

BAB II

TINJAUAN PUSTAKA

2.1 Penelitian yang Relevan

Penelitian tentang identifikasi pneumonia melalui citra X-ray dada telah banyak dilakukan menggunakan pendekatan *deep learning*, terutama *Convolutional Neural Network* (CNN). Salah satu arsitektur CNN yang umum digunakan adalah DenseNet-121 yang memiliki keunggulan koneksi erat antar layer sehingga dapat mengekstraksi fitur dengan efektif dan mengatasi masalah *vanishing gradient*.

Penelitian Pertama ***“Deep Learning Approach For Pneumonia Prediction From X-Rays Using A Pretrained Densenet Model”*** . Menggunakan model *transfer learning* berbasis DenseNet-121 untuk mendeteksi pneumonia dengan tingkat akurasi lebih dari 90% pada dataset *X-Chest Ray*. Penelitian ini juga menekankan signifikansi metode interpretasi hasil model untuk memperkuat kepercayaan tenaga medis dalam memanfaatkan sistem deteksi otomatis. Dengan tiga varian model diuji, yaitu DenseNet-121, DenseNet-169, dan DenseNet-201, dengan dataset sebanyak 5.216 data latih dan 624 data uji yang diperoleh *Guangzhou Women and Children’s Medical Center*. Temuan dari penelitian menunjukkan bahwa DenseNet-201 menghasilkan performa terbaik, dengan *precision* 0.81 dan *recall* 0.99 untuk pneumonia serta *precision* 0.99 dan *recall* 0.61 untuk kondisi normal. Ini menunjukkan bahwa model mampu mengenali pneumonia dengan sensitivitas yang sangat tinggi, meskipun masih ada beberapa kesalahan klasifikasi pada data normal (Wafi et al., 2025).

Penelitian Kedua, ***“Pneumonia Detection in Chest X-ray Images Using Concolutional Neural Networks”***. Menghasilkan model CNN untuk mendeteksi pneumonia dari 1000 gambar X-Ray di Rumah Sakit Universitas Koç. Data diolah melalui *cropping*, *resizing*, *histogram equaliation* dan *augmentasi*. Model dilatih selama 100 *epoch* menggunakan *Adam optimizer*, memperoleh akurasi 93,3%, *F1-score* 0.94 dan AUC 0.98. Dengan menggunakan *Grad-CAM*, penelitian ini juga menyajikan interpretasi visual

dari area paru yang menjadi perhatian dalam deteksi pneumonia (Şimşek et al., 2025).

Penelitian Ketiga ***“Pneumonia Detection using CNN, Resnet and DenseNet”***. Menciptakan system diagnosis otomatis pneumonia yang didasarkan pada model ensemble yang mengintegrasikan berbagai arsitektur deep learning, yaitu CNN konvensional, ResNet-50 dan DenseNet-121, pada citra X-Ray paru. Uji coba dilaksanakan pada dataset besar melalui *preprocessing* data, augmentasi, dan penyempurnaan model. Hasil penilaian menunjukkan bahwa model CNN memperoleh model. Hasil penilaian menunjukkan bahwa model CNN memperoleh akurasi 92, ResNet-50 mendapatkan 92,79% dan DenseNet-121 meraih 91,67%. Walaupun DenseNet-121 memiliki akurasi yang sedikit lebih rendah, keunggulan dari arsitektur ini adalah efisiensi dalam pelatihan dan kemampuan ekstraksi fitur yang sangat baik, sehingga ideal untuk digunakan dalam aplikasi *real-time*. Sistem ensemble yang dibangun memiliki kemampuan sebagai alat bantu diagnosis pneumonia yang tepat dan dapat dipercaya di lingkungan klinis (Gundabatini, 2024).

Penelitian Keempat, ***“Modelling radiological features fusion and Explainable AI in pneumonia detection: A graph-based deep learning and transformers approach”*** (Kaushik et al., 2025) memperkenalkan pendekatan model inovatif berbasis citra *CT scan* paru-paru, yang mengintegrasikan U-Net untuk proses segmentasi, pemodelan berbasis graf untuk merepresentasikan fitur special, serta mekanisme transformer guna mengekstrak konteks global. Model tersebut berhasil mencapai Tingkat akurasi 94%, F-1score 0,94, dan *Dice Similarity Coefficient* 0,91 khususnya pada tahap segmentasi. Penerapan teknik *Explainable AI* (XAI) seperti *Grad-CAM* dan peta perhatian (attention maps) dimanfaatkan untuk meningkatkan keterjelasan interpretasi prediksi. Secara keseluruhan, hasil penelitian ini menandakan kemajuan signifikan dalam akurasi serta keandalan model kecerdasan buatan untuk diagnosis pneumonia, yang berpotensi diimplementasikan secara *real-time* di lingkungan klinis.

Penelitian Kelima, ***"Explanatory classification of CXR images into COVID-19, Pneumonia and Tuberculosis using deep learning and XAI"*** (Bhandari et al., 2022) Mengindikasikan bahwa arsitektur DenseNet-121 dengan pendekatan transfer learning menonjol sebagai model paling efektif untuk mendeteksi pneumonia melalui citra X-ray dada, mencapai Tingkat akurasi 96-98% pada dataset seperti NIH *ChestX-ray14* dan RSNA. Namun, penerapan *Explainable AI* (XAI) seperti *Grad-CAM*, *LIME*, atau *SHAP* hanya tercakup dalam sekitar 20% studi, padahal metode ini terbukti memperkuat kepercayaan klinis terhadap prediksi model. Tinjauan tersebut menyarankan pengembangan model hybrid DL-XAI yang lebih efisien untuk aplikasi *real-time* di negara-negara berkembang.

Penelitian Keenam, ***"Detection of Omicron Caused Pneumonia from Radiology Images Using Convolution Neural Network (CNN)"*** (Khan et al., 2023) Memperkenalkan pendekatan berbasis tiga model CNN secara bertahap untuk mengidentifikasi pneumonia serta membedakan etiologinya, mencakup infeksi bakteri, *COVID-19*, dan varian *Omicron*. Dataset yang dimanfaatkan terdiri dari 1.500 citra radiologi, meliputi 500 gambar normal, 400 kasus pneumonia bakteri, 400 pneumonia akibat *COVID-19*, serta 200 pneumonia *Omicron*. Model tahap pertama berhasil mendeteksi keberadaan pneumonia dengan akurasi 98%, model kedua memisahkan pneumonia *COVID-19* dari jenis bakteri dengan akurasi 88%, sedangkan model ketiga mengenali pneumonia yang disebabkan *Omicron* mencapai akurasi 78%. Teknik *Grad-CAM* juga diintegrasikan untuk memvisualisasikan wilayah paru yang menjadi dasar keputusan prediksi.

