

BAB II

KAJIAN PUSTAKA

A. Kajian Teoritis

1. *Artificial Intelligence*

Artificial Intelligence (AI) merupakan teknologi komputasi yang mengembangkan sistem cerdas untuk meniru kemampuan kognitif manusia, seperti belajar dari data, melakukan penalaran, mengenali pola, memecahkan masalah, serta mendukung pengambilan keputusan secara otomatis. AI memanfaatkan berbagai teknik, seperti *Machine Learning*, *Deep Learning*, dan *Natural Language Processing*, untuk menghasilkan prediksi maupun rekomendasi berdasarkan data yang tersedia. Dalam bidang kesehatan, AI berperan penting dalam meningkatkan kualitas layanan melalui analisis data medis yang cepat, akurat, dan berbasis bukti (Kuwaiti et al., 2023)

Menurut Bitkina et al. (2023), *Artificial Intelligence* merupakan teknologi yang semakin banyak diterapkan dalam berbagai bidang ilmu pengetahuan dan teknologi, khususnya pada sektor Kesehatan. AI memungkinkan sistem medis melakukan analisis terhadap data klinis, citra medis, serta informasi pasien secara otomatis untuk mendukung proses diagnosis, pemantauan kondisi pasien, pengambilan keputusan klinis, hingga peningkatan efisiensi pelayanan kesehatan. Selain itu, penerapan AI juga berkontribusi dalam meningkatkan akurasi diagnosis, mengurangi

beban kerja tenaga medis, serta mempercepat proses pengolahan data medis yang kompleks.


Selanjutnya, Fasterholdt et al. (2023), mendefinisikan *Artificial Intelligence* sebagai sistem yang mampu menginterpretasikan informasi, belajar dari data, serta menghasilkan keluaran yang bertujuan untuk menyelesaikan tugas atau mencapai tujuan tertentu. AI mencakup berbagai teknologi seperti *Machine Learning*, *Deep Learning*, dan *neural network* yang banyak diterapkan pada bidang pencitraan medis (*Medical Imaging*). Dalam radiologi, AI dimanfaatkan untuk membantu proses analisis citra, meningkatkan akurasi interpretasi hasil pemeriksaan, serta mendukung pengambilan keputusan klinis secara lebih cepat dan konsisten.

Berdasarkan beberapa definisi tersebut, dapat disimpulkan bahwa *Artificial Intelligence* merupakan teknologi komputasi yang dirancang untuk meniru kemampuan intelektual manusia melalui proses pembelajaran berbasis data, pengenalan pola, analisis, dan pengambilan keputusan secara otomatis. Dalam penelitian ini, *Artificial Intelligence* menjadi landasan utama dalam pengembangan sistem klasifikasi penyakit kanker paru-paru berbasis citra CT-Scan melalui penerapan *Convolutional Neural Network* (CNN) yang terintegrasi dengan *Clinical Decision Support System* (CDSS) sehingga mampu membantu proses diagnosis secara lebih akurat, cepat, dan efisien.

2. *Convolutional Neural Network (CNN)*

Convolutional Neural Network (CNN) adalah arsitektur *Deep Learning* yang dirancang untuk memproses data berbentuk citra melalui operasi konvolusi yang memungkinkan sistem mengekstraksi fitur secara otomatis dan hierarkis dari data visual (Mienye et al., 2025). CNN memanfaatkan lapisan konvolusi, fungsi aktivasi, dan pooling untuk mengenali pola spasial kompleks pada citra medis seperti CT-Scan, sehingga efektif dalam tugas klasifikasi dan deteksi kelainan.

Lebih lanjut Salehi et al. (2023), menjelaskan bahwa kekuatan utama CNN dalam pemrosesan citra medis terletak pada kemampuannya menjaga hubungan struktural antar piksel melalui penggunaan bobot bersama (*weight sharing*) dan bidang penerimaan lokal (*local receptive fields*). Secara umum, arsitektur standar CNN terdiri atas lapisan konvolusi untuk ekstraksi fitur linear, lapisan aktivasi non-linear (seperti ReLU), lapisan *pooling* untuk reduksi dimensi spasial, serta lapisan terhubung penuh (*fully connected layer*) di bagian akhir untuk memetakan fitur menjadi kelas diagnosis. Representasi visual dari susunan blok hierarki standar pada arsitektur CNN ini dapat dilihat pada Gambar 2.1 berikut.



Gambar 2. 1 Arsitektur CNN (Salehi et al., 2023)

Menurut Mohod et al. (2024), CNN merupakan jaringan saraf tiruan yang secara khusus dikembangkan untuk analisis citra medis karena kemampuannya dalam mengurangi kebutuhan rekayasa fitur manual dan meningkatkan akurasi diagnosis berbasis computer. CNN bekerja dengan menerapkan filter konvolusi untuk mengidentifikasi pola lokal penting, kemudian menggabungkannya menjadi representasi fitur tingkat tinggi yang mendukung proses klasifikasi penyakit.

Secara matematis, operasi konvolusi dua dimensi (2D) yang menjadi inti dari arsitektur ini dirumuskan pada persamaan 2.1 sebagai berikut:

$$S(i, j) = (I * K)(i, j) = \sum_m \sum_n I(i + m, j + n)K(m, n) \quad (2.1)$$

Persamaan tersebut tidak sekadar menyimbolkan perkalian dua buah matriks, melainkan merepresentasikan proses pemindaian spasial

(*spatial scanning*). Secara operasional, sebuah matriks filter atau kernel (K) berdimensi (m, n) akan digeser (*sliding*) langkah demi langkah melintasi seluruh area matriks citra masukan (I). Pada setiap pergeserannya menuju koordinat spasial (i, j) , sistem melakukan perkalian elemen-demi-elemen (*element-wise multiplication*) antara intensitas piksel citra dengan bobot kernel yang menyimpannya, lalu menjumlahkan seluruh hasil perkalian tersebut. Nilai akumulasi inilah yang kemudian membentuk satu titik piksel baru, $S(i, j)$, pada *feature map* keluaran. Melalui mekanisme operasi konvolusi $(*)$ ini, CNN mampu menangkap informasi ketetanggaan antar-piksel untuk mengenali pola lokal penting, seperti garis tepi nodul, sudut, atau tekstur massa tumor pada citra medis.


Selanjutnya, untuk menghasilkan keluaran akhir pada suatu lapisan konvolusi ke- l yang telah ditambahkan nilai bias dan dilewatkan pada fungsi aktivasi, digunakan persamaan 2.2 berikut

$$x_j^l = f \left(\sum_i x_i^{l-1} * k_{ij}^l + b_j^l \right) \quad (2.2)$$

Persamaan ini menjelaskan siklus penuh transformasi data di dalam satu lapisan (*layer*) CNN. Alih-alih hanya menggunakan satu filter, sistem akan mengakumulasikan seluruh hasil konvolusi dari sekumpulan *feature map* masukan pada lapisan sebelumnya (X_i^{l-1}) dengan beragam kernel konvolusi spesifik (K_{ij}^l). Hasil agregasi spasial ini kemudian ditambahkan dengan parameter skalar bias (B_j^l) yang bertindak sebagai pengatur ambang batas (*threshold*). Langkah komputasi terakhir yang sangat krusial adalah

mentransformasikan hasil penjumlahan linear tersebut menggunakan fungsi aktivasi non-linear f , seperti *Rectified Linear Unit* (ReLU). Fungsi aktivasi ini bekerja sebagai gerbang keputusan penentu yang akan mengevaluasi apakah sinyal fitur medis yang diekstraksi cukup signifikan untuk "diaktifkan" dan diteruskan sebagai *feature map* keluaran akhir (Y_j^l), atau justru ditekan menjadi nol agar tidak membebani komputasi jaringan pada lapisan selanjutnya.

Dalam perkembangannya, berbagai variasi arsitektur CNN tingkat lanjut seperti VGG, *Inception*, dan *Residual Network* (ResNet) telah dikembangkan secara masif untuk menyelesaikan problem spesifik pada domain pencitraan medis, baik untuk segmentasi organ, deteksi lesi, maupun klasifikasi tumor. Pemetaan taksonomi mengenai implementasi dan variasi pemodelan CNN pada bidang medis ini dapat dilihat pada Gambar 2.2 berikut.




Gambar 2. 2 Pemetaan Taksonomi (Salehi et al., 2023)

Selanjutnya Hu et al. (2022), menjelaskan bahwa CNN telah banyak digunakan dalam berbagai aplikasi medis karena kemampuannya memproses data citra dalam jumlah besar serta mempertahankan karakteristik spasial penting dari struktur anatomi. CNN dinilai mampu

meningkatkan konsistensi dan efisiensi interpretasi citra radiologi, terutama dalam konteks sistem diagnosis berbantuan komputer.

