

## BAB II

### LANDASAN TEORI

#### 2.1 Penelitian Terdahulu

Table 2.1 Penelitian Terdahulu

| No   | Title                                                                                                                             | Model                                        | Akurasi                                   | Penjelasan                                                                                                                                                                                        |
|------|-----------------------------------------------------------------------------------------------------------------------------------|----------------------------------------------|-------------------------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| [21] | Lung-GANs:<br>Unsupervised<br>Representation<br>Learning for Lung<br>Disease Classification<br>Using Chest CT and<br>X-Ray Images | Generative<br>Adversarial<br>Networks (GANs) | 94% – 99.5%                               | Model berbasis<br>GAN berhasil<br>mencapai akurasi<br>yang sangat tinggi<br>pada berbagai<br>kumpulan data<br>penyakit<br>paru-paru dengan<br>meningkatkan<br>pembelajaran<br>representasi fitur. |
| [22] | Lung Disease Detection<br>in Chest X-ray Images<br>Using Transfer<br>Learning                                                     | VGGNet and<br>MobileNet                      | 82%<br>(MobileNet),<br>80%<br>(VGGNet-16) | MobileNet<br>menunjukkan<br>kinerja yang<br>sedikit lebih baik<br>daripada VGGNet<br>berkat<br>arsitektur yang<br>efisien dan<br>kemampuannya<br>dalam<br>mengeksktraksi<br>fitur.                |

| No   | Title                                                                                  | Model                                     | Akurasi | Penjelasan                                                                                                                  |
|------|----------------------------------------------------------------------------------------|-------------------------------------------|---------|-----------------------------------------------------------------------------------------------------------------------------|
| [23] | Transfer Learning with Deep Convolutional Neural Network (CNN) for Pneumonia Detection | AlexNet, ResNet, DenseNet, and SqueezeNet | 98%     | Transfer learning secara signifikan meningkatkan kinerja klasifikasi pneumonia pada gambar rontgen dada.                    |
| [24] | Pneumonia Detection in Chest X-ray Images Using an Ensemble of Deep Learning Models    | GoogLeNet, ResNet, DenseNet               | 98.81%  | Pembelajaran ensemble meningkatkan akurasi dan sensitivitas dengan menggabungkan beberapa arsitektur pembelajaran mendalam. |
| [25] | Detection and Classification of Pneumonia from Lung Ultrasound Images                  | EfficientNet                              | 94.62%  | EfficientNet-B5 menunjukkan kinerja yang sangat baik dalam tugas klasifikasi pneumonia multi-kelas.                         |

| No   | Title                                                                                             | Model                            | Akurasi    | Penjelasan                                                                                                                                                                                                                         |
|------|---------------------------------------------------------------------------------------------------|----------------------------------|------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| [26] | CBAM-Enhanced DenseNet121 for Multi-Class Chest X-Ray Classification with Grad-CAM Explainability | DenseNet121, EfficientNetB3, CNN | 73.88%-85% | Studi tersebut menunjukkan bahwa DenseNet121 memiliki kinerja yang lebih baik daripada EfficientNetB3 dan model CNN acuan, namun kinerja secara keseluruhan masih sangat bergantung pada optimasi model dan karakteristik dataset. |
| [27] | Automated Methods for Detection and Classification Pneumonia using Deep Learning                  | DenseNet                         | 84%        | DenseNet201 mencapai akurasi sekitar 84%, yang menunjukkan bahwa kinerja DenseNet dapat bervariasi tergantung pada prapemrosesan, kualitas dataset, dan konfigurasi pelatihan.                                                     |

| No   | Title                                                                                             | Model                            | Akurasi                                               | Penjelasan                                                                                                                                                                               |
|------|---------------------------------------------------------------------------------------------------|----------------------------------|-------------------------------------------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| [28] | CBAM-Enhanced DenseNet121 for Multi-Class Chest X-Ray Classification with Grad-CAM Explainability | DenseNet121, EfficientNetB3, CNN | DenseNet121: 85%, EfficientNetB3: 73.88%, CNN: 78.53% | The study showed that DenseNet121 outperformed EfficientNetB3 and baseline CNN models, but overall performance still depended heavily on model optimization and dataset characteristics. |

