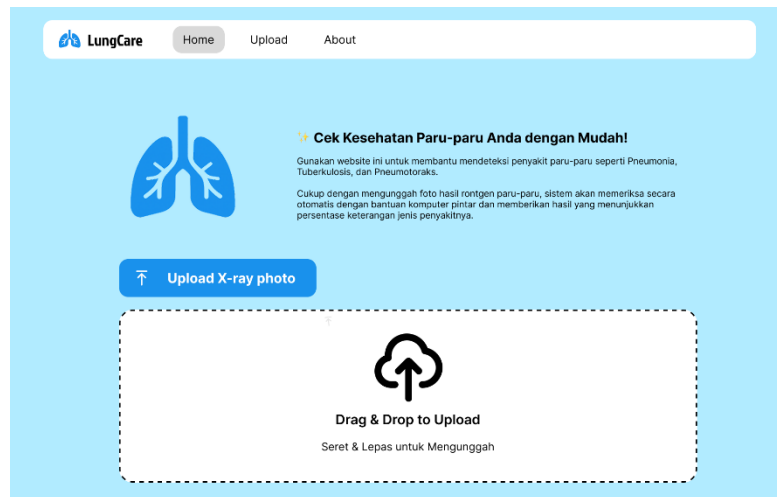
Tahapan deployment merupakan proses penerapan sistem yang telah dibuat agar dapat dijalankan dan diakses oleh pengguna secara langsung. Pada tahap ini, model deep learning yang telah dilatih diintegrasikan dengan antarmuka web sehingga dapat digunakan untuk mendeteksi penyakit paru-paru berdasarkan citra rontgen.

Sistem ini terbagi menjadi dua bagian utama, yaitu backend dan frontend, yang masing-masing memiliki peran penting dalam proses kerja keseluruhan sistem. Pada bagian backend, digunakan framework Flask yang berfungsi sebagai jembatan antara model deep learning dan aplikasi web. Di dalamnya terdapat model CNN yang telah melalui proses pelatihan sebelumnya dan disimpan dalam format (.h5). Model ini bertugas untuk melakukan analisis serta klasifikasi terhadap citra rontgen paru-paru yang diunggah pengguna. Selain itu, Flask juga berperan sebagai Application Programming Interface (API) yang menerima data citra dari web, menjalankan proses preprocessing, melakukan prediksi menggunakan model, kemudian mengirimkan hasil prediksi dalam format JSON kembali ke web.

Sementara itu, bagian frontend dibangun menggunakan kombinasi PHP, HTML, CSS, dan JavaScript sebagai antarmuka pengguna. Pada bagian ini, pengguna dapat berinteraksi langsung dengan sistem, seperti mengunggah citra rontgen, melihat hasil analisis, hingga menyimpan hasil pemeriksaan. Tampilan antarmuka dibuat dengan konsep sederhana dan responsif agar mudah diakses oleh pengguna.

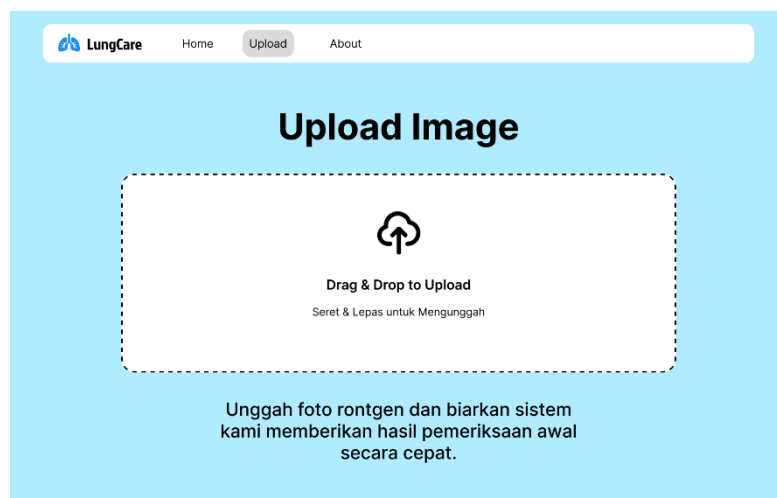
Kedua bagian tersebut terhubung melalui protokol HTTP yang memungkinkan pertukaran data antara web dan server secara real-time. Ketika pengguna mengunggah citra melalui halaman web, file tersebut dikirim ke server Flask untuk dianalisis oleh model CNN. Setelah proses analisis selesai, hasil prediksi dikembalikan ke aplikasi web dan ditampilkan dalam bentuk visual persentase serta grafik batang yang mudah dipahami oleh pengguna. Dengan arsitektur ini, sistem LungCare mampu bekerja secara efisien dan memberikan pengalaman penggunaan yang cepat, praktis, dan informatif.