Namun, pelatihan model CNN dari awal (*from scratch*) pada domain medis sering kali menghadapi kendala keterbatasan jumlah *dataset* klinis yang terlabeli secara masif. Untuk mengatasi keterbatasan data tersebut, teknik *Transfer Learning* diadopsi dengan memanfaatkan parameter bobot yang telah dilatih sebelumnya (*pre-trained weights*) dari basis data berskala besar, yang kemudian disesuaikan (*fine-tuning*) ke dalam variasi citra medis target. Mekanisme pengalihan pengetahuan algoritmik dari domain umum ke domain medis spesifik ini dapat dilihat pada Gambar 2.3 berikut.



Gambar 2. 3 *Convolutional Process* (Salehi et al., 2023)

Berdasarkan beberapa definisi tersebut, dapat disimpulkan bahwa *Convolutional Neural Network* (CNN) adalah model *Deep Learning* berbasis konvolusi yang dirancang untuk mengekstraksi dan mempelajari fitur citra secara otomatis, sehingga sangat relevan sebagai fondasi algoritmik dalam pengembangan sistem deteksi penyakit berbasis citra CT-Scan pada penelitian ini.

3. *Residual Network (ResNet)*

Residual Network (ResNet) adalah arsitektur *Deep Learning* berbasis konvolusi tingkat lanjut yang memperkenalkan konsep pembelajaran residual untuk melatih jaringan saraf dengan kedalaman ekstrem. ResNet memanfaatkan struktur blok residual khusus untuk mempertahankan performa komputasi dan mencegah terjadinya penurunan akurasi seiring bertambahnya jumlah lapisan dalam jaringan.


Menurut Salehi et al. (2023), karakteristik utama dari arsitektur ResNet terletak pada penggunaan koneksi pintas (*shortcut* atau *skip connections*) yang menghubungkan input suatu lapisan langsung ke output lapisan berikutnya tanpa melalui proses konvolusi berulang. Struktur residual ini secara efektif mengatasi fenomena hilangnya gradien (*vanishing gradient problem*) yang sering kali menyebabkan kegagalan konvergensi pada model-model jaringan saraf konvensional yang sangat dalam.

Selanjutnya Selvaraju et al. (2019), menunjukkan bahwa penggunaan arsitektur berlapis dalam seperti ResNet sangat efektif untuk mengekstraksi representasi fitur spasial yang kaya dan kompleks dari suatu objek visual. Meskipun struktur jaringannya sangat dalam dan kompleks, model ini tetap mampu mempertahankan kapabilitas lokalisasi fitur yang kuat, sehingga sangat andal ketika diintegrasikan dengan metode penalaran visual untuk mengidentifikasi letak anomali secara spesifik.

Di sisi lain Mohammadpour et al. (2022), menjelaskan bahwa variasi arsitektur jaringan saraf dalam seperti ResNet telah diadopsi secara

luas di berbagai domain klasifikasi karena efisiensinya dalam meminimalkan beban komputasi manual serta kemampuannya mengoptimalkan ekstraksi pola dari representasi data berdimensi tinggi. Implementasi arsitektur ini terbukti memberikan skalabilitas yang baik serta konsistensi performa yang tinggi saat menangani dataset dengan variabilitas kelas yang rumit.

Hubungan antara kedalaman lapisan ekstraksi ResNet dan kemampuan interpretabilitas visualnya dapat ditunjukkan secara empiris melalui pemetaan aktivasi kelas. Sebagaimana ditunjukkan pada Gambar 2.4, fitur spasial kompleks yang berhasil diekstraksi oleh lapisan konvolusi terakhir dari arsitektur ResNet diproses menggunakan perhitungan nilai gradien dari kelas target untuk menghasilkan peta lokasi kasar (*coarse localization map*). Representasi visual berupa peta intensitas warna (*heatmap*) tersebut secara transparan menonjolkan area-area penting dari suatu citra objek yang menjadi dasar bagi model ResNet dalam mengambil keputusan klasifikasi. Implementasi visualisasi ini menjadi landasan penting dalam penelitian LungScan AI untuk menerjemahkan model *black-box* menjadi informasi letak anomali lesi paru-paru yang dapat dipahami oleh pengguna.



Gambar 2. 4 Visualisasi ResNet Grad-CAM (Selvaraju et al., 2019)

Berdasarkan beberapa definisi tersebut, dapat disimpulkan bahwa *Residual Network* (ResNet) adalah model *Deep Learning* berskala dalam yang mengintegrasikan mekanisme *skip connections* untuk mengoptimalkan aliran informasi dan mengatasi kendala degradasi akurasi pada jaringan konvolusi. Karakteristik tersebut menjadikan ResNet sangat relevan digunakan sebagai komponen utama dalam arsitektur klasifikasi ganda untuk mengekstrak fitur visual citra medis secara akurat dan konsisten pada penelitian ini.

4. *Clinical Decision Support System* (CDSS)

Clinical Decision Support System (CDSS) adalah sistem berbasis komputer yang dirancang untuk membantu tenaga kesehatan dalam proses pengambilan keputusan klinis dengan memanfaatkan data pasien, basis

pengetahuan medis, serta aturan atau algoritma tertentu (Bayor et al., 2025). CDSS bertujuan meningkatkan kualitas pelayanan kesehatan melalui penyediaan rekomendasi berbasis bukti (*evidence-based*) yang terintegrasi dengan alur kerja klinis.

Menurut Mebrahtu et al. (2021), CDSS merupakan sistem digital yang memberikan dukungan terhadap keputusan klinis melalui pemberian peringatan, pengingat, maupun rekomendasi diagnostik dan terapeutik berdasarkan data pasien yang tersedia. CDSS dinilai mampu meningkatkan kepatuhan terhadap pedoman klinis serta mengurangi variasi praktik medis yang tidak terstandar.

Selanjutnya Sutton et al. (2020), mendefinisikan CDSS sebagai teknologi yang menggabungkan data klinis individual dengan basis pengetahuan terstruktur untuk menghasilkan saran atau rekomendasi yang mendukung proses diagnosis dan penentuan terapi. CDSS tidak menggantikan peran dokter, tetapi berfungsi sebagai alat bantu untuk meningkatkan akurasi dan efisiensi pengambilan keputusan dalam praktik medis.

Berdasarkan beberapa definisi tersebut, dapat disimpulkan bahwa *Clinical Decision Support System* (CDSS) adalah sistem berbasis teknologi informasi yang memproses data klinis dan pengetahuan medis untuk menghasilkan rekomendasi diagnostik atau terapeutik secara sistematis. Dalam konteks penelitian ini, CDSS berperan sebagai komponen yang

menghubungkan hasil deteksi penyakit berbasis CNN dengan rekomendasi tindakan klinis yang relevan dan terstruktur.

5. Metode Agile

Metode Agile adalah pendekatan pengembangan perangkat lunak yang menekankan fleksibilitas, kolaborasi tim, respons cepat terhadap perubahan, serta pengembangan sistem secara iteratif dan inkremental. Agile berfokus pada penyampaian perangkat lunak yang berfungsi dalam siklus pengembangan singkat (*iteration/sprint*) sehingga memungkinkan evaluasi dan perbaikan berkelanjutan selama proses pengembangan berlangsung (Al-saqqa et al., 2021).

Menurut Al-saqqa et al. (2021), *Agile Software Development* merupakan pendekatan yang mengutamakan interaksi individu, perangkat lunak yang berfungsi, kolaborasi dengan pengguna, serta adaptasi terhadap perubahan kebutuhan dibandingkan perencanaan yang kaku. Pendekatan ini banyak digunakan dalam pengembangan sistem modern karena mampu meningkatkan kualitas produk dan kepuasan pengguna melalui umpan balik yang berkelanjutan.

Selanjutnya Noteboom et al. (2021), mendefinisikan *Agile Project Management* sebagai metode manajemen proyek yang mendukung pengembangan bertahap melalui iterasi pendek, evaluasi rutin, dan keterlibatan aktif pemangku kepentingan untuk memastikan kesesuaian produk dengan kebutuhan pengguna. *Agile* dinilai efektif dalam proyek yang memiliki tingkat ketidakpastian tinggi serta kebutuhan yang dinamis.

Selain itu, Abbas et al. (2022), menjelaskan bahwa metode *Agile* mendukung pengembangan sistem berbasis eksperimen dan validasi berulang, sehingga risiko kegagalan proyek dapat diminimalkan melalui pengujian bertahap dan perbaikan terus-menerus. Pendekatan ini sangat relevan untuk pengembangan sistem berbasis teknologi cerdas yang memerlukan proses penyempurnaan model dan fitur secara iteratif.

Berdasarkan beberapa definisi tersebut, dapat disimpulkan bahwa metode *Agile* adalah pendekatan pengembangan perangkat lunak yang bersifat iteratif, adaptif, dan kolaboratif, dengan fokus pada peningkatan kualitas produk melalui siklus pengembangan bertahap dan umpan balik berkelanjutan. Dalam penelitian ini, metode *Agile* menjadi landasan dalam merancang, mengembangkan, dan memvalidasi sistem deteksi penyakit berbasis CT-Scan secara bertahap, mulai dari analisis kebutuhan, pengembangan prototipe, hingga pengujian fungsional sistem.