Penelitian Ketujuh, ***"Convolutional Neural Network dalam Analisis Citra Medis"*** (Gunawan & Setiawan, 2022) CNN menjadi Teknik deep learning paling unggul untuk berbagai tugas seperti klasifikasi, deteksi, segmentasi, dan enhanment citra medis, dengan mencapai tingkat akurasi superior pada dataset beragam termasuk *Chest X-ray*, *MRI*, *CT scan*, serta *Ultrasound*. Melalui kemampuan ekstraksi fitur otomatis dari gambar medis, CNN meminimalkan ketergantungan pada proses manual, sekaligus mempercepat efisiensi diagnosis penyakit seperti pneumonia, tumor otak, dan *COVID-19*.

Penelitian Kedelapan, ***“Penerapan Algoritma Convolutional Neural Network (CNN) Untuk Diagnosa Tumor Otak”*** (Azhar et al., 2024) Pengembangan model klasifikasi tumor otak menggunakan CNN berbasis dataset *MRI* dari Kaggle *Brain Tumor MRI* Dataset. Dataset tersebut terdiri dari empat kelas primer, yakni *Glioma*, *Meningioma*, *Pituitary*, dan *Non-tumor*, yang dianalisis melalui kerangka SEMMA (*Sample, Explore, Modify, Model, Assess*). Evaluasi pada tiga arsitektur CNN mengindikasikan bahwa model B mencapai hasil superior dengan akurasi 98,86%, presisi 98,86%, *recall* 98,86%, serta *F1-score* 98,85%. Teknik augmentasi data diterapkan untuk mengatasi *overfitting* dan memperbaiki generalisasi model.

Penelitian Kesembilan, ***“Pengembangan Model Deep Learning Untuk Deteksi Retinopati Diabetik Menggunakan Metode Transfer Learning”*** (Bintang & Imaduddin, 2024) Menekankan pengembangan model deep learning menggunakan *Convolutional Neural Network* (CNN) untuk mengidentifikasi Retinopati Diabetik (RD) melalui pendekatan transfer learning. Penelitian ini melakukan perbandingan terhadap empat arsitektur CNN, yakni ResNet152V2, Xception, DenseNet201, dan InceptionV3, dengan memanfaatkan dataset APTOS 2019 *Blindness Detection* dari kaggle. Tahapan penelitian mencakup *preprocessing*, *data augmentation*, serta *fine-tuning* untuk mengoptimalkan kemampuan model dalam mendeteksi pola pada citra retina. Hasil evaluasi mengindikasikan bahwa Xception dan DenseNet201 menunjukkan performa unggul dengan akurasi, presisi, *recall*, dan *F1-score* mencapai 96%.

Penelitian Kesepuluh, ***“Klasifikasi Pneumonia dengan Deep Learning Faster Region Convolutional Neural Network Arsitektur VGG16 dan ResNet50”*** (Hekmatyar et al., 2022) Pendekatan *Faster Region-Convolutional Neural Network* (Faster R-CNN) berbasis arsitektur VGG16 dan ResNet50 untuk mengidentifikasi pneumonia pada pasien *COVID-19* menggunakan citra X-ray dada. Dataset yang dimanfaatkan bersumber dari Kaggle, terdiri dari 30.225 citra untuk pelatihan dan 500 citra untuk pengujian. Evaluasi hasil menunjukkan bahwa model VGG16 menghasilkan performa optimal dengan

akurasi 86% dan *mean average precision* (mAP) 14,1%, sementara ResNet50 mencapai akurasi 84%.

Penelitian Kesebelas, ***“Pneumonia Detection from Chest X-ray Images Based on Convolutional Neural Network”*** (D. Zhang et al., 2021) Model CNN berbasis VGG yang dimodifikasi untuk deteksi pneumonia pada citra X-ray dada, dilengkapi *Dynamic Histogram Equalization* (DHE) untuk meningkatkan kontras dan mengurangi ambiguitas gambar. Menggunakan dataset 5.786 citra x-ray (70% latih, 10% validasi, 20% uji), model ini mencapai akurasi 96,07%, AUC 0,991, presisi 94,41%, dan *F1-score* 92,85%, melebihi VGG16, ResNet50, serta DenseNet21.

Penelitian Keduabelas, ***“Analisis Performa Model Convolutional Neural Network Dalam Mendeteksi Penyakit Pneumonia”*** (Brawijaya et al., 2022) Memanfaatkan 2.000 citra yang seimbang antara kondisi paru normal dan pneumoni, penelitian ini menguji 12 variasi scenario berdasarkan perbedaan rasio data pelatihan-pengujian, mode warna (RGB dan grayscale), serta penerapan augmentasi data. Temuan utama mengindikasikan bahwa kombinasi rasio 90:10, *mode grayscale*, dan tanpa augmentasi menghasilkan performa optimal dengan akurasi, presisi, serta *recall* masing-masing mencapai 95%.

Penelitian Ketigabelas, ***“A Federated Learning Framework for Pneumonia Image Detection Using Distributed Data”*** (Kareem et al., 2023) Penerapan deep learning berbasis CNN untuk deteksi pneumonia otomatis pada *citra rontgen* dada, membandingkan arsitektur VGG, ResNet, dan DenseNet. Menggunakan dataset besar citra paru normal-pneumonia dengan pra-pemrosesan untuk tingkatan kualitas dan kurangi *noise*, hasil menunjukkan ResNet unggul dengan akurasi >95%, melebihi model lain.

Penelitian Keempatbelas, ***“Coronavirus Diagnosis Based on Chest X-ray Images and Pre-Trained DenseNet-121”*** (Kateb et al., 2023) Mendiagnosis *COVID-19* dengan menerapkan transfer learning dengan DenseNet-121 melalui *citra rontgen* dada, menggunakan dataset *COVID-19*, pneumonia, dan normal setelah pra-pemrosesan (penyesuaian ukuran, normalisasi piksel, reduksi noise). Hasil menunjukkan akurasi >95% dalam membedakan kondisi paru,

menyimpulkan bahwa metode ini efektif dan efisien untuk deteksi otomatis penyakit paru seperti *COVID-19* dan pneumonia. Penelitian Kelimabelas, ***“Deep Learning Approach for Multi-Label Chest X-ray Diagnosis Using DenseNet-121”*** (Usman et al., 2024) Mendiagnosis 14 penyakit toraks dengan mengembangkan model DenseNet-121 dari *citra rontgen* dada menggunakan dataset *ChestX-ray14*. Dengan pra-pemrosesan normalisasi, augmentasi, dan split 80:20, model mencapai AUC 0,93 untuk emphysema serta performa kompetitif terhadap CheXNeXt pada cardiomegaly, hernia, dan infiltration, meski AUC pneumonia hanya 0,68.