Desain UI/UX pada sistem LungCare yang penulis buat terdiri dari empat bagian utama, yaitu halaman utama (Home), halaman unggah (Upload), halaman hasil (Hasil Pemeriksaan), dan halaman informasi (About). Berikut masing-masing tampilan antarmuka:



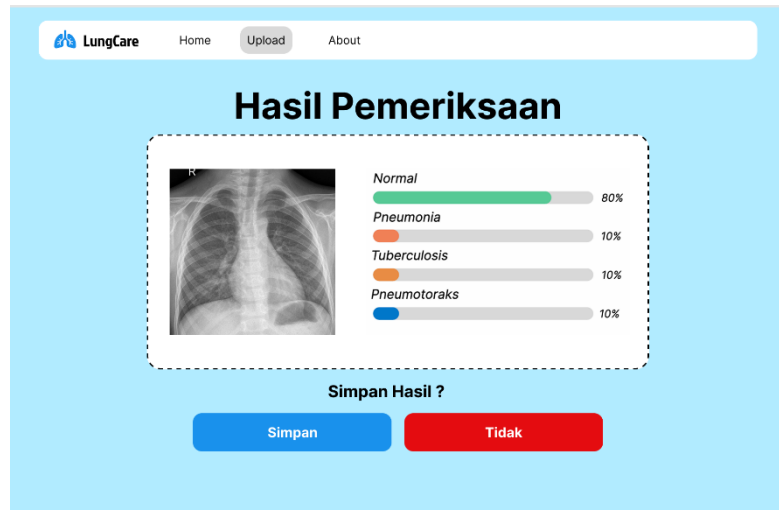
Gambar 5. UI/UX Halaman Utama

Gambar 5 merupakan tampilan pertama yang diakses oleh pengguna. Pada halaman utama terdapat logo aplikasi LungCare, menu navigasi, serta penjelasan singkat mengenai fungsi sistem. Selain itu, halaman ini juga menampilkan tombol untuk mengunggah citra rontgen paru-paru. Desain halaman utama menampilkan kombinasi teks informatif dan ilustrasi yang menarik untuk memperkenalkan fitur sistem secara jelas.



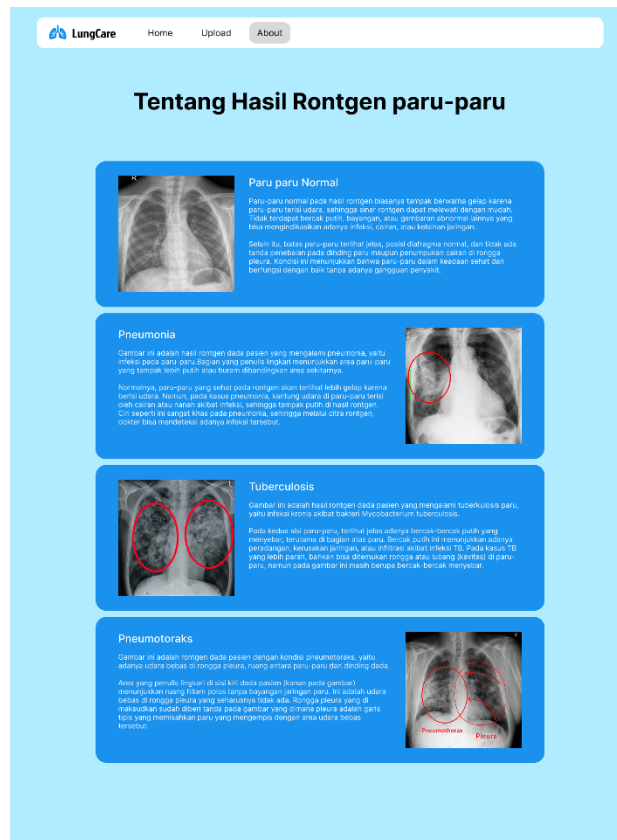
Gambar 2. UI/UX Halaman Upload

Gambar 6 merupakan bagian utama di mana pengguna dapat mengunggah citra rontgen yang akan diperiksa. Sistem menyediakan dua metode unggah, yaitu melalui tombol Upload maupun fitur drag and drop. Setelah pengguna memilih gambar, sistem otomatis mengirimkan file ke server Flask untuk diproses oleh model deep learning. Desain halaman ini dibuat minimalis dengan ikon besar dan teks petunjuk yang mudah dipahami sehingga memudahkan pengguna dalam proses unggah gambar.