6. *Deep Learning*

Deep Learning adalah cabang dari *Machine Learning* yang menggunakan jaringan saraf tiruan berlapis untuk mempelajari pola kompleks dari data dalam jumlah besar. Model ini bekerja dengan membentuk representasi data secara bertahap, mulai dari fitur sederhana hingga fitur yang lebih abstrak dan kompleks. Dalam konteks pengolahan citra, *Deep Learning* memungkinkan sistem mengenali pola visual tanpa harus bergantung sepenuhnya pada proses ekstraksi fitur manual. Menurut Alzubaidi et al. (2021), *Deep Learning* memiliki kemampuan penting dalam

mempelajari representasi data secara otomatis melalui beberapa lapisan komputasi, sehingga banyak digunakan dalam klasifikasi, deteksi, segmentasi, dan analisis citra. Kemampuan tersebut menjadikan *Deep Learning* relevan untuk pengembangan produk berbasis kecerdasan buatan, terutama ketika data yang digunakan memiliki karakteristik visual yang kompleks. Oleh karena itu, *Deep Learning* dapat dijadikan landasan utama dalam penelitian yang bertujuan mengembangkan sistem klasifikasi otomatis berbasis citra.

Menurut Abdel-jaber et al. (2022), *Deep Learning* memanfaatkan struktur jaringan saraf berlapis untuk mengolah data seperti citra, teks, suara, maupun data medis. Setiap lapisan dalam jaringan berfungsi mengekstraksi informasi tertentu, kemudian informasi tersebut diteruskan ke lapisan berikutnya untuk membentuk pemahaman yang lebih mendalam terhadap pola data. Dalam bidang kesehatan, *Deep Learning* telah banyak digunakan untuk mendukung analisis citra medis, bioinformatika, informatika medis, dan sistem kesehatan digital. Hal ini menunjukkan bahwa *Deep Learning* tidak hanya bersifat teoritis, tetapi juga memiliki penerapan praktis dalam pengembangan sistem berbasis data. Dalam penelitian pengembangan produk, teori *Deep Learning* menjadi dasar dalam menentukan kebutuhan data, pemilihan arsitektur model, proses pelatihan, serta evaluasi performa sistem. Dengan demikian, *Deep Learning* berperan sebagai fondasi teknologi dalam membangun sistem yang mampu melakukan klasifikasi secara otomatis dan terukur.

Selanjutnya Li et al. (2023), menjelaskan bahwa *Deep Learning* sangat penting dalam analisis citra medis karena mampu memproses dataset yang besar dan kompleks secara efisien. Penelitian tersebut menunjukkan bahwa pendekatan *Deep Learning* seperti CNN, RNN, GAN, LSTM, dan model hibrida telah digunakan dalam berbagai bentuk analisis citra medis. *Deep Learning* juga dinilai mampu meningkatkan efisiensi operasional dan mendukung pengambilan keputusan berbasis data dalam layanan kesehatan. Namun, penerapan *Deep Learning* tetap membutuhkan perhatian terhadap kualitas dataset, jumlah data berlabel, proses validasi, dan kemampuan generalisasi model. Oleh karena itu, dalam penelitian pengembangan produk, teori *Deep Learning* tidak hanya digunakan sebagai dasar pembuatan model, tetapi juga sebagai acuan dalam menentukan tahapan validasi dan uji coba produk. Berdasarkan uraian tersebut, *Deep Learning* dapat dipahami sebagai teknologi utama yang mendasari pengembangan sistem cerdas berbasis citra.

Berdasarkan beberapa definisi tersebut, dapat disimpulkan bahwa *Deep Learning* adalah pendekatan kecerdasan buatan yang menggunakan jaringan saraf tiruan berlapis untuk mempelajari pola data secara otomatis. Dalam penelitian ini, *Deep Learning* menjadi dasar dalam pengembangan produk karena sistem yang dirancang membutuhkan kemampuan untuk mengenali pola dari data citra secara akurat. Teori ini mendasari tahapan analisis kebutuhan, terutama dalam menentukan jenis data, format input, kebutuhan *Preprocessing*, dan kebutuhan komputasi. Selain itu, *Deep*

Learning juga menjadi dasar dalam tahap validasi produk melalui pengukuran performa model menggunakan metrik evaluasi seperti *accuracy*, *precision*, *recall*, dan *F1-score*. Pada tahap uji coba, teori ini digunakan untuk menilai apakah model mampu menghasilkan klasifikasi yang sesuai dengan data uji. Dengan demikian, *Deep Learning* menjadi kerangka konseptual utama yang menghubungkan data, model, proses klasifikasi, dan hasil evaluasi dalam penelitian.

7. *Deep Learning* dalam Analisis Citra Medis

Deep Learning dalam analisis citra medis merupakan penerapan model jaringan saraf tiruan untuk memproses, mengenali, dan mengklasifikasikan citra medis seperti *CT-Scan*, *MRI*, *X-ray*, dan *ultrasound*. Dalam bidang medis, citra memiliki karakteristik kompleks karena perbedaan struktur anatomi, variasi kualitas gambar, serta kebutuhan interpretasi yang teliti. Menurut Li et al. (2023), *Deep Learning* dapat digunakan dalam analisis citra medis karena mampu mempelajari fitur langsung dari data mentah dan mengurangi ketergantungan terhadap ekstraksi fitur manual. Penelitian tersebut juga menjelaskan bahwa evaluasi model *Deep Learning* dalam citra medis umumnya menggunakan metrik seperti *accuracy*, *sensitivity*, *specificity*, *F-score*, *robustness*, *computational complexity*, dan *generalizability*. Hal ini menunjukkan bahwa pengembangan produk berbasis *Deep Learning* harus memperhatikan bukan hanya hasil klasifikasi, tetapi juga reliabilitas dan kemampuan model dalam menghadapi data baru. Dengan demikian, teori *Deep Learning* dalam citra

medis menjadi dasar penting dalam merancang sistem klasifikasi yang dapat diuji secara objektif.

Menurut Prasad et al. (2024), model *Deep Learning* menunjukkan hasil yang menjanjikan dalam analisis citra medis, terutama pada proses klasifikasi penyakit berbasis gambar. Penelitian tersebut menguji beberapa model, seperti CNN, VGG-16, dan ensemble model, untuk klasifikasi citra medis, serta menunjukkan bahwa CNN dapat memperoleh akurasi pengujian yang tinggi pada studi kasus yang digunakan. Selain itu, penelitian tersebut juga menekankan pentingnya integrasi sistem komputasi dan keamanan data dalam pengolahan citra medis. Temuan ini mendukung bahwa pengembangan produk berbasis *Deep Learning* harus mempertimbangkan aspek teknis, validitas model, dan perlindungan data pengguna. Dalam penelitian pengembangan, pandangan ini dapat digunakan sebagai dasar untuk merancang alur sistem mulai dari input citra, *Preprocessing*, klasifikasi, hingga penyajian hasil. Oleh karena itu, *Deep Learning* dalam analisis citra medis tidak hanya berperan sebagai metode klasifikasi, tetapi juga sebagai dasar rancangan sistem yang lebih terstruktur.

Berdasarkan hasil penelitian terdahulu, penggunaan *Deep Learning* dalam citra medis memiliki beberapa keunggulan, yaitu kemampuan ekstraksi fitur otomatis, kemampuan mengenali pola visual kompleks, serta potensi meningkatkan efisiensi analisis. Namun, model *Deep Learning* juga memiliki tantangan, seperti kebutuhan dataset besar, risiko *overfitting*, keterbatasan data berlabel, dan masalah interpretabilitas

model. Alzubaidi et al. (2021), menjelaskan bahwa tantangan *Deep Learning* meliputi keterbatasan data pelatihan, data tidak seimbang, interpretabilitas, *overfitting*, *vanishing gradient*, *exploding gradient*, dan *generalisasi model*. Tantangan tersebut penting diperhatikan dalam penelitian pengembangan produk karena kualitas sistem sangat bergantung pada kualitas data dan proses validasi. Oleh sebab itu, tahap analisis kebutuhan harus mencakup kebutuhan dataset, perangkat lunak, perangkat keras, serta metode evaluasi yang sesuai. Dengan demikian, teori *Deep Learning* dalam analisis citra medis memberikan dasar yang kuat untuk menentukan langkah pengembangan, validasi, dan uji coba produk.