2.1.1 Matriks Penelitian

Tabel 2. 1 Matriks Penelitian

No	Nama Peneliti	Judul Penelitian	Sumber Data	Klasifikasi	Arsitektur	Kesimpulan
1	Ahmad Zein Al Wafi, Febry Putra Rochim, Aisyah Fatimah	<i>Deep Learning Approach For Pneumonia Prediction From X-Rays Using A Pretrained Densenet Model</i>	<i>Guangzhou Women and Children's Medical Center</i>	CNN	DenseNet121, DenseNet169, DenseNet201	Model DenseNet201 memberikan hasil terbaik dengan <i>precision</i> 0.9 dan <i>recall</i> 0.99 untuk kasus pneumonia. Metode ini efektif untuk deteksi otomatis pneumonia dari citra X-ray dengan akurasi tinggi.
2	Çağdaş Şimşek, Suat Özkorkucuklu, Bora Işıldak	<i>Pneumonia Detection in Chest X-ray Images Using Convolutional Neural Networks</i>	<i>Koç University Faculty of Medicine Hospital (1.000 citra X-ray)</i>	CNN	<i>Custom CNN (100 epoch, Adam optimizer, LR=0.0001)</i>	Model CNN mendeteksi pneumonia dengan akurasi 93,3%, <i>F1-score</i> 0.94, dan AUC 0.98. Model efektif mendukung diagnosis otomatis namun perlu diuji pada data dari berbagai rumah

No	Nama Peneliti	Judul Penelitian	Sumber Data	Klasifikasi	Arsitektur	Kesimpulan
						sakit agar lebih universal.
3	Sanjay Gandhi Gundab atini, Meda R. N. D. Lakshmi Roshini , Meruga Navya Sri, Peddisetti Deepthi , Pathuri Surya Teja	<i>Pneumonia Detection using CNN, ResNet and DenseNet</i>	<i>Dataset Kermany (Guangzhou Women and Children's Medical Center)</i>	CNN, ResNet-50, DenseNet-121	CNN, ResNet-50, DenseNet-121	Model CNN memiliki akurasi tertinggi 92.95%, diikuti ResNet-50 (92.79%) dan DenseNet-121 (91.67%). CNN terbukti paling efisien dalam mendeteksi pneumonia dari citra X-ray.
4	Mahmud Ragab, A.A. Ewees, Fatma Helmy, dkk.	<i>Modelling Radiological Features Fusion and Explainable AI in Pneumonia Detection: A Graph-Based Deep Learning and Transformers Approach</i>	NIH & Kaggle	<i>Deep Learning, Explainable AI</i>	<i>Graph Neural Network (GNN) dan Vision Transformer (ViT)</i>	Integrasi arsitektur Graph Neural Network (GNN) dengan Transformer berhasil meningkatkan tingkat akurasi diagnosis hingga 97,8%, sekaligus menyediakan interpretasi visual terhadap hasil output melalui pendekatan explainable AI, sehingga menjadikannya solusi yang efektif dan andal untuk deteksi pneumonia berbasis citra radiologi.

No	Nama Peneliti	Judul Penelitian	Sumber Data	Klasifikasi	Arsitektur	Kesimpulan
5	Mohan Bhandari, Tej Bahadur Shahi, Birat Siku, Arjun Neupane	<i>Explanatory Classification of CXR Images into COVID-19, Pneumonia and Tuberculosis Using Deep Learning and XAI</i>	NIH ChestX-ray14, RSNA	Deep Learning, XAI	DenseNet-121 (Transfer Learning) + <i>Grad-CAM</i> , <i>LIME</i> , <i>SHAP</i>	Model DenseNet-121 mampu memperoleh tingkat akurasi antara 96% hingga 98% dalam mendeteksi pneumonia. Implementasi metode <i>Explainable AI</i> seperti <i>Grad-CAM</i> , <i>LIME</i> , dan <i>SHAP</i> terbukti meningkatkan aspek interpretabilitas model, meskipun sejauh ini baru sekitar 20% penelitian yang menerapkannya. Oleh karena itu, disarankan agar penelitian ke depan mengembangkan model hybrid yang mengombinasikan deep learning dan XAI untuk mendukung aplikasi <i>real-time</i> di negara-negara berkembang
6	Arfat Akhmad Khan, Malik Muhammad Ali Shahid, Rab Nawaz	<i>Detection of Omicron Caused Pneumonia from Radiology Images Using Convolutio</i>	1.500 citra radiologi (500 normal, 400 pneumonia bakteri,	CNN	Tiga model CNN bertahap + <i>Grad-CAM</i>	Model deteksi pneumonia terdiri dari tiga tahap: tahap pertama berhasil mengidentifikasi pneumonia dengan akurasi

No	Nama Peneliti	Judul Penelitian	Sumber Data	Klasifikasi	Arsitektur	Kesimpulan
	Bashir, Salman Iqbal, Arshad Shehzad Ahmad Shahid, Javeria Maqbool, Chitapong Wechtaisong	<i>n Neural Network (CNN)</i>	400 <i>COVID-19, 200 Omicron</i>)			sebesar 98%, tahap kedua mampu membedakan antara infeksi <i>COVID-19</i> dan bakteri dengan tingkat akurasi 88%, sedangkan tahap ketiga dapat mengenali pneumonia akibat varian <i>Omicron</i> dengan akurasi 78%. Penggunaan <i>Grad-CAM</i> pada sistem tersebut memungkinkan visualisasi area paru-paru yang menjadi fokus prediksi, sehingga interpretasi hasil model lebih jelas dan transparan.
7	D Gunawan, H Setiawan	<i>Convolutional Neural Network</i> dalam Analisis Citra Medis	<i>Chest X-ray, MRI, CT scan, Ultrasonid</i>	Deep Learning, CNN	CNN	<i>Convolutional Neural Network (CNN)</i> merupakan metode deep learning unggulan yang efektif untuk tugas klasifikasi, deteksi, segmentasi, dan peningkatan kualitas citra medis. CNN mampu secara otomatis mengekstraksi fitur penting

No	Nama Peneliti	Judul Penelitian	Sumber Data	Klasifikasi	Arsitektur	Kesimpulan
						dari gambar, sehingga mengurangi ketergantungan pada analisis manual dan mempercepat proses diagnosis penyakit seperti pneumonia, tumor otak, dan <i>COVID-19</i> .
8	Azhar, Bambang Siswoyo, Denni Pratama, Khaerul Anam, Heliyanti Susana	Penerapan Algoritma <i>Convolutional Neural Network</i> (CNN) untuk Diagnosa Tumor Otak	Kaggle Brain Tumor MRI Dataset	CNN	Tiga model CNN (Model B terbaik)	Model B menunjukkan performa terbaik dengan akurasi mencapai 98,86%, disertai presisi dan <i>recall</i> yang sama, yaitu 98,86%, serta skor F1 sebesar 98,85%. Pendekatan ini menggunakan teknik augmentasi data untuk mengatasi masalah <i>overfitting</i> sekaligus meningkatkan generalisasi model dalam proses klasifikasi tumor otak.
9	Yayes Kasnanda Bintang, Helmi Imaduddin	Pengembangan Model Deep Learning untuk Deteksi Retinopati Diabetik Menggunakan Metode	Dataset APTOS 2019 Blindness Detection (Kaggle)	Deep Learning, CNN	ResNet152V2, Xception, DenseNet201, InceptionV3	Model Xception dan DenseNet201 menunjukkan performa unggul dengan nilai akurasi, presisi, <i>recall</i> , dan <i>F1-score</i> mencapai 96%.

