

Klasifikasi Citra X-Ray Pneumonia Menggunakan Convolutional Neural Network (CNN) dengan Eksplorasi Tekstur Gabor Filter

Sigit Hudawiguna*, Muhammad Rikza Nashrulloh, Mita Tri Andari

Sistem Informasi, Institut Teknologi Garut, Garut, Indonesia

Email: ^{1,*}sigithudawiguna@itg.ac.id, ²rikza@itg.ac.id, ³2106049@itg.ac.id

Email Penulis Korespondensi: sigithudawiguna@itg.ac.id*

Submitted: 15/04/2026; Accepted: 19/05/2026; Published: 30/06/2026

Abstrak—Pneumonia merupakan salah satu penyakit pernapasan yang dapat dideteksi melalui citra *X-ray* dada, ditandai dengan munculnya infiltrat pada paru-paru. Proses diagnosis manual oleh tenaga medis memerlukan waktu dan berpotensi menghasilkan subjektivitas, sehingga diperlukan pendekatan berbasis kecerdasan buatan. Penelitian ini bertujuan mengembangkan model klasifikasi pneumonia menggunakan metode *Convolutional Neural Network* (CNN) yang dikombinasikan dengan eksplorasi *Gabor Filter* untuk analisis tekstur citra. Metodologi yang digunakan adalah *sEMMA* (*Sample, Explore, Modify, Model, Assess*). Dataset yang digunakan bersumber dari *Kaggle* berjumlah 5.216 citra yang terbagi menjadi dua kelas, yaitu normal dan pneumonia, dengan pembagian data *training* dan *validation* menggunakan rasio 80:20. Tahap *preprocessing* meliputi *resize* citra, konversi *grayscale*, augmentasi data, normalisasi, serta penerapan *Gabor Filter* sebagai analisis tekstur. Model CNN dibangun secara kustom dan dilatih menggunakan *optimizer* Adam. Hasil evaluasi menunjukkan bahwa model mencapai akurasi 90,61%, presisi 98,97%, *recall* 88,12%, dan *F1-score* sebesar 0,9323. Selain itu, nilai *AUC-ROC* sebesar 0,9854 dan *AUC-PR* sebesar 0,9950 menunjukkan kemampuan klasifikasi yang baik. Hasil penelitian ini menunjukkan bahwa metode yang diusulkan berpotensi mendukung diagnosis pneumonia berbasis citra medis.

Kata Kunci: *Pneumonia; Chest X-ray; Convolutional Neural Network; Gabor Filter; sEMMA*

Abstract—Pneumonia is a respiratory disease that can be identified through chest *X-ray* images, typically indicated by infiltrates in the lung area. Manual diagnosis by medical professionals is time-consuming and may lead to subjective interpretation, highlighting the need for automated approaches using artificial intelligence. This study aims to develop a pneumonia classification model using a *Convolutional Neural Network* (CNN) combined with *Gabor Filter* exploration for texture feature analysis. The research adopts the *sEMMA* methodology, consisting of *Sample, Explore, Modify, Model, and Assess* stages. The dataset comprises 5,216 chest *X-ray* images from *Kaggle* categorized into normal and pneumonia classes, with an 80:20 *training-validation* split. *Preprocessing* steps include image resizing, grayscale conversion, data augmentation, normalization, and *Gabor Filter* application as texture analysis. A custom CNN architecture was developed and trained using the Adam *optimizer*. The evaluation results show that the model achieves an accuracy of 90.61%, precision of 98.97%, *recall* of 88.12%, and an *F1-score* of 0.9323. Furthermore, the model demonstrates strong classification performance with an *AUC-ROC* of 0.9854 and an *AUC-PR* of 0.9950. These findings indicate that the proposed method has the potential to support pneumonia diagnosis based on medical imaging.