8. Validasi dan Evaluasi Produk Berbasis *Deep Learning*

Validasi produk berbasis *Deep Learning* adalah proses untuk memastikan bahwa model dan sistem yang dikembangkan mampu bekerja sesuai tujuan penelitian. Dalam konteks sistem klasifikasi, validasi dilakukan untuk menilai apakah model dapat menghasilkan prediksi yang benar terhadap data uji. Menurut Li et al. (2023), evaluasi *Deep Learning* dalam analisis citra medis dapat dilakukan dengan berbagai metrik, seperti *accuracy*, *sensitivity*, *specificity*, *F-score*, *robustness*, *computational complexity*, dan *generalizability*. Metrik tersebut digunakan untuk mengetahui kemampuan model dalam mengklasifikasikan data secara objektif. *Accuracy* menunjukkan tingkat ketepatan keseluruhan model, sedangkan *precision* dan *recall* menunjukkan kualitas prediksi pada setiap

kelas. *F1-score* digunakan untuk menyeimbangkan nilai *precision* dan *recall*, terutama ketika data memiliki distribusi kelas yang tidak seimbang.

Menurut Alzubaidi et al. (2021), pengembangan model *Deep Learning* harus memperhatikan beberapa tantangan seperti keterbatasan data, *overfitting*, ketidakseimbangan data, dan interpretabilitas model. Hal ini menunjukkan bahwa validasi produk tidak cukup hanya dilakukan melalui hasil akurasi, tetapi juga harus memperhatikan stabilitas model dan kesesuaian hasil dengan tujuan sistem. Dalam penelitian pengembangan, validasi produk dapat dilakukan melalui validasi ahli, validasi sistem, dan validasi performa model. Validasi ahli digunakan untuk menilai kesesuaian rancangan produk, validasi sistem digunakan untuk menilai fungsi aplikasi, sedangkan validasi model digunakan untuk menilai kinerja algoritma *Deep Learning*. Uji coba produk kemudian dilakukan untuk mengetahui apakah sistem dapat digunakan sesuai kebutuhan pengguna. Dengan demikian, teori evaluasi *Deep Learning* menjadi dasar dalam menentukan indikator keberhasilan produk yang dikembangkan.

Berdasarkan teori tersebut, elemen yang dapat diukur dalam penelitian ini meliputi kualitas data, performa model, fungsi sistem, dan kelayakan produk. Kualitas data berkaitan dengan jumlah, format, pembagian, dan keseimbangan dataset. Performa model diukur menggunakan *Confusion Matrix* dengan parameter *accuracy*, *precision*, *recall*, dan *F1-score*. Fungsi sistem dapat diuji menggunakan pengujian fungsional untuk memastikan setiap fitur berjalan sesuai rancangan.

Kelayakan produk dapat dinilai melalui validasi ahli atau uji coba pengguna sesuai kebutuhan penelitian. Dengan demikian, landasan teori *Deep Learning* memberikan kerangka konseptual yang jelas dalam menghubungkan kebutuhan sistem, proses pengembangan produk, validasi, uji coba, dan evaluasi hasil penelitian.

9. *Confusion Matrix*

Confusion Matrix merupakan salah satu metode evaluasi yang digunakan untuk mengukur performa model klasifikasi dengan membandingkan hasil prediksi model terhadap kelas sebenarnya (*actual class*). Metode ini menghasilkan sebuah matriks yang menggambarkan jumlah prediksi benar maupun prediksi yang salah sehingga peneliti dapat mengetahui kemampuan model dalam melakukan klasifikasi secara lebih rinci. *Confusion Matrix* menjadi salah satu metode evaluasi yang paling banyak digunakan dalam penelitian *Machine Learning* karena mampu memberikan informasi mengenai tingkat kesalahan klasifikasi melalui empat komponen utama, yaitu *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN) (Nasrullah et al., 2024).

Menurut Indransyah et al. (2022), *Confusion Matrix* merupakan metode evaluasi yang menggunakan tabel matriks untuk membandingkan nilai aktual dengan hasil prediksi model klasifikasi. Melalui matriks tersebut dapat diketahui jumlah data yang berhasil diklasifikasikan dengan benar maupun yang mengalami kesalahan klasifikasi. Selain digunakan pada klasifikasi biner, *Confusion Matrix* juga dapat diterapkan pada klasifikasi

multikelas dengan mengubah setiap kelas menjadi skenario one-versus-rest sehingga proses evaluasi tetap dapat dilakukan secara akurat.

Selanjutnya Nurhidayat & Dewi (2023), menjelaskan bahwa *Confusion Matrix* merupakan teknik evaluasi yang efektif untuk mengukur performa sistem klasifikasi karena mampu menunjukkan jumlah data yang diklasifikasikan secara benar maupun salah. Informasi tersebut membantu peneliti dalam mengidentifikasi kelemahan model sehingga dapat dilakukan proses optimasi terhadap algoritma yang digunakan. Oleh karena itu, *Confusion Matrix* tidak hanya digunakan untuk menghitung tingkat akurasi, tetapi juga menghasilkan berbagai metrik evaluasi lain yang lebih representatif, terutama ketika menghadapi data yang tidak seimbang (*imbalanced dataset*).

Berdasarkan beberapa pendapat tersebut, dapat disimpulkan bahwa *Confusion Matrix* merupakan metode evaluasi performa model klasifikasi yang membandingkan hasil prediksi dengan kondisi aktual melalui empat komponen utama, yaitu *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN). Pada penelitian ini, *Confusion Matrix* digunakan sebagai metode utama untuk mengevaluasi performa model *Convolutional Neural Network* (CNN) dalam mengklasifikasikan citra CT-Scan kanker paru-paru. Evaluasi ini diperlukan untuk mengetahui tingkat ketepatan model dalam mendeteksi pasien yang benar-benar menderita kanker paru-paru maupun pasien yang tidak terdiagnosis kanker sehingga sistem yang dikembangkan dapat memberikan rekomendasi yang

lebih akurat pada *Clinical Decision Support System* (CDSS). Bentuk dasar representasi dari *Confusion Matrix* untuk klasifikasi biner (dua kelas) dapat dilihat pada gambar 2.5 berikut:

	Prediksi	
Aktual	TRUE	FALSE
TRUE	TP	FP
FALSE	FN	TN

Gambar 2. 5 Representasi *Confusion Matrix* (Indransyah et al., 2022)

Empat komponen utama pada *Confusion Matrix* pada gambar 2.5 dijelaskan sebagai berikut.

- True Positive* (TP) merupakan jumlah data positif yang berhasil diprediksi sebagai positif oleh model.
- True Negative* (TN) merupakan jumlah data negatif yang berhasil diprediksi sebagai negatif.
- False Positive* (FP) merupakan jumlah data negatif yang diprediksi sebagai positif (kesalahan tipe I).
- False Negative* (FN) merupakan jumlah data positif yang diprediksi sebagai negatif (kesalahan tipe II).

Dalam bidang kesehatan, khususnya klasifikasi kanker paru-paru, nilai *False Negative* menjadi perhatian utama karena menunjukkan pasien yang sebenarnya menderita kanker tetapi diprediksi tidak menderita kanker. Kesalahan ini berpotensi menyebabkan keterlambatan diagnosis dan penanganan medis. Oleh karena itu, model klasifikasi diharapkan memiliki

nilai *Recall* (*Sensitivity*) yang tinggi sehingga mampu meminimalkan jumlah *False Negative*.

Sebaliknya, nilai *False Positive* menunjukkan pasien sehat yang diprediksi menderita kanker. Meskipun masih memerlukan pemeriksaan lanjutan, kesalahan ini umumnya lebih dapat ditoleransi dibandingkan *False Negative* karena tidak menyebabkan pasien kehilangan kesempatan memperoleh diagnosis dini. Oleh sebab itu, dalam sistem pendukung keputusan klinis, keseimbangan antara *Precision* dan *Recall* perlu diperhatikan agar model memiliki performa yang optimal.

Selain empat komponen utama tersebut, *Confusion Matrix* menghasilkan berbagai ukuran evaluasi performa model yang digunakan untuk menilai kualitas algoritma klasifikasi.

a. *True Positive Rate (TPR) / Sensitivity / Recall*

True Positive Rate menunjukkan kemampuan model dalam mendeteksi seluruh data yang benar-benar positif. Seperti pada persamaan (2.3) berikut:

$$TPR = \frac{TP}{TP + FN} \quad (2.3)$$

Semakin tinggi nilai TPR, semakin baik kemampuan model dalam mendeteksi pasien yang benar-benar menderita kanker paru-paru.

b. *False Positive Rate (FPR)*

False Positive Rate menunjukkan proporsi data negatif yang salah diprediksi sebagai positif. Seperti pada persamaan (2.4) berikut:

$$FPR = \frac{FP}{FP + TN} \quad (2.4)$$

Nilai FPR yang rendah menunjukkan model jarang memberikan diagnosis positif pada pasien yang sebenarnya sehat.

c. *True Negative Rate (TNR) / Specificity*

Specificity menunjukkan kemampuan model dalam mengenali data negatif secara benar. Seperti pada persamaan (2.5) berikut:

$$TNR = \frac{TN}{TN + FP} \quad (2.5)$$

Semakin tinggi nilai TNR, semakin baik model dalam membedakan pasien sehat dari pasien yang menderita kanker.