No	Nama Peneliti	Judul Penelitian	Sumber Data	Klasifikasi	Arsitektur	Kesimpulan
		Transfer Learning				Penelitian ini menegaskan bahwa transfer learning dan augmentasi data efektif dalam meningkatkan akurasi deteksi Retinopati Diabetik melalui citra retina.
10	Hafidz Daffa Hekmatyar, Wahyu Andi Saputra, Cepi Ramdani	Klasifikasi Pneumonia dengan Deep Learning <i>Faster Region Convolutional Neural Network</i> Arsitektur VGG16 dan ResNet50	Dataset X-ray dari Kaggle (30.225 citra latih, 500 citra uji)	Deep Learning, Faster R-CNN	VGG16 dan ResNet50	Pendekatan Faster R-CNN telah berhasil digunakan untuk mendeteksi pneumonia pada pasien <i>COVID-19</i> . Dalam penelitian tersebut, model dengan arsitektur VGG16 memberikan hasil terbaik dengan akurasi mencapai 86% dan mean Average Precision (mAP) sebesar 14,1%, sedangkan model ResNet50 mencapai akurasi 84%. Metode ini efektif untuk mendeteksi area pneumonia melalui segmentasi berbasis objek pada citra X-ray paru-paru.

No	Nama Peneliti	Judul Penelitian	Sumber Data	Klasifikasi	Arsitektur	Kesimpulan
11	Dejun Zhang, Fuquan Ren, Yushuang Li, Lei Na, Yue Ma	Pneumonia Detection from <i>Chest X-ray</i> Images Based on <i>Convolutional Neural Network</i>	Dataset <i>Chest X-ray</i> berisi 5.786 citra (70% latih, 10% validasi, 20% uji)	CNN	Modified VGG + <i>Dynamic Histogram Equalization</i> (DHE)	Model CNN berbasis VGG yang dilengkapi dengan teknik <i>Dynamic Histogram Equalization</i> (DHE) berhasil meningkatkan kontras citra serta akurasi deteksi pneumonia hingga 96,07%. Model ini juga menunjukkan nilai Area Under the Curve (AUC) sebesar 0,991, presisi mencapai 94,41%, dan <i>F1-score</i> sebesar 92,85%. Kinerja model ini melampaui hasil dari model VGG16, ResNet50, dan DenseNet121, menunjukkan keunggulan dalam klasifikasi pneumonia pada citra dada.
12	Ahmad Izzan Kautsar, Bayu Rahayudi, Lailil Muflikhah	Analisis Performa Model <i>Convolutional Neural Network</i> dalam Mendeteksi Penyakit Pneumonia	2.000 citra X-ray (seimbang: normal & pneumonia)	CNN	<i>Convolutional Neural Network</i> (bervariasi 12 skenario)	Kombinasi rasio data 90:10, mode grayscale, dan tanpa augmentasi menghasilkan performa terbaik pada model CNN dengan nilai akurasi, presisi, dan <i>recall</i> masing-masing

No	Nama Peneliti	Judul Penelitian	Sumber Data	Klasifikasi	Arsitektur	Kesimpulan
						mencapai 95%. Hasil ini menunjukkan bahwa rasio data dan mode warna memiliki pengaruh signifikan terhadap kinerja model klasifikasi pneumonia.
13	Amer Kareem , Haiming Liu, Vladan Velisavljevic	A Federated Learning Framework for Pneumonia Image Detection Using Distributed Data	Dataset besar citra X-ray paru (normal & pneumonia)	Deep Learning, CNN, Federated Learning	VGG, ResNet, DenseNet	Penerapan Federated Learning memungkinkan pelatihan model tanpa harus menggabungkan data secara terpusat, sehingga menjaga privasi data pasien. Dalam konteks deteksi pneumonia otomatis, model ResNet menunjukkan performa terbaik dengan akurasi lebih dari 95%, melampaui model VGG dan DenseNet. Metode ini efektif untuk meningkatkan kinerja deteksi pneumonia sambil menjamin keamanan data.
14	Yousra Kateb, Hocine Meglouli, Abdelm	Coronaviruss Diagnosis Based on Chest X-ray Images and Pre-Trained	Dataset X-ray COVID-19, pneumo	Deep Learning, Transfer Learning	DenseNet-121 (Pre-trained)	Model DenseNet-121 berbasis transfer learning mampu

No	Nama Peneliti	Judul Penelitian	Sumber Data	Klasifikasi	Arsitektur	Kesimpulan
	alek Khebli	DenseNet-121	nia, dan normal			mencapai akurasi lebih dari 95% dalam membedakan kondisi paru-paru seperti <i>COVID-19</i> , pneumonia, dan normal. Teknik pra-pemrosesan, termasuk normalisasi piksel dan pengurangan noise, berperan penting dalam meningkatkan stabilitas dan efisiensi deteksi otomatis penyakit paru-paru. Pendekatan ini menunjukkan potensi kuat dalam mendukung diagnosis medis yang cepat dan akurat.
15	Muhammad Usman, Irtaza Ali Nasir, Reeda Saeed, Hajra Nazir, Muhammad Asad	Deep Learning Approach for Multi-Label <i>Chest X-ray</i> Diagnosis Using DenseNet-121	Dataset <i>ChestX-ray14</i>	Deep Learning, Multi-label Classification	DenseNet-121	Model DenseNet-121 mampu mendiagnosis 14 penyakit toraks dengan performa yang cukup baik, termasuk mencapai nilai AUC sebesar 0,93 untuk penyakit emphysema. Model ini juga menunjukkan kinerja kompetitif dibandingkan CheXNeXt,

No	Nama Peneliti	Judul Penelitian	Sumber Data	Klasifikasi	Arsitektur	Kesimpulan
						khususnya pada penyakit cardiomegaly, hernia, dan infiltration. Namun, untuk deteksi pneumonia, kinerja model masih terbatas dengan nilai AUC hanya 0,68. Pra-pemrosesan data seperti normalisasi, augmentasi, dan pembagian data dengan rasio 80:20 sangat berperan dalam meningkatkan kinerja model ini.