Berdasarkan penelitian terdahulu pada Tabel 2.1, penerapan deep learning dalam mendeteksi pneumonia menggunakan citra chest X-ray telah menunjukkan hasil yang sangat baik. Berbagai arsitektur seperti CNN, DenseNet, ResNet, EfficientNet, VGGNet, MobileNet, GoogLeNet, hingga Generative Adversarial Networks (GANs) berhasil mencapai tingkat akurasi yang tinggi pada dataset yang digunakan masing-masing. Selain itu, beberapa penelitian juga menunjukkan bahwa pendekatan transfer learning mampu meningkatkan performa klasifikasi dibandingkan model yang dibangun dari awal.

Demikian, setiap penelitian menggunakan dataset, proses preprocessing, teknik augmentasi, serta konfigurasi pelatihan yang berbeda-beda. Perbedaan tersebut menyebabkan hasil performa antar penelitian tidak dapat dibandingkan secara langsung. Sebagian penelitian hanya mengevaluasi satu model, sedangkan penelitian lainnya menggunakan pendekatan ensemble learning atau melakukan modifikasi arsitektur, seperti penambahan modul CBAM pada DenseNet121. Akibatnya, masih sulit untuk mengetahui model mana yang memberikan performa terbaik apabila seluruh model diuji pada kondisi eksperimen yang sama.

Karena itu, penelitian ini melakukan perbandingan langsung antara empat arsitektur, yaitu CNN, DenseNet121, ResNet50, dan EfficientNet, menggunakan dataset yang sama, tahapan preprocessing yang sama, parameter pelatihan yang seragam, serta metode evaluasi yang identik. Selain membandingkan nilai accuracy, penelitian ini juga mengevaluasi performa model menggunakan precision, recall, F1-score, confusion matrix, ROC Curve, dan Grad-CAM. Dengan pendekatan tersebut, hasil penelitian diharapkan dapat memberikan perbandingan yang lebih objektif mengenai performa masing-masing model dalam mendeteksi pneumonia berdasarkan citra chest X-ray.

## **2.2 Teori yang berkaitan**

### **2.2.1 Pneumonia**

Pneumonia adalah infeksi pada sistem pernapasan yang biasanya disebabkan oleh virus atau bakteri. Pneumonia dapat menyebabkan penyakit ringan hingga berbahaya bagi semua anggota umat manusia, tetapi juga merupakan jenis pneumonia yang paling umum terjadi pada anak-anak di seluruh dunia. Pada tahun 2017, pneumonia merenggut nyawa lebih dari 808.000 anak di bawah usia 5 tahun, menyumbang 15% dari total kematian pada kelompok usia tersebut. Kelompok lain yang rentan terhadap pneumonia termasuk lansia di atas usia 65 tahun serta individu dengan masalah kesehatan yang sudah ada sebelumnya[1]. Secara bersama-sama, pneumonia dan infeksi saluran pernapasan bawah lainnya merupakan penyebab kematian paling umum keempat pada tahun 2019 dan merupakan kelompok penyakit menular yang paling mematikan[27].

Pneumonia adalah penyebab utama kematian akibat infeksi di seluruh dunia, yang ditandai dengan morbiditas yang tinggi dan mortalitas jangka pendek dan jangka panjang yang signifikan. Pneumonia dapat muncul

sebagai pneumonia yang didapat dari komunitas (CAP), pneumonia yang didapat dari rumah sakit (HAP), atau pneumonia yang berhubungan dengan ventilator (VAP). Kasus yang parah sering kali menyebabkan komplikasi yang berkepanjangan seperti gangguan fungsi paru-paru, penurunan kognitif, dan berkurangnya kekuatan fisik[28].