d. *False Negative Rate (FNR)*

False Negative Rate menunjukkan proporsi pasien positif yang gagal dideteksi oleh sistem. Seperti pada persamaan (2.6) berikut:

$$FNR = \frac{FN}{FN + TP} \quad (2.6)$$

Dalam aplikasi medis, nilai FNR diharapkan sekecil mungkin karena berkaitan langsung dengan kegagalan diagnosis. Selain keempat ukuran tersebut, performa model juga diukur menggunakan beberapa metrik berikut.

e. *Accuracy*

Accuracy menunjukkan proporsi seluruh prediksi yang benar terhadap seluruh data pengujian. Seperti pada persamaan (2.7) berikut:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.7)$$

f. *Precision*

Precision menunjukkan persentase prediksi positif yang benar-benar positif. Seperti pada persamaan (2.8) berikut:

$$Precision = \frac{TP}{TP + FP} \quad (2.8)$$

Precision yang tinggi menunjukkan bahwa sebagian besar pasien yang diprediksi menderita kanker memang benar-benar terdiagnosis kanker.

g. *Recall (Sensitivity)*

Recall merupakan ukuran kemampuan model menemukan seluruh kasus positif. Seperti pada persamaan (2.9) berikut:

$$Recall = \frac{TP}{TP + FN} \quad (2.9)$$

Pada penelitian klasifikasi kanker paru-paru, *Recall* menjadi salah satu metrik yang paling penting karena berhubungan langsung dengan keberhasilan deteksi dini penyakit.

h. *F1-score*

F1-score merupakan rata-rata harmonik antara *Precision* dan *Recall* sehingga memberikan ukuran evaluasi yang lebih seimbang. Seperti pada persamaan (2.10) berikut:

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (2.10)$$

Nilai *F1-score* yang tinggi menunjukkan model memiliki keseimbangan yang baik antara kemampuan mendeteksi pasien positif dan mengurangi kesalahan klasifikasi.

Sebagai contoh, apabila model CNN menguji 1.000 citra CT-Scan dan menghasilkan TP = 460, TN = 480, FP = 20, serta FN = 40, maka diperoleh *Accuracy* sebesar 94%, *Precision* sebesar 95,83%, *Recall* sebesar 92%, *Specificity* sebesar 96%, dan *F1-score* sebesar 93,88%. Nilai tersebut menunjukkan bahwa model memiliki kemampuan klasifikasi yang baik dalam mendeteksi kanker paru-paru serta layak digunakan sebagai komponen pendukung pada *Clinical Decision Support System* (CDSS).

10. *Flowchart*

Flowchart atau diagram alir merupakan suatu diagram yang digunakan untuk menggambarkan urutan proses, algoritma, maupun langkah-langkah instruksi dalam suatu sistem secara visual. *Flowchart* disusun menggunakan simbol-simbol tertentu yang saling terhubung sehingga membentuk alur proses yang sistematis dan mudah dipahami. Menurut Harsemadi et al. (2022), *Flowchart* adalah diagram yang merepresentasikan langkah-langkah instruksi secara berurutan dalam suatu sistem dengan menggunakan simbol-simbol tertentu untuk menggambarkan setiap proses yang terjadi. Penggunaan *Flowchart* bertujuan untuk mempermudah pemahaman terhadap mekanisme kerja sistem sehingga proses analisis, perancangan, dan evaluasi sistem dapat dilakukan secara



lebih efektif. Dalam pengembangan sistem informasi, *Flowchart* digunakan sebagai alat bantu untuk menggambarkan hubungan antarproses, aliran data, serta urutan kegiatan yang terjadi di dalam sistem. Dengan demikian, *Flowchart* menjadi bagian penting dalam tahap desain sistem karena mampu memberikan gambaran visual mengenai mekanisme kerja sistem yang akan dikembangkan.








Selain digunakan dalam pengembangan sistem, *Flowchart* juga berfungsi sebagai media dokumentasi proses kerja dan alur sistem. Menurut Tuasamu et al. (2023), bagan alir (*Flowchart*) merupakan teknik analitis bergambar yang digunakan untuk menjelaskan aspek-aspek sistem informasi secara jelas, ringkas, dan logis. *Flowchart* digunakan untuk menggambarkan alur proses bisnis, dokumen, serta hubungan antarbagian dalam suatu sistem sehingga mempermudah proses analisis dan evaluasi sistem. Dalam penelitian tersebut dijelaskan bahwa *Flowchart* membantu pengembang memahami mekanisme kerja sistem secara sistematis sebelum sistem diimplementasikan. Oleh karena itu, *Flowchart* menjadi alat penting dalam tahap perancangan sistem karena mampu memberikan gambaran visual mengenai urutan proses, hubungan antaraktivitas, serta aliran data dalam sistem yang dikembangkan. Dengan adanya *Flowchart*, proses validasi rancangan sistem dapat dilakukan lebih mudah karena seluruh proses kerja telah divisualisasikan secara terstruktur.

Selanjutnya Özsoy (2025), menjelaskan bahwa *Flowchart* memiliki keunggulan dalam memvisualisasikan proses secara runtut

sehingga mendukung proses perencanaan sistem dan komunikasi antarbidang. Penelitian tersebut menunjukkan bahwa *Flowchart* efektif digunakan untuk menggambarkan proses berurutan dan logika sistem dalam pengembangan produk cerdas. Selain itu, *Flowchart* juga dapat dikombinasikan dengan diagram lain seperti state diagram untuk menghasilkan pemodelan sistem yang lebih lengkap. Dalam konteks penelitian pengembangan produk, *Flowchart* dapat digunakan untuk menjelaskan alur proses mulai dari input data, pemrosesan sistem, pengambilan keputusan, hingga output yang dihasilkan. Oleh karena itu, *Flowchart* menjadi alat bantu penting dalam tahap desain sistem karena mampu memberikan gambaran visual yang jelas mengenai mekanisme kerja produk yang dikembangkan. Jenis-jenis *Flowchart* dipaparkan pada tabel 2.1 berikut ini :

Tabel 2. 1 Jenis-jenis Simbol Flowchart

No	Simbol	Nama	Keterangan
1.		<i>Terminator</i>	Digunakan untuk memulai dan mengakhiri sebuah proses atau program
2.		<i>Document</i>	Sebuah dokumen atau laporan. Dokumen dapat dibuat dengan tangan atau dicetak oleh komputer
3.		Kegiatan Manual	Sebuah kegiatan pemrosesan yang dilaksanakan secara manual.

4.		Arsip	Arsip dokumen disimpan dan diambil secara manual. Huruf di dalamnya menunjukkan cara pengurutan arsip.
5.		<i>Input / output</i>	Menggambarkan berbagai media input dan output dalam sebuah bagan alir program
6.		<i>Magnetic Disk</i> (Disk Bermagnet)	Data disimpan secara permanen dalam disk bermagnet.
7.		<i>Connector</i> (Penghubung)	Menghubungkan bagan alir yang berada di halaman berbeda
8.		Pemasukan Data <i>On Line</i>	Entri data alat oleh On Line seperti terminal CRT dan komputer pribadi
9		<i>Process</i> (Proses)	Sebuah fungsi pemrosesan yang dilaksanakan oleh komputer yang biasanya menghasilkan suatu perubahan terhadap data atau informasi
10		Arus Dokumen	Arus dokumen atau pemrosesan
11		<i>Decision</i> (Keputusan)	Sebuah tahap pembuatan keputusan
12		Penghubung Dalam Sebuah Dokumen	Menghubungkan bagan alir yang berada pada halaman yang sama
13		Dokumen Rangkap	Digambarkan dengan menumpuk simbol dokumen dan pencetakan nomor

dokumen di bagian depan
dokumen pada bagian kiri atas

Sumber : (Harsemadi et al., 2022)

Berdasarkan beberapa definisi tersebut, dapat disimpulkan bahwa *Flowchart* adalah diagram visual yang digunakan untuk menggambarkan urutan proses dan logika kerja suatu sistem secara sistematis. Dalam penelitian ini, *Flowchart* digunakan sebagai dasar dalam merancang alur sistem sebelum proses implementasi dilakukan. *Flowchart* membantu peneliti dalam tahap analisis kebutuhan dengan memetakan proses input, proses utama, keputusan, dan output sistem secara jelas. Pada tahap validasi produk, *Flowchart* digunakan untuk memastikan bahwa alur sistem telah sesuai dengan kebutuhan pengguna dan tujuan penelitian. Sedangkan pada tahap uji coba, *Flowchart* membantu dalam mengevaluasi apakah setiap proses sistem berjalan sesuai rancangan yang telah dibuat. Dengan demikian, *Flowchart* menjadi kerangka konseptual penting dalam menghubungkan desain sistem, implementasi, validasi, dan evaluasi produk penelitian.

11. Kanker Paru-paru

Penyakit paru-paru secara mendasar merupakan suatu kondisi patologis di mana organ paru-paru tidak dapat bekerja dengan baik atau kehilangan fungsi awalnya sebagai pengatur sistem pernapasan utama manusia. Kesehatan paru-paru sangat krusial mengingat fungsinya dalam menyaring udara dan memasok oksigen ke seluruh tubuh, namun organ ini

rentan mengalami penurunan fungsi yang berujung pada berbagai komplikasi pernapasan serius (Wenda et al., 2023).