Penelitian yang dilakukan penulis memiliki perbedaan dan kebaruan dibandingkan penelitian sebelumnya dalam beberapa hal. Berikut aspek yang menunjukkan bahwa penelitian ini lebih baru dan memiliki kontribusi signifikan:

1. Studi ini tidak sekedar membangun model pengenalan pneumonia melalui arsitektur DenseNet-121 yang memanfaatkan Transfer Learning, melainkan juga menerapkan metode *Explainable Artificial Intelligence* (XAI) seperti *Grad-CAM* guna menyediakan visualisasi wilayah krusial pada gambar X-ray. Strategi ini membuat hasil prediksi model lebih jelas dan mudah ditafsirkan oleh para profesional kesehatan, yang membedakannya dari penelitian sebelumnya yang biasanya hanya menekankan pada tingkat akurasi tanpa mempertimbangkan interpretabilitas.
2. Mayoritas penelitian sebelumnya hanya mengevaluasi kinerja model melalui metrik kuantitatif seperti akurasi, presisi, dan *recall*. Di penelitian ini, penulis menggarisbawahi pentingnya menafsirkan hasil

prediksi dengan bantuan metode XAI, sehingga keputusan model dapat diverifikasi serta divalidasi oleh para dokter. Kondisi ini memberikan keunggulan tambahan dalam penerapan system diagnosis otomatis pada konteks klinis.

3. DenseNet-121 dipilih sebagai arsitektur karena menawarkan koneksi yang kuat antar lapisan, yang memfasilitasi ekstraksi fitur gambar secara lebih optimal dan meminimalkan risiko vanishing gradient. Kelebihan ini membuat model lebih handal serta tepat dalam performanya, bahkan ketika diterapkan pada dataset medis yang memiliki jumlah sampel yang terbatas.
4. Dataset *X-Chest Ray* yang dipergunakan terdiri dari ribuan gambar X-ray dada yang telah diberi label pneumonia dan normal, sehingga menyediakan pondasi yang kuat untuk proses pelatihan model. Dataset ini memungkinkan peilaian model secara komprehensif dalam kondisi sebenarnya, yang membedakannya dari penelitian sebelumnya yang cenderung mengandalkan dataset yang terbatas dari satu sumber saja.
5. Penelitian ini tidak hanya terbatas pada fase pengujian model, melainkan diorientasikan pada penerapan langsung melalui sistem diagnosis berbasis web yang dapat dimanfaatkan oleh para tenaga medis sebagai alat pendukung untuk diagnosis yang cepat serta informatif. Dengan begitu, penelitian ini berpotensi memberikan kontribusi langsung dalam meningkatkan efisiensi dan ketepatan diagnosis pneumonia di fasilitas kesehatan.

Oleh karena itu, penelitian ini diharapkan mampu memberikan kontribusi konkret dalam pengembangan sistem diagnosis medis berbasis deep learning yang tidak hanya unggul dalam tingkat akurasi, melainkan juga efektif dalam menyediakan penjelasan yang jelas terhadap hasil prediksi melalui implementasi Explainable AI. Keunikan inovasi yang ditawarkan membuat penelitian ini menonjol dibandingkan dengan studi sebelumnya, karena mengintegrasikan keunggulan arsitektur DenseNet-121 dengan metode interpretatif XAI, sehingga hasil yang diperoleh tidak hanya akurat, tapi juga transparan serta dapat dipertanggungjawabkan dalam praktik klinis.

2.2 Landasan Teori

Landasan teori membahas tentang beberapa teori yang mendasari analisis permasalahan dan sesuai dengan topik yang dibahas, berikut adalah teori pada penelitian ini:

2.2.1 Pneumonia


Pneumonia komunitas atau community acquired pneumonia (CAP) merupakan salah satu masalah kesehatan yang sering dijumpai dan mempunyai dampak yang signifikan di seluruh dunia, terutama pada populasi usia lanjut. Insiden pneumonia komunitas dilaporkan meningkat sesuai dengan bertambahnya usia.³⁻⁵ Pada pasien usia ≥ 65 tahun yang dirawat di rumah sakit, pneumonia merupakan diagnosis terbanyak ketiga. Angka ini menjadi semakin penting mengingat bahwa diperkirakan sebanyak 20% dari penduduk dunia akan berusia lebih dari 65 tahun di tahun 2050 (Sari et al., 2020). Pneumonia diklasifikasi berdasarkan inang dan lingkungan menjadi pneumonia komunitas, atipikal primer, virus, pneumonis, aspirasi. Salah satu patogen yang dapat menyebabkan pneumonia yang paling umum adalah *Streptococcus pneumoniae*. Pneumonia tentunya perlu mendapat perhatian dan penanganan yang tepat, mengingat penyakit ini masih menjadi permasalahan kesehatan utama di Indonesia. Untuk itu, diagnosis yang tepat, pemberian terapi antibiotika yang efektif, perawatan yang baik, serta usaha preventif yang bermakna terhadap penyakit ini perlu dilakukan agar berkurangnya morbiditas dan mortalitas pada pneumonia (Zahra & Rosfadilla, 2025).



Gambar 2. 1 Pneumonia ([Kaggle](#))

2.2.2 Citra Digital

Citra digital merupakan gambar 2 dimensi yang dihasilkan dari analog dua dimensi yang kontinu menjadi gambar melalui proses sampling. Gambar analog dibagi menjadi N bari dan M kolom sehingga menjadi gambar diskrit. *Pixel* mempunyai dua parameter, yaitu koordinat dan intensitas (warna). Nilai yang terdapat pada koordinat (x,y) adalah $f(x,y)$, yaitu besar intensitas dari pixel di titik itu. Berikut bentuk matriks sebuah citra digital (Wijaya et al., 2021).



Gambar 2. 2 Proses Pengolahan Citra (Yasir et al., 2023)

2.2.2.1 Jenis-Jenis Citra

A. Citra RGB

Citra RGB atau citra berwarna tersusun dari tiga keping warna yaitu *Red* (merah), *Green* (hijau), *Blue* (biru) masing-masing memiliki nilai sebesar 8-bit sehingga nilai derajat warna antara 0 sampai 255. Nilai piksel merah adalah 25x0x0, piksel hijau 0x255x0, dan biru 0x0x255 (Yasir et al., 2023).

