

## BAB II TINJAUAN PUSTAKA

Pada BAB ini dijelaskan beberapa topik yang berkaitan dengan penelitian yang penulis lakukan. Dengan isi tinjauan pustaka terkait penelitian terdahulu yang relevan terhadap penelitian, penyakit pneumonia secara spesifik dalam diagnosis, arsitektur model VGG16, dan *Explainable AI* yang dalam penelitian ini sebagai topik utama untuk membantu menjelaskan hasil diagnosis model *deep learning* terkait kasus pneumonia menggunakan data citra x-ray. Penjelasan mendalam mengenai topik-topik tersebut diharapkan dapat memberikan penulis landasan yang kuat dan mendukung keberhasilan analisis yang dilakukan dalam penelitian ini.

### 2.1 Penelitian Terdahulu

Berdasarkan riset pada berbagai sumber, terdapat penelitian-penelitian yang telah dilakukan sesuai dengan topik penulis saat ini. Penelitian tersebut dapat digunakan sebagai acuan dalam penggunaan sebuah teori atau metode mendalam. Sehingga dalam penelitian yang diangkat oleh penulis dapat memberikan kontribusi lebih lanjut untuk studi di masa yang akan datang. Beberapa penelitian terdahulu yang relevan dengan penulis dapat dilihat pada **Tabel. 1** berisi studi literatur.

**Tabel 1.** Studi Literatur

NO	Judul Penelitian dan Metode Penelitian	Penulis dan Tahun Penelitian	Hasil Pembahasan
1	Ensemble Image Explainable AI (XAI) Algorithm for Severe Community-Acquired Pneumonia and COVID-19 Respiratory Infections.  (Model <i>deep learning</i> yang digunakan VGG16, Exception. Metode <i>explainable</i> SHAP, Grad-CAM, Grad-CAM++,	Lin Zou, dan tim, tahun 2023	Penelitian ini mengolah data citra x-ray pasien pneumonia dan COVID-19 rumah sakit di Singapura. Model yang dibangun menggunakan VGG16 memiliki nilai akurasi dan AUC sebesar 85.5% dan 94.8% lebih tinggi daripada Exception sebesar 81.7% dan 91.7%. Sedangkan metode XAI yang diusulkan menggunakan EnsembleXAI


	<p>Saliency Map, LIME, EnsembleXAI)</p>		<p>memiliki performa paling baik daripada metode lain dan mendapat kepercayaan dari ahli radiolog, dengan nilai rata-rata F1 0.77, <i>Recall</i> 0.88, <i>Precision</i> 0.72 menggunakan model VGG16. Pada penelitian ini, ditemukan bahwa penggunaan kombinasi metode <i>explainable</i> (Grad-CAM++ dan SHAP) dengan kemiripan hasil metode menunjukkan areal yang lebih spesifik tersegmentasi sehingga dapat dilakukan observasi lebih lanjut [8]. Meskipun penelitian ini menunjukkan kombinasi metode menguntungkan diagnosis, terdapat kekurangan yang perlu disoroti terkait penggunaan dataset yang digunakan oleh peneliti pada bagian interpretasi dilakukan pengujian hanya menggunakan data citra yang diprediksi terinfeksi pneumonia (<i>true positive</i>). Sehingga pembaca tidak mengetahui hasil interpretasi paru-paru yang normal.</p>
<p>2</p>	<p>Using Diverse ConvNets to Classify Face Action Units in Dataset on Emotions Among Mexicans (DEM)</p>	<p>Marco A. Moreno-Armendariz dan tim, tahun 2024</p>	<p>Penelitian ini menguji model <i>deep learning</i> untuk mengolah dua dataset citra wajah untuk mendeteksi ekspresi wajah. Mengolah dataset “<i>Dataset on Emotions among Mexicans</i></p>