Menurut Haffandi et al. (2022), penyakit paru-paru merupakan kondisi gangguan respirasi yang sangat sering terjadi akibat paparan polutan, seperti udara tercemar, debu, asap, virus, maupun bakteri yang memicu infeksi pada saluran pernapasan. Kanker paru-paru diklasifikasikan sebagai salah satu jenis spesifik dari penyakit paru yang sangat mematikan, berdampingan dengan jenis penyakit pernapasan lain seperti bronkitis, asma, pneumonia, penyakit paru obstruktif kronik (PPOK), dan tuberkulosis. Proses pengklasifikasian penyakit ini sangat penting untuk dilakukan, mengingat setiap jenis penyakit paru sering kali menunjukkan gejala klinis yang mirip satu sama lain, padahal masing-masing membutuhkan penanganan medis yang sama sekali berbeda.

Selanjutnya Vierisyah et al. (2023), secara spesifik mendefinisikan kanker paru-paru sebagai penyebab utama keganasan di dunia, yang secara statistik menyumbang hingga tiga belas persen dari seluruh angka kematian akibat kanker secara global. Penyakit mematikan ini mutlak membutuhkan langkah deteksi dini dan penanganan yang tepat. Seiring dengan kemajuan teknologi medis, instrumen pencitraan seperti *Computed Tomography* (CT-Scan) yang dipadukan dengan kecerdasan buatan, khususnya *Convolutional Neural Network* (CNN), telah menjadi solusi krusial dalam menganalisis citra medis guna meningkatkan efektivitas deteksi dini kanker paru-paru secara akurat.

Berdasarkan beberapa definisi tersebut, dapat disimpulkan bahwa kanker paru-paru merupakan kelainan patologis berupa keganasan mematikan pada sistem respirasi yang sangat membutuhkan identifikasi dini dan penanganan medis yang spesifik. Dalam penelitian ini, pemahaman komprehensif mengenai karakteristik penyakit tersebut menjadi landasan utama dalam pengembangan sistem klasifikasi kanker paru-paru berbasis citra CT-Scan. Melalui penerapan *Convolutional Neural Network* (CNN) yang terintegrasi langsung dengan *Clinical Decision Support System* (CDSS), sistem ini dikembangkan agar mampu membantu proses diagnosis jenis dan tingkat keparahan kanker secara lebih akurat, cepat, efisien, dan dapat dimanfaatkan sebagai langkah skrining awal secara mandiri.

a. Etiologi Kanker Paru-Paru

Etiologi atau faktor penyebab utama dari berkembangnya kanker paru-paru dan berbagai penyakit pernapasan lainnya sangat erat kaitannya dengan gaya hidup serta kondisi lingkungan tempat individu berada. Menurut Vierisyah et al. (2023), penyebab paling utama dan dominan dari timbulnya kanker paru-paru adalah kebiasaan merokok secara aktif. Namun demikian, risiko keganasan ini tidak terbatas hanya pada perokok aktif; individu yang tidak merokok tetapi secara terus-menerus terpapar asap rokok di lingkungannya (perokok pasif) juga memiliki tingkat risiko yang sangat signifikan untuk terjangkit kanker paru-paru.

Di samping faktor kebiasaan merokok, buruknya kualitas udara dan faktor lingkungan memainkan peran etiologis yang krusial dalam memicu kerusakan organ respirasi. Haffandi et al. (2022) menguraikan bahwa penyakit pada paru-paru umumnya disebabkan oleh aktivitas menghirup udara yang telah tercemar. Kontaminasi udara tersebut dapat bersumber dari paparan debu, asap, serta agen patogen mikrobiologis seperti virus maupun bakteri yang pada akhirnya mengakibatkan infeksi pada saluran pernapasan.

Lebih lanjut, Haffandi et al. (2022) juga menegaskan bahwa pencemaran udara yang menjadi pemicu utama berbagai penyakit paru-paru ini sering kali merupakan dampak akumulatif dari aktivitas manusia dan modernisasi. Sumber polusi tersebut mencakup limbah gas dari pabrik industri, polusi emisi dari sarana transportasi, serta paparan asap akibat proses pembakaran yang terjadi secara terus-menerus dalam kehidupan sehari-hari. Akumulasi polutan inilah yang secara bertahap merusak jaringan epitel paru-paru dan memicu mutasi seluler hingga berkembang menjadi kanker.

b. Tanda-tanda Kanker Paru-Paru

Manifestasi klinis dan tanda-tanda yang dialami oleh penderita kanker paru-paru sangat bervariasi dan kerap memiliki kemiripan dengan jenis penyakit pernapasan lainnya. Menurut penelitian yang dilakukan oleh Wenda et al. (2023), terdapat beberapa gejala klinis yang secara spesifik dapat mengindikasikan adanya

penyakit kanker paru. Tanda-tanda tersebut meliputi batuk darah, sesak napas, rasa capai yang berlebihan, serta hilangnya nafsu makan secara signifikan. Lebih lanjut, penderita kanker paru juga kerap merasakan nyeri yang menjalar di area dada, bahu, atau punggung, mengalami radang paru yang berulang, hingga terjadinya perubahan fisik berupa suara yang menjadi parau serta adanya pembengkakan pada bagian leher dan wajah.

c. Patofisiologi Kanker Paru-Paru

Secara patofisiologis, kelainan pada kasus kanker paru-paru sangat memengaruhi fungsi utama sistem respirasi dan sirkulasi tubuh manusia. Vierisyah et al. (2023) menjelaskan bahwa paru-paru secara anatomis terdiri dari bagian-bagian seperti bronkus, bronkiolus, dan alveolus yang berfungsi sebagai tempat pertukaran gas. Pertukaran ini terjadi ketika oksigen yang dihirup masuk ke dalam alveolus untuk kemudian diserap oleh pembuluh darah kapiler, sementara karbon dioksida dari dalam darah dilepaskan kembali ke dalam alveolus untuk dibuang saat menghembuskan napas.

Selanjutnya Haffandi et al. (2022) menjabarkan bahwa proses respirasi tersebut pada dasarnya adalah proses pelepasan energi secara kimiawi, di mana oksigen (O_2) digunakan untuk memecah senyawa organik tubuh agar menghasilkan energi, air (H_2O), dan gas buang berupa karbon dioksida (CO_2). Ketika terjadi keganasan atau penyakit pada paru-paru, Wenda et al. (2023) menegaskan bahwa fungsi vital

paru-paru untuk menampung dan menyaring oksigen ini mengalami kegagalan, sehingga organ tersebut tidak dapat lagi bekerja sesuai dengan fungsi fisiologis awalnya.

Pada kasus kanker paru-paru, munculnya massa tumor pada jaringan atau saluran pernapasan akan menyumbat dan merusak struktur anatomi tersebut. Kegagalan struktural ini akan menghambat distribusi oksigen ke dalam aliran darah secara masif. Menurut Haffandi et al. (2022), terhambatnya asupan oksigen ini pada tingkat lanjut akan memicu terjadinya hipoksia, yaitu kondisi di mana jaringan tubuh mengalami kekurangan oksigen yang parah, yang jika dibiarkan dapat menyebabkan komplikasi fatal hingga kematian pada individu yang terkena.

12. *Black-box Testing*

Black-box Testing merupakan jenis pengujian yang memperlakukan perangkat lunak layaknya sebuah kotak hitam tanpa perlu mengetahui kinerja maupun struktur internalnya, sehingga penguji cukup tunduk dan berfokus pada proses pengujian luarnya saja (Wintana et al., 2022). Lebih lanjut, dalam penggunaannya, pengujian ini terbukti lebih baik dan efisien apabila diterapkan pada proses pengujian yang memiliki frekuensi repetisi yang lebih sedikit.

Menurut Putri et al. (2024), *Black-box Testing* atau yang biasa disebut *Behavioral Testing* adalah metode pengujian yang berfokus pada fungsionalitas dan perilaku perangkat lunak tanpa perlu memeriksa

struktur maupun implementasi kode internal program. Dalam pelaksanaannya, penguji berinteraksi langsung dengan antarmuka sistem dengan cara memberikan *input* dan memeriksa *output* yang dihasilkan, tanpa diwajibkan memiliki pengetahuan khusus mengenai bahasa pemrograman maupun detail cara kerja sistem di balik layar.

Selanjutnya, Saputra & Mardiaty (2025) mendefinisikan *Black-box Testing* sebagai metode pengujian yang bertujuan untuk mengevaluasi fungsionalitas sistem dengan cara menguji validitas *input*, proses, dan *output* dari sebuah perangkat lunak. Perhatian utama dalam metode ini adalah memastikan bahwa sistem yang dikembangkan berfungsi dengan baik dan merespons secara akurat sesuai dengan spesifikasi kebutuhan yang telah ditetapkan oleh pengguna, tanpa perlu melakukan pemeriksaan terhadap detail logika kode sumbernya.