B. Citra Grayscale


Citra *grayscale* merupakan citra yang hanya memiliki satu keping warna dengan derajat warna 0 s.d 255 merupakan warna keabuan maka warna hitam sempurna bernilai 0 dan putih sempurna bernilai 255 (Yasir et al., 2023).

C. Citra Binner

Citra biner atau citra monokrom merupakan citra yang hanya memiliki satu keping warna dengan nilai 1-bit sehingga hanya terbagi warna hitam dengan nilai 0 dan warna putih dengan nilai 1 (Yasir et al., 2023).

2.2.3 Pengolahan Citra

Pengolahan Citra merupakan kegiatan memperbaiki kualitas citra agar mudah diinterpretasi oleh manusia / mesin (komputer) (Samsurizal et al., 2021). Inputannya adalah citra dan keluarannya juga citra tapi dengan kualitas lebih baik daripada citra masukan.. Citra yang dimaksud mencakup gambar tetap seperti foto dan gambar bergerak yang berasal dari webcam. Sementara itu, aspek digital menunjukkan bahwa pengolahan ini dilakukan secara digital menggunakan komputer (Shpakov & Bogomolov, 2022).



Gambar 2. 3 Representasi Citra Digital Dalam 2 Dimensi (Shpakov & Bogomolov, 2014)

2.2.4 *Computed Tomography Scanning*

Sebagai modalitas pencitraan radiologi, CT-Scan mengaplikasikan teknologi sinar-X yang terintegrasi dengan sistem komputer untuk menghasilkan gambaran potongan melintang anatomi tubuh. Keunggulan teknik ini adalah kemampuannya menampilkan struktur organ secara terpisah tanpa adanya tumpang tindih gambaran antar organ (Sejati & Nurbaiti, 2021).

2.2.5 *Deep Learning*

Deep learning merupakan salah satu pendekatan dalam machine learning yang memanfaatkan jaringan saraf tiruan berlapis untuk mempelajari representasi data secara otomatis langsung dari data mentah. Pendekatan ini memungkinkan model memahami struktur data yang kompleks tanpa bergantung pada proses perancangan fitur secara manual. (Liu, 2025) menyatakan bahwa deep learning mampu mengekstraksi pola yang rumit serta fitur visual tingkat tinggi pada citra medis, termasuk citra

X-ray dada, sehingga sangat efektif untuk analisis dan interpretasi data medis.

Pendekatan deep learning menggunakan arsitektur jaringan saraf yang mendalam, seperti *Convolutional Neural Network* (CNN), untuk menangkap dan menganalisis pola spasial pada citra radiologi. Melalui kemampuan ini, model deep learning dapat mengenali karakteristik patologis yang bersifat halus dan kompleks pada citra medis, yang dalam banyak kasus sulit diidentifikasi secara akurat hanya melalui pengamatan visual konvensional oleh radiolog. Dalam diagnosis pneumonia, deep learning berfungsi sebagai pendekatan otomatis yang mampu menganalisis citra X-ray dada secara akurat dan konsisten. Pemanfaatan metode ini membantu menekan tingkat subjektivitas serta mempercepat proses pengambilan keputusan, sehingga diagnosis klinis dapat dilakukan dengan lebih tepat waktu dan andal. (Liu, 2025).


2.2.6 Klasifikasi

Klasifikasi merupakan salah satu metode *supervised learning* yang berfokus pada pengelompokan data ke dalam kelas tertentu berdasarkan pola yang dipelajari dari data latih. Dalam pengolahan citra medis, proses ini dilakukan dengan mempelajari karakteristik visual citra agar sistem mampu memberikan label kelas yang tepat pada data baru. (Brawijaya et al., 2022) menyatakan bahwa dalam klasifikasi citra X-ray dada, model pembelajaran mesin memanfaatkan fitur yang diekstraksi dari citra untuk membedakan kondisi paru-paru normal dan paru-paru yang mengalami kelainan, seperti pneumonia.

2.2.7 *Convolutional Neural Network*

Jaringan saraf konvolusional (CNN) adalah algoritma pembelajaran mendalam yang menggunakan foto untuk mengekstrak fitur dengan menggabungkannya dengan kernel atau filter (Arvio et al., 2024). *Convolutional Neural Network* (CNN) merupakan metode *deep learning* yang banyak digunakan dalam pengolahan citra karena kemampuannya mengekstraksi fitur gambar secara otomatis melalui lapisan konvolusi,

pooling, dan *fully connected* (Jatnika et al., 2023). Metode ini sangat efektif dalam mengklasifikasikan, mengidentifikasi, dan mengenali pola-pola di dalam gambar. CNN mampu memahami detail gambar dengan lebih baik karena arsitekturnya mirip dengan cara otak manusia memproses informasi visual. Data yang digunakan adalah data dua dimensi, seperti citra atau suara, yang diproses melalui operasi konvolusi pada matriks dengan bobot berbentuk empat dimensi berupa kernel konvolusi. Oleh karena itu, CNN hanya dapat diterapkan pada data yang memiliki struktur dua dimensi.



Gambar 2. 4 Arsitektur Dasar CNN (Gunawan & Setiawan, 2022)

Berdasarkan gambar diatas, *Convolutional Neural Network* (CNN) dibagi menjadi dua komponen utama, yaitu feature learning yang berfungsi untuk mengekstrak fitur penting dari input data, dan classification yang menangani output akhir setelah proses pembelajaran selesai. Arsitektur CNN terdiri dari beberapa lapisan atau blok multi-bangunan, di mana setiap lapisan beserta fungsinya akan diuraikan secara mendalam selanjutnya (Gunawan & Setiawan, 2022).

2.2.7.1 Convolution Layer

Convolutional Layer berfungsi untuk mengekstraksi fitur dengan cara menghitung nilai setiap piksel keluaran berdasarkan nilai piksel aslinya serta nilai piksel di sekitarnya. Proses perhitungan ini menggunakan kernel (matriks bobot) yang menentukan seberapa besar pengaruh piksel-piksel di sekitar terhadap nilai piksel hasil (Herman Bedi Agtriadi et al., 2025).

2.2.7.2 Pooling Layer

Pooling layer merupakan lapisan yang mengurangi dimensi feature map yang dapat mempercepat komputasi karena parameter yang harus di update semakin sedikit dan juga dapat mengatasi overfitting. Nilai yang diambil pada pooling adalah max pooling

yaitu nilai tertinggi pada area filter tersebut (Paraijun et al., 2022) . Teknik ini tetap mempertahankan elemen informasi yang paling krusial. Selain itu, layer pooling berperan dalam mempercepat proses komputasi dan meningkatkan efisiensi keseluruhan lapisan convolutional. Umumnya, layer ini melibatkan dua metode utama, yakni *max pooling* dan *average pooling*, (Gunawan & Setiawan, 2022). Pada arsitektur CNN lanjutan seperti DenseNet-121, pooling layer tidak selalu berdiri sendiri, melainkan terintegrasi ke dalam transition layer dan global average pooling.