	<p>(Model <i>deep learning</i> yang digunakan VGG19, ResNet101, MobileNetV2, NASNet Mobile, EfficientNetB0, ShuffleNetV2, Classifier.                  Metode <i>explainable</i> Grad-CAM dan Grad-CAM++)</p>	<p>(DEM)”, model VGG19 memiliki hasil rata-rata F1 <i>score</i> paling tinggi dengan nilai 0.818 dari 12 unit aksi atau ekspresi. Pengolahan dataset Denver Intensity of Spontaneous Facial Action (DISFA) memiliki hasil yang berbeda, di mana model yang baru dikenalkan (Classifier) menghasilkan rata-rata F1 <i>score</i> tertinggi dari 12 unit aksi dengan nilai 0.944. Pada penelitian ini juga membandingkan Metode XAI antara Grad-CAM dan Grad-CAM++ menggunakan model VGG19 dan ShuffleNetV2 dengan alasan memiliki hasil skor yang paling stabil pada kedua dataset. Ditunjukkan dalam visualisasinya, Grad-CAM++ berhasil menunjukkan segmentasi areal penting yang lebih baik daripada Grad-CAM [9]. Terdapat beberapa kekurangan yang disoroti terkait interpretasi Grad-CAM dan Grad-CAM++ yang sering kali berbeda di hasil segmentasi.</p>
--	---	---

## 2.2 Pneumonia

Pneumonia secara global dikenal sebagai *Forgotten Communicable Disease* dan *Forgotten Killer*. Hal tersebut disebabkan karena pneumonia merupakan penyakit menular akibat bakteri, jamur, dan virus dibawa udara yang sering terlupakan hingga menyebabkan kematian. Pada beberapa tahun ke belakang, pneumonia dan COVID-19 selalu dikaitkan satu dengan yang lain. Gejala, pengobatan, pengaruhnya terhadap imun, dan kasus yang hampir

sama menunjukkan kaitan antara kedua penyakit tersebut. Pneumonia pada pasien dengan penyakit lain seperti hipertensi dan diabetes memiliki tingkat kematian yang lebih tinggi [10]. Menurut medis, diagnosis pneumonia dapat dilakukan dengan cara anamnesis, pemeriksaan fisis, foto toraks dan laboratorium. Gejala dan tanda klinis tidak dapat memberikan gambaran akurat sehingga diagnosis paling bisa dilakukan adalah melakukan foto toraks. Pneumonia dikatakan positif apabila pada gambar foto toraks terdapat in filtrat (zat atau material yang memasuki tubuh) diikuti gejala klinis seperti batuk, demam, sesak napas, dan lainnya [11].



(A)

(B)

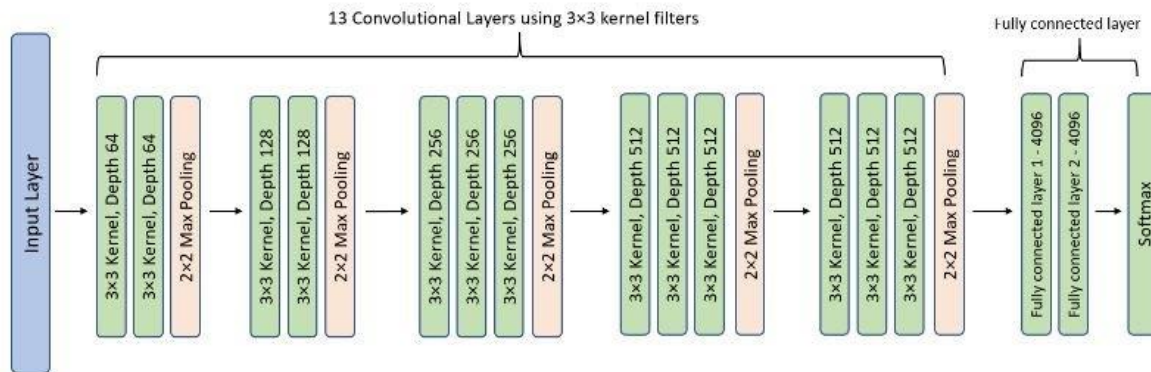
**Gambar 1.** Citra X-Ray : (A) Paru-paru Normal, (B) Paru-paru dengan In filtrat

Pada **Gambar 1** ditunjukkan contoh data pasien “A” yang tidak terdiagnosis mengidap pneumonia dan pasien “B” yang terdapat in filtrat (substansi yang lebih padat dibandingkan udara, seperti lendir, nanah, darah, atau protein, yang ditemukan di jaringan tubuh) di dalam paru-parunya. Pada tiap bagian dari gambar harus diidentifikasi lanjut dengan memperhatikan bayangan yang ada di dalamnya. Perlu adanya ketelitian dan studi mendalam untuk mengetahui sebuah bayangan pada citra tersebut dianggap berbahaya atau tidak. Diagnosis memerlukan waktu yang terkadang cukup lama untuk mengetahui apakah pasien terdeteksi penyakit.