Berdasarkan beberapa definisi tersebut, dapat disimpulkan bahwa *Black-box Testing* merupakan pendekatan pengujian yang sangat efektif untuk memvalidasi kelayakan fungsionalitas sistem dari sudut pandang pengguna akhir. Dalam penerapannya untuk merancang kasus uji, metode ini didukung oleh berbagai teknik spesifik, di antaranya *Equivalence Class Partitioning* (ECP) yang mengelompokkan input ke dalam kelas valid dan tidak valid, *Boundary Value Analysis* (BVA) yang menguji parameter nilai pada batas atas dan bawah input, serta *Decision Table* (DT) yang merangkum serta menguji berbagai kombinasi *input* dan kondisi yang berbeda. Untuk mengukur dan mengevaluasi sejauh mana tingkat

keberhasilan serta kualitas perangkat lunak dari pengujian *Black-box* yang telah dilakukan, diperlukan standar pengukuran yang objektif berupa *Software Testing Metrics*. Penggunaan metrik ini juga berfungsi untuk memantau sejauh mana perkembangan perangkat lunak tersebut. Terdapat tiga rumus persentase utama yang digunakan untuk menghitung hasil pengujian *Black-box*, yaitu:

a. Persentase Kasus Uji yang Dieksekusi (*Test Case Executed*)

Rumus ini digunakan untuk mengetahui persentase jumlah kasus uji yang berhasil dieksekusi oleh sistem dibandingkan dengan total keseluruhan kasus uji yang telah dirancang.

$$\text{Test Case Executed \%} = \left(\frac{\text{Test Case Executed}}{\text{Test Case Written}} \right) \times 100\% \quad (2.11)$$

Dalam perhitungan ini, variabel *Test Case Executed* merepresentasikan total *test case* yang dapat dieksekusi oleh sistem, sedangkan variabel *Test Case Written* merujuk pada total *test case* yang telah dibuat atau dirancang untuk pengujian tersebut.

b. Persentase Kasus Uji yang Berhasil (*Test Case Passed*)

Rumus ini digunakan untuk menghitung tingkat keberhasilan fungsionalitas sistem, yakni dengan membandingkan jumlah kasus uji yang berstatus berhasil dengan total kasus uji yang dijalankan.

$$\text{Test Case Passed \%} = \left(\frac{\text{Test Case Passed}}{\text{Total Test Case}} \right) \times 100\% \quad (2.12)$$

Pada rumus ini, yang dimaksud dengan variabel *Test Case Passed* adalah total *test case* yang berhasil dijalankan sesuai dengan harapan, yang kemudian pembagiannya dilakukan terhadap *Total Test*

Case, yaitu keseluruhan jumlah *test case* yang diuji pada pengujian tersebut.

c. Persentase Kasus Uji yang Gagal (*Test Case Failed*)

Rumus ini digunakan untuk menghitung tingkat kegagalan (bug/error) pada sistem, yakni dengan membandingkan jumlah kasus uji yang berstatus gagal dengan total kasus uji yang dijalankan.

$$Test\ Case\ Failed\ \% = \left(\frac{Test\ Case\ Failed}{Total\ Test\ Case} \right) \times 100\% \quad (2.13)$$

Untuk perhitungan tingkat kegagalan ini, variabel *Test Case Failed* merujuk pada total *test case* yang berstatus gagal atau tidak berjalan sesuai dengan spesifikasi, di mana nilai tersebut dibagi dengan *Total Test Case* yang merupakan total keseluruhan *test case* yang diuji.

B. Kajian Empiris

Penelitian oleh Mamun et al. (2022), berjudul “*LCDetCNN: Lung Cancer Diagnosis of CT Scan Images Using CNN Based Model*” yang dipublikasikan melalui *arXiv*. Penelitian ini dilatarbelakangi oleh tingginya angka kematian akibat kanker paru-paru dan pentingnya deteksi dini menggunakan citra CT-Scan. Tujuan penelitian tersebut adalah mengembangkan model *Convolutional Neural Network* (CNN) untuk mendeteksi kanker paru-paru dari citra CT-Scan secara otomatis. Metode penelitian yang digunakan adalah eksperimen dengan membandingkan beberapa model *Deep Learning* seperti CNN, InceptionV3, Xception, dan ResNet50. Hasil penelitian menunjukkan bahwa model CNN yang diusulkan memiliki performa terbaik dengan akurasi mencapai 92%, nilai AUC sebesar

98,21%, dan *recall* sebesar 91,72%. Penelitian ini memiliki persamaan dengan penelitian yang dilakukan penulis karena sama-sama menggunakan citra CT-Scan dan metode CNN untuk klasifikasi kanker paru-paru. Perbedaannya adalah penelitian mereka hanya berfokus pada klasifikasi citra tanpa integrasi *Clinical Decision Support System* (CDSS). Selain itu, penelitian tersebut belum membahas bagaimana hasil klasifikasi digunakan sebagai pendukung pengambilan keputusan klinis. Kelemahan penelitian tersebut adalah sistem masih berfokus pada hasil klasifikasi model tanpa menyediakan rekomendasi atau dukungan keputusan bagi pasien awam. Oleh karena itu, penelitian ini dilakukan untuk melengkapi kesenjangan tersebut melalui integrasi CNN dengan *Clinical Decision Support System* sehingga hasil klasifikasi dapat digunakan sebagai pendukung keputusan klinis secara lebih komprehensif.

Penelitian oleh Rai et al. (2022), berjudul “*An Explainable AI Approach for Lung Cancer Detection Using Convolutional Neural Networks*” yang dipublikasikan melalui *arXiv*. Penelitian ini dilatarbelakangi oleh pentingnya transparansi dan interpretabilitas sistem kecerdasan buatan dalam bidang medis, khususnya pada deteksi kanker paru-paru menggunakan citra CT-Scan. Tujuan penelitian tersebut adalah mengembangkan sistem deteksi kanker paru-paru berbasis CNN yang dilengkapi teknik *Explainable Artificial Intelligence* (XAI) untuk membantu interpretasi hasil prediksi model. Metode penelitian yang digunakan adalah eksperimen menggunakan beberapa model CNN seperti DenseNet121, ResNet152, dan VGG19 dengan pendekatan *cost-sensitive learning* untuk mengatasi ketidakseimbangan data. Penelitian tersebut

juga menggunakan metode SHAP (*Shapley Additive Explanations*) untuk menjelaskan kontribusi fitur terhadap hasil prediksi model. Hasil penelitian menunjukkan bahwa model ResNet152 memperoleh akurasi tertinggi sebesar 97,3%, sedangkan DenseNet121 memberikan keseimbangan terbaik pada *precision*, *recall*, dan *F1-score*. Persamaan penelitian tersebut dengan penelitian ini terletak pada penggunaan CNN dalam deteksi kanker paru-paru berbasis citra CT-Scan. Perbedaannya adalah penelitiannya berfokus pada *explainability model AI*, sedangkan penelitian ini menitikberatkan pada integrasi CNN dengan *Clinical Decision Support System* sebagai pendukung pengambilan keputusan medis. Kelemahan penelitian tersebut adalah belum adanya integrasi sistem pendukung keputusan klinis yang dapat membantu tenaga kesehatan dalam menentukan tindak lanjut berdasarkan hasil klasifikasi model. Oleh karena itu, penelitian ini hadir untuk melengkapi kesenjangan tersebut dengan mengintegrasikan CNN dan *Clinical Decision Support System* dalam satu sistem klasifikasi kanker paru-paru berbasis CT-Scan.

Penelitian oleh Deril et al. (2024), berjudul “*Classification of Lung Cancer with Convolutional Neural Network Method Using ResNet Architecture*” yang dipublikasikan pada jurnal TEKNIKA. Penelitian ini dilatarbelakangi oleh kenyataan bahwa pengobatan kanker paru-paru pada stadium awal jauh lebih efektif dan efisien, sehingga klasifikasi yang akurat sangat dibutuhkan. Tujuan penelitian tersebut adalah mengklasifikasikan tiga tipe umum kanker paru (*Adenocarcinoma*, *Large cell carcinoma*, dan *Squamous cell carcinoma*) beserta paru-paru *Normal* menggunakan arsitektur ResNet.

Metode yang digunakan adalah *Convolutional Neural Network* (CNN) dengan mengevaluasi model ResNet50, ResNet101, dan ResNet152 pada dataset citra *Low-Dose Computed Tomography* (LDCT). Hasil penelitian menunjukkan bahwa ResNet152 memberikan performa paling superior dengan tingkat akurasi mencapai 89%. Persamaan penelitian tersebut dengan penelitian yang dilakukan adalah sama-sama menggunakan citra CT-Scan dan arsitektur CNN (berbasis ResNet) untuk proses klasifikasi penyakit paru. Perbedaannya, penelitian mereka murni berfokus pada evaluasi arsitektur klasifikasi berbagai sub-tipe kanker. Kelemahan dari penelitian tersebut adalah hasil klasifikasinya belum diekspansi ke dalam sebuah platform *Clinical Decision Support System* (CDSS) yang fungsional bagi tenaga medis. Oleh karena itu, penelitian ini dilakukan untuk menyempurnakan pendekatan tersebut dengan membungkus kemampuan klasifikasi model ke dalam sistem yang secara aktif mendukung proses analisis klinis secara komprehensif.