Pneumonia adalah sebuah kondisi pernapasan yang disebabkan dengan inflamasi pada salah satu atau kedua paru-paru, yang menyebabkan gejala-gejala seperti demam, batuk, dan kesulitan bernapas. Pneumonia menyebabkan kantung udara di paru-paru terisi dengan cairan yang selanjutnya menyebabkan masalah dalam bernapas[29]. Mengidentifikasi pneumonia pada tahap awal sangat penting untuk memberikan pengobatan yang tepat waktu dan meningkatkan hasil pemulihan pasien[30].

### 2.2.2 Transfer Learning

*Transfer Learning* adalah teknik dalam *deep learning* yang memanfaatkan model yang telah melalui proses pelatihan sebelumnya (*pretrained model*) untuk menyelesaikan tugas baru pada dataset yang berbeda. Model *pretrained* umumnya dilatih menggunakan dataset berukuran besar, seperti ImageNet, sehingga mampu mempelajari berbagai karakteristik dan pola umum dari citra. Pengetahuan yang telah diperoleh selama proses pelatihan tersebut kemudian digunakan kembali untuk mendukung proses pembelajaran pada tugas klasifikasi yang baru[30].

Pendekatan ini sangat bermanfaat ketika jumlah data yang tersedia relatif terbatas karena model tidak perlu dilatih dari tahap awal. Dalam penerapannya, *transfer learning* biasanya dilakukan dengan mempertahankan bobot pada beberapa lapisan awal (*freeze layers*) yang berfungsi mengekstraksi fitur umum, kemudian melakukan *fine-tuning*

pada lapisan-lapisan akhir agar model dapat beradaptasi dengan karakteristik dataset yang digunakan[31]. Oleh karena itu, metode ini banyak diterapkan pada bidang *computer vision* dan analisis citra medis karena mampu meningkatkan kinerja model sekaligus mengurangi waktu pelatihan yang dibutuhkan[32].

### 2.2.3 Confusion Matrix

Confusion matrix, atau matriks kebingungan, adalah alat yang digunakan dalam machine learning dan statistik untuk mengevaluasi kinerja model klasifikasi[44]. Matriks ini menampilkan perbandingan antara prediksi model dan nilai aktual, memungkinkan analisis mendalam terhadap kesalahan yang dibuat oleh model. Matriks ini membantu dalam mengidentifikasi sejauh mana model mampu melakukan prediksi secara akurat, serta memberikan wawasan tentang jenis dan jumlah kesalahan yang terjadi selama proses klasifikasi.

Dari confusion matrix, beberapa metrik evaluasi kinerja model dapat dihitung[45]:

Akurasi: Proporsi prediksi yang benar terhadap total prediksi.

$$\frac{TP + TN}{TP + FP + TN + FN}$$

Presisi: Persentase prediksi positif yang benar terhadap total prediksi positif.

$$TP$$

$$TP + FP$$

Recall (Sensitivitas): Proporsi kasus positif yang terdeteksi dengan benar.

$$TP$$

$$TP + FN$$

F1-Score: Rata-rata harmonis dari presisi dan recall.

$$Presisi \times Recall$$

$$2 \times$$

$$Presisi + Recall$$

## 2.3 Framework/Algoritma yang digunakan

### 2.3.1 Convolutional Neural Network (CNN)

Convolutional Neural Networks (CNNs) memanfaatkan struktur spasial dua dimensi dari modalitas input, yang membantu mengurangi jumlah parameter selama fase pelatihan. CNN banyak digunakan untuk segmentasi dan klasifikasi objek[34]. Kemajuan dalam CNN dipercepat dengan peningkatan efisiensi komputasi yang dicapai melalui penerapan operasi konvolusi pada GPU, yang meningkatkan kecepatan pemrosesan 2-24 kali lipat dibandingkan dengan CPU. Lompatan komputasi ini memungkinkan CNN untuk menangani dataset berskala besar yang kompleks secara efektif, sehingga menarik perhatian yang signifikan di bidang deep learning[35].