### 2.3 VGG16

VGG pada dasarnya merupakan pengembangan arsitektur CNN (*Convolutional Neural Network*). VGG pertama kali diperkenalkan oleh tim VGG “Visual Geometry Group” terdiri dari Karen Simonyan dan Andre Zisserman pada 2015 pada judul penelitian “Very Deep Convolutional Networks for Large-Scale Image Recognition”. Secara umum arsitektur VGG mengolah citra berukuran 224\*224 dengan saluran warna RGB. Khusus di dalamnya menggunakan filter berukuran paling kecil (3\*3) seperti pada **Gambar 2**. Variasi yang dibuat oleh pengembang memiliki 16 dan 19 lapisan *convolution* dan *pooling*. VGG telah digunakan

dalam berbagai penelitian dan kompetisi sejak pertama kali rilis hingga sekarang dalam bidang kesehatan [12], SAR [13], deteksi benda [14], bisnis [15], olahraga [16], dan lainnya.



**Gambar 2.** Arsitektur VGG16

### 2.3.1 Lapisan Convolutional

Lapisan *Convolutional* pada **Gambar 2** atau lapisan konvolusi pada arsitektur VGG memanfaatkan reseptif minimal berukuran  $3 \times 3$  di mana ukuran tersebut merupakan ukuran terkecil yang masih dapat menangkap arah atas, bawah, kanan, dan kiri. Terdapat pula sebuah filter konvolusi berukuran  $1 \times 1$  dengan fungsi sebagai transformasi linier dari lapisan *input*. Unit ReLU (*Rectified Linear Unit*) yang merupakan inovasi dari arsitektur AlexNet digunakan untuk mengurangi waktu pelatihan. ReLU akan menghasilkan nilai *input* jika nilainya positif dan nol "0" jika hasilnya negatif yang penting dipelajari oleh jaringan saraf saat pelatihan.

### 2.3.2 Lapisan Pooling

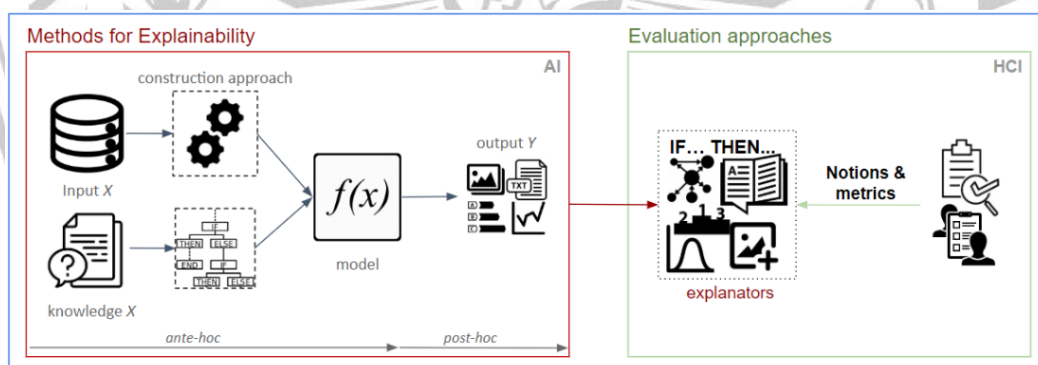
Lapisan *Pooling* adalah lapisan pada arsitektur CNN selain lapisan konvolusi yang bertugas mengolah data. Secara umum tujuan utamanya adalah mengurangi ukuran data dan jumlah parameter sehingga meningkatkan efisiensi dalam komputasi dan mengatasi *overfitting* [17]. *Max pooling* dalam **Gambar 2** merupakan salah satu jenis dari lapisan ini dengan karakteristik memilih nilai maksimum dalam setiap area reseptif. Lapisan ini juga memiliki manfaat untuk membantu fokus jaringan saraf pada fitur-fitur penting demi menjaga performa dan efisiensi model.

### 2.3.3 Lapisan Fully Connected

Lapisan *Fully Connected* pada **Gambar 2** memiliki dua lapisan yang berisi 4096 unit neuron yang masing-masing terhubung dengan semua neuron pada lapisan sebelumnya, dan satu lapisan *output* dengan 1000 unit neuron. Pada dua lapisan pertama, memiliki tugas untuk mengumpulkan dan memproses informasi dari lapisan sebelumnya untuk membuat keputusan yang kemudian diperhalus dan disaring fitur-fitur yang telah dipelajari oleh jaringan. Hasil dari dua lapisan tersebut kemudian masuk ke dalam lapisan *output* untuk menghasilkan probabilitas prediksi akhir jaringan.