Gambar 7. UI/UX Halaman Pemeriksaan

Setelah proses prediksi selesai, pengguna diarahkan ke halaman hasil pemeriksaan yang dapat dilihat pada gambar 7. Pada halaman ini ditampilkan hasil analisis model dalam bentuk persentase untuk empat kategori, yaitu Normal, Pneumonia, Tuberculosis, dan Pneumotoraks. Nilai hasil klasifikasi divisualisasikan menggunakan grafik batang dengan warna berbeda pada setiap kategori agar mudah dibedakan. Selain itu, halaman ini juga menyediakan tombol “Simpan” yang memungkinkan pengguna mengunduh hasil pemeriksaan dalam bentuk gambar untuk keperluan dokumentasi pribadi.



Gambar 2. UI/UX Halaman About

Tampilan pada gambar 8 berfungsi sebagai sarana edukasi bagi pengguna. Di dalamnya terdapat penjelasan mengenai empat kategori penyakit paru-paru berdasarkan hasil citra rontgen, yaitu Normal, Pneumonia, Tuberculosis, dan Pneumotoraks. Masing-masing kategori disertai gambar contoh citra rontgen dan penjelasan singkat tentang karakteristik visual yang membedakan satu dengan yang lain. Dengan adanya halaman ini, pengguna dapat memahami arti dari hasil pemeriksaan yang diberikan oleh sistem.

KESIMPULAN

Berdasarkan seluruh tahapan penelitian yang telah dilakukan, mulai dari pengumpulan data, perancangan model, proses pelatihan, hingga evaluasi hasil, dapat disimpulkan bahwa penerapan metode Convolutional Neural Network (CNN) mampu memberikan kinerja yang baik dalam mendeteksi penyakit paru-paru melalui citra rontgen dada. Penelitian ini berhasil mengembangkan sebuah model deep learning berbasis CNN yang dapat mengklasifikasikan citra rontgen ke dalam empat kategori kondisi paru-paru, yaitu Normal, Pneumonia, Tuberculosis, dan Pneumotoraks, melalui proses eksperimen yang sistematis meliputi penentuan arsitektur jaringan, pengujian

variasi jumlah lapisan, serta optimasi parameter pelatihan. Hasil pengujian menunjukkan bahwa konfigurasi jumlah lapisan CNN yang digunakan mampu memberikan keseimbangan yang optimal antara kedalaman jaringan dan stabilitas performa tanpa menimbulkan overfitting yang signifikan, sementara kombinasi parameter pelatihan terbaik diperoleh pada batch size sebesar 8 dan ukuran citra 640×640. Model CNN final yang dihasilkan mampu mencapai akurasi sebesar 93%, dengan nilai precision sebesar 90%, recall sebesar 92%, dan F1-score sebesar 91%, yang menunjukkan kemampuan klasifikasi yang seimbang pada seluruh kelas penyakit serta melampaui kriteria evaluasi yang telah ditetapkan. Selain itu, model yang dikembangkan memiliki kemampuan generalisasi yang baik dan berhasil diintegrasikan ke dalam aplikasi berbasis web, sehingga dapat berfungsi sebagai sistem pendukung deteksi dini penyakit paru-paru yang cepat, efisien, dan mudah diakses. Secara keseluruhan, penelitian ini berhasil mencapai seluruh tujuan yang telah dirumuskan, membuktikan keandalan metode CNN dalam analisis citra medis, serta memberikan landasan yang kuat bagi pengembangan sistem deteksi penyakit paru-paru berbasis kecerdasan buatan pada penelitian selanjutnya.