2.2.7.3 Fully Connected Layer

Fully Connected Layer merupakan komponen dasar dalam neural network, di mana setiap neuron saling terhubung secara lengkap. Layer ini biasanya diterapkan di bagian akhir arsitektur jaringan. Pada layer output, layer ini sering memanfaatkan fungsi aktivitas softmax guna mendukung proses klasifikasi. Fungsi softmax ini dirancang untuk mengatasi pembelajaran multi-kelas dalam jaringan saraf serta menangani permasalahan klasifikasi gambar dengan input berupa himpunan piksel.

2.2.8 Transfer Learning


Transfer learning merupakan strategi dalam deep learning yang memanfaatkan pengetahuan yang telah dipelajari model dari tugas atau dataset sebelumnya untuk diterapkan pada tugas baru yang masih memiliki keterkaitan. Berdasarkan kajian literatur yang dilaporkan oleh (Kim et al., 2022), pendekatan ini memungkinkan model yang telah dilatih menggunakan dataset berskala besar untuk digunakan kembali pada klasifikasi citra medis dengan jumlah data yang terbatas, sehingga proses pelatihan tidak perlu dilakukan dari awal.

Dalam pengolahan citra medis, transfer learning umumnya diterapkan dengan memanfaatkan model *Convolutional Neural Network* (CNN) yang telah dilatih sebelumnya pada dataset umum, seperti ImageNet. Model prelatih tersebut kemudian disesuaikan melalui proses *fine-tuning* agar

mampu mengenali karakteristik khusus pada citra medis, termasuk pola visual penyakit pada citra X-ray dada. Pendekatan ini terbukti efektif dalam meningkatkan kinerja klasifikasi sekaligus menekan risiko *overfitting*, terutama ketika jumlah data medis yang tersedia relatif terbatas (Kim et al., 2022).

2.2.9 DenseNet-121

Menurut (Ariawan et al., 2025), DenseNet-121 merupakan salah satu arsitektur CNN yang dirancang untuk meningkatkan pemanfaatan fitur dan memperlancar penyaluran informasi antar lapisan jaringan. Dalam arsitektur ini, setiap lapisan atau blok menerapkan mekanisme feed-forward yang menghubungkan secara langsung dengan semua lapisan atau blok lainnya. Komponen utama pada setiap lapisan DenseNet normalisasi batch, fungsi aktivasi ReLU, serta operasi konvolusi dengan filter 3x3. Normalisasi batch berfungsi untuk mempercepat proses pelatihan dan memungkinkan penggunaan tingkat pembelajaran yang lebih tinggi saat membangun model. Setiap blok menerima input berupa matriks yang mewakili piksel gambar, yang kemudian diproses melalui normalisasi batch guna mengurangi resiko *overfitting* selama tahap pelatihan.



Gambar 2. 5 Arsitektur DenseNet-121 (Ariawan et al., 2025)

2.2.10 Explainable Artificial Intelligence (XAI)

Explainable Artificial Intelligence merupakan sub-disiplin dalam bidang kecerdasan buatan yang menekankan peningkatan keterbukaan dan kemudahan interpretasi pada model AI, terutama untuk sistem deep learning yang sering dipersepsikan sebagai kotak hitam. Tujuan utama XAI adalah

menyediakan penjelasan yang mudah dipahami oleh manusia terkait proses dan alasan di balik keputusan yang dihasilkan oleh model, sehingga dapat meningkatkan tingkat kepercayaan serta akuntabilitas pada sistem yang berbasis AI (Mahamud et al., 2024).

2.2.11 *Confusion matrix*

Confusion matrix adalah metode efisien untuk mengevaluasi kinerja klasifikasi melalui tabel yang menunjukkan jumlah data uji benar atau salah, memudahkan identifikasi kesalahan dan penilaian akurasi. Teknik ini sederhana, efektif, dan bertujuan menilai performa sistem dalam mengklasifikasikan data uji (Nurhidayat & Dewi, 2023).

		Nilai Aktual	
		Positive	Negative
Positive		TP	FP
Negative		FN	TN

Gambar 2. 6 Confussion Matrix (Wibowo et al., 2024)

Keterangan :

- TP (*True Positive*) = Jumlah data positif yang diklasifikasikan oleh sistem dengan benar
- TN (*True Negative*) = Jumlah data negatif yang diklasifikasikan oleh sistem dengan benar
- FP (*False Positive*) = Jumlah data positif yang diklasifikasikan oleh sistem dengan salah
- FN (*False Negative*) = Jumlah data positif yang diklasifikasikan oleh sistem dengan salah

Confusion matrix digunakan untuk mengevaluasi tingkat akurasi dari suatu proses klasifikasi yang telah dilakukan. Akurasi ini menggambarkan proporsi prediksi yang benar. Untuk menghitung akurasi, presisi, dan *recall*, diterapkan rumus-rumus yang relevan sebagai berikut:

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (2.1)$$

$$Recall = \frac{TP}{TP+FN} \quad (2.2)$$




$$Precision = \frac{TP}{TP+FP} \quad (2.3)$$

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (2.4)$$

2.2.12 Flowchart

Flowchart adalah diagram alir yang dimanfaatkan untuk menggambarkan urutan proses atau logika dalam sebuah system secara visual. Dalam konteks penelitian berbasis kecerdasan buatan, *Flowchart* berperan dalam mengilustrasikan tahapan kerja sistem, mulai dari penumpulan data, pra-pemrosesan, pelatihan model evaluasi, hingga interpretasi hasil. Setiap Langkah direpresentasikan dengan symbol standarseperti oval (mulai/akhir), persegi panjang (proses), belah ketupat (keputusan), dan panah (arah aliran data) (Sutanti et al., 2020).

Tabel 2. 2 Flowchart

No	Simbol	Nama	Keterangan
1		Flow Direction	Digunakan untuk menghubungkan simbol yang satu dengan simbol yang lainnya
2		Terminator	Untuk permulaan (start) dan akhir (stop) dari suatu kegiatan
3		Processing	Simbol yang menunjukkan bahwa komputer melakukan pengolahan
4		Decision	Simbol proses yang dipilih berdasarkan kondisi saat ini
5		Connector	Simbol penyambungan proses dalam lembar / halaman yang sama
6		Preparation	Simbol untuk menyiapkan penyimpanan yang akan diproses di dalam penyimpanan

dalam konteks masalah yang diatasi melalui data mining (Dhewayani et al., 2022).

B. *Data Understanding*

Tahap persiapan yang melibatkan pemeriksaan data yang digunakan, pengumpulan data awal, serta identifikasi kualitas data. Pada tahap ini, data akan menjalani proses deskripsi untuk setiap fiturnya (Dhewayani et al., 2022).