## 2.4 Explainable Artificial Intelligence (XAI)

Sejak diperkenalkan kepada dunia, *Explainable Artificial Intelligence* (XAI) telah mengalami kemajuan yang signifikan. Sempat disinggung bahwa sebagian besar model pembelajaran mesin dan pembelajaran mendalam memiliki “kotak hitam” karena kompleksitas dan sifat non-linear terkait interpretasinya. Di negara-negara Uni Eropa, model yang mengolah data harus bertanggung jawab sebagai persyaratan hukum [18]. Artinya secara khusus setiap penggunaan kecerdasan buatan harus memiliki dasar kejelasan dalam pengambilan keputusan yang dibuat.



**Gambar 3.** Simulasi Pandangan Diagram XAI Sebagai Sub-Bidang Persimpangan Antara Kecerdasan Buatan Dan Interaksi Manusia-Komputer

Dijelaskan pada **Gambar 3** terkait kerangka konsep yang mendasari adanya XAI sebagai penghubung antara model dan manusia. Konsep tersebut berkaitan terhadap fase setelah transparansi keputusan dibuat. Fase ini menjelaskan bagaimana penjelasan tersebut dapat dipercaya manusia sesuai dengan kriteria tertentu seperti yang dibuat oleh Komisi Eropa yang disinggung sebelumnya [19]. Terdapat tujuh kriteria utama, yaitu pengawasan manusia, ketangguhan dan keamanan, privasi dan tata kelola data, transparansi, keanekaragaman dan

keadilan, kesejahteraan sosial dan lingkungan, serta akuntabilitas. Kriteria tersebut dirumuskan pada prinsip transparansi, keandalan, dan perlindungan data.

Metode XAI memiliki 3 jenis dalam penerapan komputasi yang efektif [20], yaitu *pre-model* (sebelum pelatihan model) yang berguna untuk pengolahan data, *in-model* (saat pelatihan model) untuk transparansi model seperti pada algoritma pembelajaran mesin *Decision Tree*, dan *post-model* (setelah pelatihan model) yang berguna untuk menjelaskan hasil keputusan yang dibuat oleh model. Dalam konteks *deep learning*, *post-model* merupakan metode yang paling banyak digunakan. Hal ini berkaitan pada luaran prediktif data. Dalam sektor medis contohnya, *post-model* XAI membantu penjelasan sebuah model mengambil keputusan. Terdapat survei yang menguatkan penggunaan algoritma pembelajaran mesin dengan XAI dalam dunia medis [21]. Menunjukkan banyaknya penelitian terdahulu terkait interpretasi hasil model pembelajaran mesin yang mendorong pendidikan medis berbasis data dan matematika. XAI menunjukkan perkembangannya dalam dunia medis, namun masih perlu pengawasan ketat oleh klinisi dan praktisi. Penjelasan visual dan tekstual dari algoritma utamanya.

#### 2.4.1 Grad-CAM++

Grad-CAM++ (*Gradient-weighted Class Activation Mapping++*) merupakan pengembangan dari versi Grad-CAM sebelumnya. Metode ini menghasilkan peta panas (*heatmap*) pada area-area dalam citra dengan kontribusi terbanyak menghasilkan keputusan model *deep learning* [22]. Grad-CAM++ dan versi sebelumnya memiliki cara kerja menghitung bobot gradien pada setiap piksel dan *feature map*, sehingga penggabungan keduanya menghasilkan skor untuk masing-masing kelas klasifikasi. Areal terdeteksi dari Grad-CAM++ hanya mempertimbangkan gradien positif atau fitur dalam citra yang terdeteksi meningkatkan keputusan model, tidak menunjukkan fitur negatifnya.





**Gambar 4.** Implementasi Grad-CAM dan Grad-CAM++

Dijelaskan pada **Gambar 4** di atas contoh hasil penggunaan Grad-CAM++ dan versi sebelumnya (Grad-CAM) menunjukkan gradien positif atau *heatmap* fitur terdeteksi memiliki pengaruh dalam perhitungan skor kelas, dan bagian lain tidak memiliki gradien positif atau negatif dianggap tidak berbobot untuk perhitungan skor kelas.