DAFTAR PUSTAKA

- Ahmad Izzan Kautsar, Bayu Rahayudi, & Lailil Muflikhah. (2017). Analisis Performa Model Convolutional Neural Network Dalam Mendeteksi Penyakit Pneumonia (Vol. 1, Nomor 1). <http://j-ptiik.ub.ac.id>
- Dipdo PWidjaya, Zulkifli Amin, Suprayitno, Rahmi Afifi, & Hamzah Shatri. (2014). Karakteristik dan Faktor-Faktor yang Mempengaruhi Kesintasan Pasien Pneumotoraks di Rumah Sakit Cipto Mangunkusumo, Jakarta.
- Geert Litjens, Thijs Kooi, Babak Ehteshami Bejnordi, Arnaud Arindra Adiyoso Setio, Francesco Ciompi, Mohsen Ghahfoorian, Jeroen A.W.M. van der Laak, Bram van Ginneken, & Clara I. Sánchez. (2017). A survey on deep learning in medical image analysis. Dalam *Medical Image Analysis* (Vol. 42, hlm. 60–88). Elsevier B.V. <https://doi.org/10.1016/j.media.2017.07.005>
- Hantian Dong, Biaokai Zhu, Xinri Zhang, & Xiaomei Kong. (2022). Use data augmentation for a deep learning classification model with chest X-ray clinical imaging featuring coal workers' pneumoconiosis. <https://doi.org/https://doi.org/10.1186/s12890-022-02068-x>
- Indah Kurniawati, Ridho Akbar, Izza Fahma Kusumawati, & Yessie Ardina Kusuma. (2024). Identifikasi Pneumonia pada Balita melalui Citra X-ray Menggunakan Metode Convolutional Neural Network (CNN). *Journal of Manufacturing in Industrial Engineering & Technology*, 3(1), 10–23. <https://doi.org/10.30651/mine-tech.v3i1.23391>
- Mienye, I. D., Swart, T. G., Obaido, G., Jordan, M., & Ilono, P. (2025). Deep Convolutional Neural Networks in Medical Image Analysis: A Review. *Information*, 16(3), 195. <https://doi.org/10.3390/info16030195>

- Paul Mooney. (2018). Chest X-Ray Images (Pneumonia). Kaggle. <https://www.kaggle.com/datasets/paultimothymooney/chest-xray-pneumonia>
- Pebri Andhi Herry Pratama, Rony Teguh, Abertun Sagit Sahay, & Valencia Wilentine. (2021). Deteksi COVID-19 Berdasarkan Hasil Rontgen Dada (Chest Xray) Menggunakan Python. Dalam JOINTECOMS (Journal of Information Technology and Computer Science) p-ISSN: xxxx-xxxx (Vol. 1, Nomor 1).
- Perani Rosyani, Abrar Sachio Rizqi Susilo Effendy, Muhammad Alfin Gio Abidin, Rafly Ramandha Kusuma, & Rizki Waluya Ramadhan. (2024). Klasifikasi Penyakit Paru-Paru Berbasis Pengolahan Citra X-Ray Menggunakan Convolutional Neural Network. <https://jurnalmahasiswa.com/index.php/biikma>
- Pranav Rajpurkar, Jeremy Irvin, Kaylie Zhu, Brandon Yang, Hershel Mehta, Tony Duan, Daisy Ding, Aarti Bagul, Robyn L. Ball, Curtis Langlotz, Katie Shpanskaya, Matthew P. Lungren, & Andrew Y. Ng. (2017). CheXNet: Radiologist-Level Pneumonia Detection on Chest X-Rays with Deep Learning. <http://arxiv.org/abs/1711.05225>
- Saman Motamed, Patrik Rogalla, & Farzad Khalvati. (2021). Data augmentation using Generative Adversarial Networks (GANs) for GAN-based detection of Pneumonia and COVID-19 in chest X-ray images. *Informatics in Medicine Unlocked*, 27. <https://doi.org/10.1016/j.imu.2021.100779>
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, 6(1), 60. <https://doi.org/10.1186/s40537-019-0197-0>
- Siddhanth Tripathi, Somil Jain, Sinchana Shetty, & Vanshika Sharma. (2021). Lung Disease Detection Using Deep Learning. *International Journal of Innovative Technology and Exploring Engineering (IJITEE)*, 2278–3075. <https://doi.org/10.35940/ijitee.H9259.0610821>
- Tawsifur Rahman. (2021). Tuberculosis (TB) Chest X-ray Database. Kaggle. <https://www.kaggle.com/datasets/tawsifurrahman/tuberculosis-tb-chest-xray-dataset>
- vbookshelf. (2020). Chest X-Ray Images with Pneumothorax Masks. Kaggle. <https://www.kaggle.com/datasets/vbookshelf/pneumothorax-chest-xray-images-and-masks>
- Viktoria Thanita. (2024). Pneumotoraks Spontan Sekunder akibat Tuberkulosis Paru. *MEDICINUS*, 37(1), 45–48. <https://doi.org/10.56951/66c77517>
- World Health Organization. (2022, November 11). Pneumonia in children. World Health Organization. <https://www.who.int/news-room/fact-sheets/detail/pneumonia>
- Yann Lecun, Yoshua Bengio, & Geoffrey Hinton. (2016). Deep learning. Dalam *Nature* (Vol. 521, Nomor 7553, hlm. 436–444). Nature Publishing Group. <https://doi.org/10.1038/nature14539>