Penelitian oleh Mulya & Novita (2025), berjudul "Klasifikasi Citra CT Scan Kanker Paru-Paru Menggunakan Pendekatan *Deep Learning*" yang dipublikasikan pada jurnal BITS. Penelitian ini dilatarbelakangi oleh sulitnya mengenali tanda abnormal seperti nodul atau massa pada citra CT Scan secara manual. Tujuan penelitian ini adalah mengembangkan model *Deep Learning* yang andal untuk mengklasifikasi kanker paru-paru menjadi kategori ganas, jinak, dan *Normal*. Metode penelitian mengkomparasikan arsitektur CNN seperti DenseNet121, InceptionResNetV2, Inception V3, dan ResNet152V2 menggunakan optimisasi Adam dan SGDM dengan beberapa variasi pembagian

rasio *hold-out* data. Hasilnya, arsitektur Inception V3 (SGDM) dan InceptionResNetV2 (Adam) mencapai performa klasifikasi yang sangat baik dengan nilai akurasi berturut-turut 99,38% dan 99,40%. Persamaan dengan penelitian ini adalah pemanfaatan *Deep Learning* (CNN) dalam mengidentifikasi tingkat keparahan kanker paru melalui citra CT Scan. Perbedaannya terletak pada fokus penelitian; Mereka sangat menitik beratkan pada komparasi pengaruh fungsi optimisasi dan rasio *splitting* data secara ekstensif. Kelemahan penelitian tersebut adalah peneliti belum memadukan atau mengintegrasikan model berakurasi tinggi tersebut ke dalam sistem pendukung keputusan klinis (CDSS). Oleh karena itu, penelitian ini dirancang agar kecerdasan buatan tersebut dapat direpresentasikan secara langsung untuk mendukung keputusan tim medis.

Penelitian oleh Septhya et al. (2023), berjudul "Implementasi Algoritma *Decision Tree* dan *Support Vector Machine* untuk Klasifikasi Penyakit Kanker Paru" yang diterbitkan pada jurnal MALCOM. Latar belakang penelitian ini adalah belum ditemukannya metode skrining dini yang efektif untuk mendeteksi penyakit kanker paru. Tujuannya adalah membandingkan algoritma klasifikasi *Decision Tree* dan *Support Vector Machine* (SVM) untuk mengetahui model yang memberikan hasil prediksi terbaik. Metode penelitian ini menerapkan algoritma klasifikasi berbasis rekam data klinis (non-citra) dengan penambahan metode seleksi fitur berupa *forward selection* untuk mengoptimalkan komputasi atribut pasien. Hasil pengujian menyimpulkan bahwa algoritma SVM yang dipadukan dengan *forward selection* memiliki

performa terbaik dengan tingkat akurasi sebesar 62,3%. Persamaan penelitian ini dengan sistem yang diusulkan adalah sama-sama mengimplementasikan metode komputasi *Machine Learning* untuk proses klasifikasi prediksi penyakit kanker paru. Perbedaan utamanya, penelitian sebelumnya menggunakan *Machine Learning* tradisional berbasis data tabular atau rekam klinis pasien (seperti gejala batuk, riwayat merokok, usia, dll.). Kelemahan dari penelitian ini adalah akurasi yang dihasilkan masih tergolong rendah (62,3%) dan sistem tidak memanfaatkan pengolahan citra medis (CT Scan) yang memuat informasi patologis visual yang krusial bagi tenaga medis. Oleh karena itu, penelitian ini dilakukan untuk menyelesaikan kendala akurasi rendah dengan mengimplementasikan pengenalan pola mikrostesktur paru melalui *Deep Learning*.

Penelitian oleh Septiani et al. (2026), berjudul "Diagnosis Kanker Paru-paru Berbasis Data Klinis: Evaluasi Performa Algoritma Pembelajaran Mesin" yang dipublikasikan pada Jurnal Ilmiah Fifo. Latar belakangnya adalah tantangan medis di mana gejala awal kanker paru sangat tidak spesifik sehingga dibutuhkan bantuan komputasi berbasis data untuk penemuan dini. Penelitian ini bertujuan untuk mengevaluasi secara komprehensif performa berbagai algoritma *Machine Learning* dalam memprediksi kanker paru. Metodologi yang digunakan adalah evaluasi silang menggunakan algoritma *K-Nearest Neighbors* (k-NN), *Logistic Regression*, *Naïve Bayes*, *Support Vector Machine* (SVM), dan *Neural Network* berbasis 16 parameter data klinis kesehatan pasien. Hasil eksperimen menunjukkan bahwa k-NN dan *Neural Network* memiliki performa

terbaik dengan tingkat akurasi mencapai 0,92 (92%). Persamaan dengan penelitian ini adalah pemanfaatan komputasi kecerdasan buatan (*Neural Network*) untuk membangun model klasifikasi kanker paru secara otomatis. Perbedaan utama terletak pada jenis data; peneliti mengekstraksi informasi prediktif semata-mata dari riwayat data pasien (rekam medis), sementara penelitian ini memproses representasi fitur spasial langsung dari citra medis CT Scan. Kelemahan penelitian tersebut adalah tidak dilibatkannya data pencitraan medis yang merupakan alat utama diagnosis radiologi, serta hasil prediksi yang belum terintegrasi ke dalam sebuah CDSS. Oleh karena itu, penelitian yang penulis ajukan berusaha menggabungkan kedalaman analisis citra CT Scan dengan kemampuan rekomendasi sistem cerdas bagi para klinisi.


Berdasarkan keseluruhan penelitian terdahulu tersebut, dapat diketahui bahwa penelitian mengenai kanker paru-paru telah dilakukan melalui dua pendekatan utama, yakni pengolahan citra CT-Scan menggunakan arsitektur *Convolutional Neural Network* (CNN) dan analisis prediktif berbasis data klinis tabular menggunakan *Machine Learning* konvensional. Kedua pendekatan tersebut terbukti mampu menunjukkan hasil performa yang tinggi dalam proses klasifikasi, deteksi nodul paru, hingga analisis fitur. Namun, dapat disimpulkan pula bahwa sebagian besar penelitian tersebut masih terhenti pada capaian akurasi model algoritmik semata, baik itu dalam domain klasifikasi citra, segmentasi, maupun komparasi *optimizer*. Penelitian terdahulu belum banyak membahas atau merealisasikan bagaimana keluaran arsitektur CNN tersebut digunakan sebagai bagian utuh dari *Clinical Decision Support System* (CDSS)

yang siap diakses oleh tenaga medis untuk merumuskan pengambilan keputusan akhir. Oleh karena itu, penelitian ini dilakukan untuk mengisi kesenjangan tersebut secara nyata dengan mengembangkan sistem kecerdasan buatan klasifikasi kanker paru-paru yang secara langsung terintegrasi dengan fungsionalitas *Clinical Decision Support System*. Kontribusi penelitian ini diharapkan mampu menghasilkan sistem yang tidak hanya tangguh secara komputasi, tetapi juga aplikatif, interaktif, dan informatif dalam mengawal proses diagnosis medis agar jauh lebih akurat dan efektif.

C. Kerangka Berpikir

Penelitian-penelitian terdahulu mengenai klasifikasi kanker paru-paru berbasis citra CT-Scan umumnya masih terfokus pada peningkatan performa model, segmentasi, dan interpretabilitas (*Explainable AI*), namun belum terintegrasi secara komprehensif ke dalam *Clinical Decision Support System* (CDSS) guna membantu pengambilan keputusan medis. Untuk menjembatani kesenjangan tersebut, penelitian ini bertujuan mengembangkan sistem klasifikasi cerdas yang memadukan keandalan *Convolutional Neural Network* (CNN) dalam mengekstraksi fitur citra dengan fungsionalitas CDSS untuk memberikan informasi diagnostik pendukung secara langsung bagi pasien awam. Proses pengembangannya dilakukan secara sistematis, meliputi analisis kebutuhan, prapemrosesan data, pelatihan dan evaluasi model menggunakan parameter matriks kebingungan (*accuracy, precision, recall, F1-score*), hingga tahap validasi serta uji coba fungsional. Melalui alur pengembangan yang terintegrasi ini, penelitian diharapkan mampu memberikan kontribusi baru

berupa sistem medis yang tidak hanya berakurasi tinggi, tetapi juga aplikatif dan efektif dalam memfasilitasi penentuan diagnosis klinis.



Gambar 2. 6 Kerangka Berpikir