Arsitektur CNN standar terdiri dari lapisan konvolusi untuk ekstraksi fitur, lapisan penyatuan untuk pengurangan dimensi, dan lapisan yang sepenuhnya terhubung untuk memetakan fitur ke klasifikasi keluaran. Semua komponen ini memungkinkan CNN untuk mempelajari dan menampilkan pola yang rumit pada citra medis, yang sangat penting untuk diagnosis dan analisis yang akurat. Seiring berjalannya waktu, arsitektur

CNN yang lebih baik telah mencapai tingkat akurasi diagnostik yang sebanding dengan para ahli medis, yang menunjukkan potensinya untuk menambah dan mendukung para profesional perawatan kesehatan[36].

Tipe jaringan saraf tiruan yang disebut convolutional neural network (CNN) diciptakan khusus untuk menginterpretasikan data berbentuk grid, seperti gambar.[37]. Struktur dasar CNN terdiri dari beberapa lapisan yang secara berurutan melakukan ekstraksi fitur dan klasifikasi. [38]. Tiga lapisan utama dalam arsitektur CNN adalah[39]:

- a. Convolutional Layer: Lapisan tersebut bertugas untuk mengekstraksi fitur lokal dari input dengan menerapkan filter atau kernel yang bergerak melintasi data. Operasi konvolusi menghasilkan peta fitur yang menyoroti karakteristik penting dalam data, seperti tepi, tekstur, atau pola tertentu. Lapisan tersebut adalah komponen utama pada arsitektur CNN yang berfungsi untuk mendeteksi fitur-fitur signifikan tanpa memerlukan supervisi manusia.
- b. Pooling Layer: Lapisan ini dapat digunakan untuk memperkecil dimensi spasial dari peta fitur, sehingga menurunkan jumlah parameter dan komputasi dalam jaringan. Pooling juga membantu membuat deteksi fitur menjadi lebih robust terhadap translasi kecil pada input. Jenis pooling yang biasa digunakan adalah max pooling, yang menggunakan nilai maksimal di masing-masing area yang digabungkan.. Lapisan pooling membantu dalam mengurangi kompleksitas komputasi dan meningkatkan ketahanan terhadap variasi posisi fitur dalam data.
- c. Fully Connected Layer: Pada bagian akhir jaringan, terdapat lapisan fully connected yang menghubungkan seluruh neuron dari lapisan sebelumnya dengan setiap neuron pada lapisan tersebut. Lapisan ini bertugas

mengintegrasikan berbagai fitur yang telah diekstraksi selama proses pembelajaran untuk menghasilkan keputusan klasifikasi. Melalui kombinasi fitur yang diperoleh, lapisan fully connected menghasilkan prediksi atau keluaran klasifikasi akhir.

### 2.3.2 Residual Neural Network (ResNet)

Residual Neural Network (ResNet) merupakan salah satu pengembangan penting dalam arsitektur deep learning yang dirancang untuk mengatasi permasalahan vanishing gradient pada jaringan saraf yang sangat dalam[40]. ResNet memperkenalkan konsep residual learning melalui penggunaan skip connection, yaitu koneksi yang memungkinkan informasi dari lapisan sebelumnya diteruskan secara langsung ke lapisan berikutnya. Output dari sebuah blok residual dapat dinyatakan sebagai:


$$y = F(x, \{W_i\}) + x$$

Merepresentasikan fungsi residual yang dipelajari oleh jaringan, sedangkan  $x$  merupakan input yang diteruskan melalui skip connection. Pendekatan ini memungkinkan model untuk mempelajari representasi yang lebih efektif serta mendukung pelatihan jaringan yang lebih dalam tanpa mengalami penurunan kinerja (degradation problem).[41].

### 2.3.3 CRISP-DM

*The Cross-Industry Standard Process for Data Mining (CRISP-DM)* adalah kerangka kerja yang diakui secara luas dan serbaguna yang dirancang untuk memandu proses menerjemahkan masalah bisnis yang

kompleks menjadi tugas-tugas penambangan data yang terstruktur. Kerangka ini menyediakan pendekatan sistematis untuk merencanakan dan melaksanakan proyek penambangan data, memastikan bahwa proyek tersebut dilakukan secara efektif



**Gambar 2.1 CRISP-DM**

#### **2.3.3.1 Business Understanding**

Berfokus pada dan mengungkap faktor-faktor penting termasuk kriteria keberhasilan, tujuan dan persyaratan bisnis dan penggalian data serta terminologi bisnis dan istilah teknis[43].