C. *Data Preparation*

Proses yang dilaksanakan setelah data dikumpulkan. Pada tahap ini, data menjalani identifikasi, pemilihan, pembersihan, serta transformasi data (Dhewayani et al., 2022).

D. *Modelling*

Tahap pelaksanaan algoritma yang digunakan untuk mencari, mengidentifikasi, serta menghasilkan pola pada data penelitian (Dhewayani et al., 2022).

E. *Evaluation*

Proses untuk mengukur hasil dari model yang telah diimplementasikan pada tahap modeling sebelumnya. Hasil evaluasi ini menggambarkan proses data mining yang telah dilaksanakan serta menentukan model terbaik yang sesuai untuk digunakan (Dhewayani et al., 2022).


F. *Deployment*

Proses penyusunan laporan atau artikel jurnal berdasarkan hasil penelitian yang telah diperoleh. (Dhewayani et al., 2022).

2.2.14 Grad-CAM (*Gradient-weighted Class Activation Mapping*)

Grad-CAM (*Gradient-weighted Class Activation Mapping*) merupakan salah satu teknik Explainable AI yang menghubungkan informasi gradien kelas target dengan *feature map* pada lapisan konvolusi terakhir untuk menghasilkan peta aktivasi (*heatmap*) yang visual. Teknik ini digunakan untuk memperlihatkan area pada citra medis yang paling berpengaruh terhadap prediksi model deep learning sehingga meningkatkan transparansi sistem *black-box* CNN. (H. Zhang & Ogasawara, 2023) menyatakan bahwa

Grad-CAM bekerja dengan menghitung rata-rata gradien terhadap setiap feature map untuk menentukan bobot pentingnya, kemudian menghasilkan *heatmap* yang dapat dibandingkan langsung dengan citra input untuk memperlihatkan fokus model.



Gambar 2. 8 Tahapan Crisp-dm (H. Zhang & Ogasawara, 2023)

Adapun tahapan dari Grad-CAM di jelaskan dibawah ini :

1. Forward Pass

Citra input dimasukkan ke dalam model CNN untuk menghasilkan prediksi kelas. Proses ini menghasilkan output prediksi berdasarkan fitur yang diekstraksi oleh model.

2. Pemilihan Kelas Target

Pada tahap ini, Anda memilih kelas yang ingin dianalisis (pneumonia). Kelas ini akan digunakan untuk mengidentifikasi area citra yang berkontribusi paling besar terhadap keputusan model.

3. Perhitungan Gradien

Gradien dari skor kelas target dihitung terhadap feature map pada lapisan konvolusi terakhir. Ini akan menunjukkan seberapa besar perubahan skor kelas target dipengaruhi oleh perubahan pada tiap fitur di dalam feature map.

4. Global Average Pooling pada Gradien

Gradien yang diperoleh dari langkah sebelumnya dirata-ratakan secara global untuk mendapatkan bobot kepentingan setiap feature map. Global average pooling digunakan untuk menghitung rata-rata gradien per channel.

5. Pembobotan Feature Map

Feature map pada lapisan konvolusi terakhir dikalikan dengan bobot gradien yang dihitung pada langkah sebelumnya. Ini menentukan kontribusi dari setiap fitur yang ada dalam citra terhadap prediksi model.

6. ReLU Activation

Fungsi ReLU diterapkan untuk mempertahankan kontribusi positif yang relevan terhadap kelas target. Hanya nilai positif dari kontribusi yang dipertahankan, sementara yang negatif diset menjadi nol, untuk meningkatkan fokus pada area yang relevan.


7. Pembuatan Heatmap dan Overlay

Fungsi ReLU diterapkan untuk mempertahankan kontribusi positif yang relevan terhadap kelas target. Hanya nilai positif dari kontribusi yang dipertahankan, sementara yang negatif diset menjadi nol, untuk meningkatkan fokus pada area yang relevan.

2.2.15 Python

Python adalah bahasa pemrograman yang populer dan mudah dipelajari. Python sering digunakan dalam pengembangan perangkat lunak, kecerdasan buatan, pengembangan web, machine learning, dan analisis data. Python menyediakan berbagai pustaka, seperti NumPy untuk komputasi numerik dan Pandas untuk analisis data, yang memudahkan pengguna dalam menyelesaikan tugas-tugas tertentu dengan cepat dan efisien (Surbakti et al., 2024).

2.3 Kerangka Pemikiran



Gambar 2. 9 Kerangka Pemikiran

Gambar di atas menggambarkan kerangka pemikiran penelitian yang akan dilakukan, dengan penjelasan sebagai berikut:

1. Indikator

Data penelitian ini terdiri dari citra Ches CT-Scan yang diperoleh dari sumber Kaggle

<https://www.kaggle.com/datasets/paultimothymooney/chest-xray-pneumonia>

2. Metode Usulan

Metode yang digunakan dalam penelitian ini adalah transfer learning dengan memanfaatkan arsitektur DenseNet-121, yaitu sebuah model *Convolutional Neural Network* (CNN) yang sudah dilatih sebelumnya dan disesuaikan untuk tugas klasifikasi citra X-ray pneumonia. Penelitian ini juga mengaplikasikan teknik *Explainable Artificial Intelligence* (XAI), khususnya *Grad-CAM*, untuk menghasilkan interpretasi visual yang menampilkan area citra yang berkontribusi terhadap keputusan model. Sebelum proses pelatihan, citra X-ray akan melalui tahap *preprocessing*, augmentasi, dan normalisasi agar model dapat memiliki performa yang lebih baik serta kemampuan generalisasi yang optimal.

3. Objektif

Tujuan dari penelitian ini adalah untuk mengembangkan model klasifikasi citra X-ray dada yang mampu membedakan antara pneumonia dan non-pneumonia dengan performa tinggi dalam metrik-akurasi, presisi, *recall*, dan *F1-score*. Selain memberikan prediksi kelas, sistem juga akan menyajikan visualisasi interpretasi dari hasil prediksi model agar diagnosis menjadi lebih transparan dan mudah dipahami oleh tenaga medis, sekaligus mendukung pengambilan keputusan klinis berbasis teknologi AI.

4. Pengukuran

Evaluasi performa model dilakukan dengan menggunakan *Confusion matrix* untuk menghitung metrik akurasi, presisi, *recall*, dan *F1-score* pada pengujian klasifikasi citra pneumonia. Selain pengukuran performa secara kuantitatif, efektivitas metode XAI juga divalidasi dengan menilai kesesuaian area visual yang

diidentifikasi oleh model dengan region anatomi serta gejala klinis pada citra X-ray dada.