Keywords: *Pneumonia; Chest X-ray; Convolutional Neural Network; Gabor Filter; sEMMA*

1. PENDAHULUAN

Pneumonia merupakan salah satu penyakit infeksi saluran pernapasan yang menjadi penyebab utama morbiditas dan mortalitas di dunia, khususnya pada kelompok rentan seperti anak-anak dan lansia [1], [2]. Penyakit ini ditandai dengan adanya infeksi pada alveolus paru-paru yang menyebabkan akumulasi cairan atau nanah, sehingga mengganggu proses pertukaran oksigen dalam tubuh [3]. Salah satu metode diagnosis yang umum digunakan adalah analisis citra *X-ray* dada, yang mampu menampilkan kondisi paru-paru secara visual, termasuk adanya infiltrat atau bercak putih yang mengindikasikan infeksi. Namun, proses interpretasi citra *X-ray* secara manual masih memiliki berbagai keterbatasan, seperti membutuhkan waktu yang relatif lama, bergantung pada pengalaman radiolog, serta berpotensi menimbulkan subjektivitas antar pengamat [4], [5]. Kondisi ini menjadi tantangan tersendiri dalam upaya diagnosis yang cepat dan akurat, terutama ketika jumlah pasien meningkat secara signifikan. Oleh karena itu, diperlukan suatu sistem otomatis berbasis kecerdasan buatan yang mampu membantu proses diagnosis secara lebih cepat, objektif, dan akurat.

Perkembangan teknologi deep learning, khususnya *Convolutional Neural Network* (CNN), telah menunjukkan performa yang sangat baik dalam pengolahan citra medis, termasuk klasifikasi pneumonia berbasis citra *X-ray*. CNN mampu mengekstraksi fitur secara otomatis dari citra tanpa memerlukan rekayasa fitur manual, sehingga menjadi metode yang populer dalam berbagai penelitian klasifikasi citra medis [6]. Meskipun demikian, tantangan masih muncul dalam hal optimalisasi preprocessing data, ketidakseimbangan dataset, serta pemanfaatan metode ekstraksi fitur tambahan yang dapat meningkatkan performa model secara signifikan.

Beberapa penelitian sebelumnya telah mengkaji penggunaan CNN untuk klasifikasi pneumonia. Penelitian oleh Kong dan Cheng (2021) mengembangkan model CNN untuk klasifikasi pneumonia berbasis citra *X-ray* dan menunjukkan bahwa pendekatan deep learning dapat meningkatkan akurasi diagnosis dibandingkan metode

konvensional [7]. Selanjutnya, Ahmed et al. (2022) juga menerapkan CNN untuk mendeteksi pneumonia dan menekankan pentingnya diagnosis dini guna mengurangi tingkat kematian akibat penyakit tersebut [8].

Penelitian yang lebih baru menunjukkan pengembangan model yang lebih kompleks dan akurat. Yen dan Tsao (2024) mengusulkan lightweight CNN yang mampu melakukan klasifikasi citra X-ray secara efisien dengan tetap mempertahankan performa tinggi [9]. Sementara itu, penelitian lain mengembangkan model CNN dengan pendekatan explainable AI menggunakan Integrated Gradients, yang mampu mencapai akurasi hingga 97,2% serta meningkatkan interpretabilitas model bagi tenaga medis [5].

Selain itu, penelitian oleh Liu et al. (2023) menggabungkan CNN dengan MLP-mixer untuk meningkatkan kemampuan klasifikasi pneumonia berbasis citra X-ray, menunjukkan bahwa kombinasi model dapat meningkatkan performa dibandingkan model tunggal [10]. Penelitian terbaru lainnya menggabungkan CNN dengan *Vision Transformer* atau model *ensemble* untuk meningkatkan akurasi klasifikasi hingga di atas 94%, dengan memanfaatkan kekuatan representasi fitur yang lebih kompleks [11].

Di sisi lain, beberapa penelitian juga mengeksplorasi penggunaan teknik preprocessing dan filtering untuk meningkatkan kualitas citra sebelum masuk ke model CNN. Penggunaan berbagai filter seperti *Gaussian*, *median*, dan *Wiener* terbukti dapat meningkatkan akurasi klasifikasi citra medis hingga di atas 96% . Selain itu, *Gabor Filter* juga telah digunakan dalam beberapa penelitian untuk meningkatkan ekstraksi fitur tekstur pada citra medis, terutama dalam meningkatkan kontras dan pola frekuensi spasial [12].