#### **2.3.3.2 Data Understanding**

Tahap kedua dari proses CRISP-DM ini berfokus pada pengumpulan data, pemeriksaan kualitas, dan eksplorasi data. Tujuannya adalah untuk mendapatkan wawasan dari data dan membangun hipotesis terkait informasi tersembunyi yang mungkin ada[43].

#### **2.3.3.3 Data Preparation**

Tahap ketiga dalam proses CRISP-DM ini menitikberatkan pada pemilihan dan persiapan dataset final. Tahapan ini mencakup berbagai tugas seperti pemilihan catatan, tabel, dan atribut, serta pembersihan dan transformasi data agar siap untuk dianalisis lebih lanjut[43].

#### **2.3.3.4 Modeling**

Tahap keempat dalam proses CRISP-DM melibatkan pemilihan dan penerapan berbagai teknik pemodelan. Parameter-parameter tertentu diatur, dan beberapa model dibuat untuk menyelesaikan masalah penambangan data yang sama, dengan tujuan menemukan model yang paling optimal[43].

#### **2.3.3.5 Evaluasian**

Tahap kelima dari proses CRISP-DM berfokus pada penilaian model yang telah dihasilkan dan menentukan cara memanfaatkan hasil yang diperoleh.

Interpretasi model bergantung pada algoritma yang digunakan, dan evaluasi dilakukan untuk memastikan apakah model tersebut telah memenuhi tujuan yang ditetapkan[43].

#### **2.3.3.6 Deployment**

Tahap keenam sekaligus terakhir dari proses CRISP-DM menitikberatkan pada pemanfaatan pengetahuan dan hasil yang diperoleh. Tahapan ini juga mencakup pengorganisasian, pelaporan, dan penyajian wawasan yang telah dihasilkan, sesuai kebutuhan[43].

## **2.4 Tools/software yang digunakan**

### **2.4.1 Python**

Python adalah bahasa pemrograman tingkat tinggi yang dirancang untuk mudah dipelajari dan digunakan, dengan fokus pada produktivitas pengembang serta keterbacaan kode. Python telah menjadi bahasa pemrograman yang dominan dalam pengembangan model machine learning dan kecerdasan buatan (AI)[46].

#### **2.4.1.1 Pandas & Numpy**

NumPy (Numerical Python) merupakan salah satu pustaka dasar dalam Python yang banyak digunakan untuk kebutuhan komputasi ilmiah dan numerik. Pustaka ini menyediakan struktur data berupa multidimensional array yang efisien serta berbagai fungsi matematika yang mendukung proses perhitungan numerik. Dengan kemampuan tersebut, NumPy memungkinkan pengolahan dan manipulasi data dilakukan secara lebih cepat dan efektif.

Sementara itu, Pandas merupakan pustaka Python yang menyediakan struktur data tingkat tinggi, seperti DataFrame, untuk mendukung proses analisis dan pengelolaan data. Pandas menawarkan berbagai fitur yang memudahkan penanganan data, termasuk pengelolaan nilai yang hilang (missing values), pengelompokan data (grouping), agregasi, serta berbagai operasi lain yang penting dalam analisis data[47].

#### **2.4.1.2 Seaborn & Matplotlib**

Matplotlib merupakan pustaka visualisasi data yang banyak digunakan dalam Python untuk membuat berbagai jenis grafik dan plot. Pustaka ini menyediakan antarmuka yang fleksibel sehingga pengguna dapat menghasilkan visualisasi mulai dari grafik sederhana hingga representasi data yang lebih kompleks. Dengan kemampuannya tersebut, Matplotlib menjadi salah satu alat utama dalam penyajian dan eksplorasi data.