Meskipun berbagai penelitian telah menunjukkan hasil yang sangat baik, masih terdapat beberapa celah (*gap*) yang dapat diidentifikasi. Pertama, sebagian besar penelitian berfokus pada peningkatan akurasi model dengan menggunakan arsitektur kompleks seperti ensemble learning atau transformer, namun belum banyak yang mengeksplorasi kombinasi metode sederhana namun efektif antara CNN dengan teknik ekstraksi fitur tekstur seperti *Gabor Filter* secara komprehensif. Kedua, beberapa penelitian lebih menitikberatkan pada penggunaan pretrained model, sehingga kurang mengeksplorasi kemampuan arsitektur CNN kustom dalam menangkap karakteristik spesifik citra pneumonia. Ketiga, evaluasi model pada beberapa penelitian masih terbatas pada metrik akurasi, tanpa mempertimbangkan metrik lain seperti *precision*, *recall*, *F1-score*, serta *AUC* yang lebih representatif dalam klasifikasi data tidak seimbang.

Berdasarkan *gap* yang telah diidentifikasi, penelitian ini memiliki beberapa kontribusi utama yang membedakannya dari penelitian sebelumnya. Pertama, penelitian ini mengembangkan arsitektur CNN kustom tanpa menggunakan *pretrained model*, sehingga mampu menangkap karakteristik spesifik citra pneumonia sesuai dengan kebutuhan dataset. Kedua, penelitian ini mengimplementasikan pendekatan metodologi *sEMMA* (*Sample, Explore, Modify, Model, Assess*) yang memberikan kerangka kerja sistematis dari tahap pengumpulan data hingga evaluasi model. Ketiga, penelitian ini melakukan eksplorasi *Gabor Filter* sebagai alat analisis tekstur dan visualisasi, bukan sebagai fitur tambahan dalam model CNN, mengingat CNN secara intrinsik telah mampu melakukan ekstraksi fitur otomatis. Keempat, evaluasi model dilakukan dengan metrik yang lebih komprehensif, meliputi akurasi, presisi, *recall*, *F1-score*, *AUC-ROC*, dan *AUC-PR*, yang memberikan gambaran menyeluruh terhadap kemampuan model dalam menangani dataset tidak seimbang.

Dengan demikian, penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan sistem klasifikasi pneumonia yang lebih efektif, efisien, dan aplikatif dalam dunia medis. Hasil penelitian ini juga diharapkan dapat menjadi dasar bagi pengembangan penelitian selanjutnya, khususnya dalam eksplorasi metode kombinasi antara deep learning dan teknik ekstraksi fitur untuk meningkatkan performa klasifikasi citra medis.

2. METODOLOGI PENELITIAN

Penelitian ini menggunakan metode *SEMMA* untuk menerapkan algoritma CNN dan *Gabor Filter* dalam klasifikasi citra x-ray pneumonia, yang meliputi lima tahap: *Sample, Explore, Modify, Model, dan Assess*.

2.1 sEMMA

Metodologi *sEMMA*, yang dikembangkan oleh SAS, berfokus pada penyusunan logis pada tahap pengembangan model proyek pembelajaran mesin. Singkatan *sEMMA*, yang meliputi tahap *sample, explore, modify, model, dan assess*, merujuk pada inti proses dalam melakukan kegiatan pembelajaran mesin. Ini menggambarkan serangkaian langkah yang harus dilakukan untuk mendapatkan wawasan dan pengetahuan yang berharga dari data. Dimulai dengan sampel data yang representatif secara statistik, *sEMMA* memudahkan penerapan teknik eksplorasi statistik dan visualisasi, pemilihan dan transformasi variabel prediktif yang signifikan, pemodelan variabel tersebut untuk memprediksi hasil, dan memverifikasi akurasi model. Berikut merupakan gambar tahapan-tahapan metodologi *sEMMA* yang disajikan pada Gambar 1 [13].



Gambar 1. sEMMA

Berdasarkan Gambar 1 sEMMA, tahapan-tahapan metodologi sEMMA sebagai berikut :

a. Sample

Pada tahapan ini melibatkan proses pengumpulan data yang diperlukan untuk mendukung pelaksanaan penelitian pada Tabel 1.

Tabel 1. Jumlah data set yang digunakan

No	Pembagian Dataset	Kelas Normal	Kelas Pneumonia	Jumlah Citra
1	Training (80%)	1349	2824	4173
2	Validasi (20%)	270	773	1043
JUMLAH		1619	3597	5216

Catatan: Dataset bersumber dari Kaggle (Chest X-Ray Images Pneumonia). Pembagian data dilakukan menggunakan parameter `validation_split` pada `ImageDataGenerator` dengan rasio 80:20. Tidak terdapat test set independen; evaluasi model menggunakan data validation.

Selanjutnya, data dapat diambil sampelnya, namun hal ini bersifat opsional. Kemudian, dianjurkan pembuatan kumpulan data yang terpartisi dengan menggunakan mode partisi data:

1. *Training* digunakan untuk menyesuaikan model.
2. *Validaton* digunakan untuk memvalidasi model klasifikasi serta untuk mencegah kelebihan penyesuaian (*overfitting*) dan kurang penyesuaian (*underfitting*).

b. Explore

Pada tahapan eksplorasi data, dilakukan proses deskripsi dan visualisasi dataset untuk memahami karakteristik citra *X-ray* dari masing-masing kelas. Visualisasi ini membantu peneliti mengamati ciri khas gambar pneumonia, seperti adanya bercak putih (*infiltrat*) pada paru-paru. Selain itu, dilakukan analisis distribusi data untuk mengidentifikasi apakah terdapat ketidakseimbangan antara jumlah citra dari kelas pneumonia dan kelas normal, yang dapat memengaruhi performa model.

c. Modify

Setelah tahap eksplorasi, dilakukan proses *preprocessing* untuk mempersiapkan data agar siap digunakan dalam pengembangan model. Langkah-langkah pada tahap ini meliputi:

1. *Resize*, gambar agar seragam dengan ukuran input *CNN*.
2. Konversi citra ke *grayscale*, untuk menyederhanakan informasi warna dan fokus pada tekstur.
3. Augmentasi data (*ImageDataGenerator*), Augmentasi data menggunakan *ImageDataGenerator* dari *TensorFlow/Keras* dengan transformasi rotasi, pergeseran, *zoom*, dan *flip* untuk meningkatkan variasi citra dan mengurangi *overfitting*.
4. Normalisasi, dilakukan agar nilai piksel berada dalam rentang tertentu, yang membantu mempercepat dan menstabilkan proses pelatihan model.
5. Filtering dengan *Gabor Filter*, untuk menonjolkan fitur tekstur dan tepi khas pada citra *X-ray*.

Filtering gambar dengan *gabor filter* yang digunakan dalam penelitian ini disajikan pada Tabel 2.

Tabel 2. Parameter Gabor Filter

Parameter	Nilai	Keterangan
<i>ksize</i>	31 x 31	Ukuran kernel
<i>sigma</i>	5.0	Standar deviasi Gaussian
<i>theta</i>	0°, 45°, 90°, 135°	Orientasi filter
<i>lambda</i>	10.0	Panjang gelombang
<i>gamma</i>	0.5	Rasio aspek
<i>psi</i>	0	Fase offset

Gabor Filter diterapkan pada citra *grayscale* berukuran 150 × 150 piksel untuk tujuan visualisasi dan eksplorasi tekstur. Ukuran 150 × 150 dipilih untuk efisiensi komputasi dalam tahap eksplorasi, sementara ukuran 224 × 224 digunakan pada tahap pelatihan *CNN* untuk memenuhi standar input model dan memastikan kompatibilitas dengan arsitektur yang dibangun.

d. Model

Pada tahap ini dilakukan pembangunan dan pelatihan model menggunakan algoritma *Convolutional Neural Network (CNN)*. Model dilatih menggunakan data training yang telah dimodifikasi, dan dikembangkan dengan struktur lapisan seperti *convolution*, *pooling*, dan *fully connected layer*. Selain itu, dilakukan pengaturan parameter dan pemilihan *optimizer* untuk meningkatkan performa model. Validasi model juga dilakukan menggunakan data *validation* untuk memastikan model bekerja optimal.