Seaborn adalah pustaka visualisasi data yang dibangun di atas Matplotlib dan dirancang untuk mempermudah pembuatan visualisasi statistik yang informatif serta menarik secara visual. Seaborn menyediakan antarmuka tingkat tinggi yang memungkinkan pengguna membuat grafik yang kompleks dengan kode yang lebih sederhana. Selain itu, Seaborn memiliki integrasi yang baik dengan struktur data dari Pandas, sehingga memudahkan proses analisis dan visualisasi data.

[48].

#### **2.4.1.3 Scikit-Learn**

Scikit-learn merupakan pustaka Python yang menyediakan berbagai alat untuk proses data mining dan analisis data secara efisien. Pustaka ini dikembangkan di atas NumPy, SciPy, dan Matplotlib sehingga mampu mendukung implementasi berbagai metode machine learning. Scikit-learn menawarkan beragam algoritma yang dapat digunakan untuk tugas klasifikasi, regresi, pengelompokan (clustering), serta reduksi dimensi (dimensionality reduction), sehingga menjadi salah satu pustaka yang banyak digunakan dalam pengembangan model pembelajaran mesin[49].

#### 2.4.1.4 TensorFlow & Pytorch

Google menciptakan pustaka TensorFlow sumber terbuka untuk pembelajaran mesin dan komputasi numerik berskala besar. TensorFlow telah memantapkan dirinya sebagai standar dalam penelitian dan produksi, menawarkan antarmuka yang mudah digunakan untuk membuat dan melatih model deep learning.[50].

PyTorch dikembangkan oleh Facebook's AI Research lab (FAIR) dan telah menjadi populer di kalangan peneliti dan praktisi pembelajaran mendalam. PyTorch menawarkan fleksibilitas dan kemudahan penggunaan dengan pendekatan yang lebih "pythonic" dan dukungan kuat untuk komputasi dinamis, yang memudahkan eksperimen dan pengembangan model[51].

#### 2.4.2 Jupyter Notebook

Membuat dan berbagi dokumen dengan kode komputer, teks deskriptif, visualisasi, dan komponen multimedia lainnya menjadi mudah dengan Jupyter Notebook, alat web open-source. Penggabungan kode yang dapat dieksekusi, dokumentasi, dan visual ke dalam satu dokumen interaktif adalah praktik umum dalam ilmu data, pembelajaran mesin, dan penelitian ilmiah.[52]. Fitur Utama Jupyter Notebook[53]:

1. Interaktivitas: Memungkinkan eksekusi kode secara interaktif, sehingga pengguna dapat melihat hasil secara langsung dan melakukan iterasi dengan cepat.
2. Integrasi Multibahasa: Mendukung berbagai bahasa pemrograman melalui penggunaan kernels, meskipun Python adalah yang paling umum digunakan.

3. Dokumentasi Terintegrasi: Memungkinkan penulisan teks deskriptif menggunakan Markdown, sehingga dokumentasi dapat disajikan bersama dengan kode.
4. Visualisasi Data: Mendukung integrasi dengan pustaka visualisasi seperti Matplotlib dan Seaborn untuk menampilkan grafik dan plot secara langsung dalam notebook.

### 2.4.3 Kaggle

Kaggle adalah platform daring yang menyediakan lingkungan bagi para profesional dan penggemar data science untuk berkolaborasi, berbagi dataset, dan berpartisipasi dalam kompetisi analisis data. Sejak didirikan pada tahun 2010, Kaggle telah menjadi pusat komunitas global yang berfokus pada pembelajaran mesin dan analisis data. Kaggle telah menjadi alat yang berharga dalam penelitian data science. Melalui kompetisi yang diselenggarakan, peneliti dapat menguji algoritma dan model mereka pada dataset nyata dan membandingkan kinerja dengan peserta lain. Selain itu, akses ke berbagai dataset publik memungkinkan peneliti untuk melakukan eksperimen dan validasi model secara efisien. Kaggle juga memfasilitasi kolaborasi lintas disiplin dan geografis, mempercepat inovasi dalam bidang pembelajaran mesin dan analisis data[54].