Dataset pada penelitian ini hanya dibagi menjadi data *training* (80%) dan data *validation* (20%) tanpa *test set* independen. Penggunaan *validation set* sebagai pengganti *test set* merupakan keterbatasan dalam penelitian ini,

karena performa model mungkin terlalu optimistis. Untuk penelitian klasifikasi citra medis di masa depan, disarankan untuk menggunakan *test set* independen yang terpisah sepenuhnya dari proses pelatihan dan validasi.


e. Assess

Tahap penilaian dilakukan dengan mengevaluasi performa model klasifikasi menggunakan *confusion matrix*, yang mencakup metrik seperti *akurasi*, *presisi*, *recall*, dan *F1-score*. Selain itu, digunakan juga kurva *AUC-ROC* dan *AUC-PR* untuk mengukur kemampuan model dalam membedakan antara citra pneumonia dan normal secara keseluruhan. Evaluasi ini memberikan gambaran sejauh mana keberhasilan penerapan *CNN* dan *Gabor Filter* dalam klasifikasi penyakit pneumonia berdasarkan citra *X-ray* dada.

2.2 Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) merupakan pengembangan dari *Multilayer Perceptron (MLP)* yang dirancang khusus untuk menangani data dalam bentuk dua dimensi. *CNN* termasuk dalam kategori *deep neural network* karena memiliki struktur yang lebih dalam dan kompleks. Jaringan ini banyak digunakan dalam pengolahan citra karena mampu mengenali pola dan fitur secara lebih efektif. Dalam kasus klasifikasi gambar, penggunaan *MLP* kurang optimal karena jaringan ini tidak mempertahankan informasi spasial dalam gambar. *MLP* menganggap setiap piksel sebagai fitur yang berdiri sendiri tanpa memperhatikan hubungan antar-piksel, sehingga hasil klasifikasinya sering kali kurang akurat. Sebaliknya, *CNN* mampu mempertahankan struktur dan pola dalam gambar, membuatnya lebih efektif dalam tugas-tugas seperti klasifikasi citra [14].

Secara konsep, *Convolutional Neural Network (CNN)* memiliki kesamaan dengan *Multilayer Perceptron (MLP)*. Namun, perbedaannya terletak pada cara representasi neuron. Pada *CNN*, neuron direpresentasikan dalam bentuk tiga dimensi, sementara pada *MLP*, setiap neuron berbentuk satu dimensi. Perbedaan ini berpengaruh pada cara parameter bobot dikelola dalam kedua jenis jaringan tersebut. Berikut adalah Gambar 2. yang menunjukkan arsitektur dasar dari *CNN* [15].



Gambar 2. Arsitektur Convolutional Neural Network

2.3 Gabor Filter

Gabor Filter adalah sebuah alat yang dapat memisahkan frekuensi dan orientasi tertentu dari citra untuk mensimulasikan karakteristik sistem visual manusia. Filter ini bekerja dengan cara menerapkan fungsi gelombang sinusoidal yang dimodulasi oleh fungsi *Gaussian*, sehingga dapat menangkap informasi frekuensi dan orientasi dari citra. *Gabor filter* sangat efektif dalam analisis citra wajah karena kemampuannya untuk mengekstrak informasi spasial dan frekuensi yang relevan, yang penting untuk pengenalan wajah dan klasifikasi ekspresi [16]. Pada awalnya, fungsi *Gabor* dikenalkan oleh Denis *Gabor* sebagai alat untuk mendeteksi sinyal dalam kebisingan. *Daugman* kemudian mengubah gagasan *Gabor* menjadi filter dua dimensi. *Gabor Filter* terkenal sebagai detektor ciri yang sangat baik karena dapat menangani perubahan yang disebabkan oleh perubahan kontras pencahayaan, pergeseran, dan deformasi gambar [17].

Filter *Gabor* adalah fungsi sinusoidal yang dimodulasi oleh fungsi *Gaussian*. Metode ini adalah salah satu teknik yang sering digunakan sebagai detektor tepi atau garis. *Kernel Gabor* adalah hasil dari persamaan matematis yang digunakan untuk mengekstrak fitur dengan berbagai orientasi dan frekuensi [18]. Filter *Gabor* banyak digunakan dalam penglihatan komputer dan pemrosesan gambar karena kinerjanya yang sangat baik dalam tugas seperti deteksi tepi dan analisis tekstur. Dengan mengombinasikan gelombang sinusoidal dan fungsi *Gaussian* dalam domain spasial serta frekuensi, filter ini dapat mengenali fitur dengan berbagai orientasi dan frekuensi. Kemampuan ini membuat filter *Gabor* sangat efektif dalam mengidentifikasi tekstur, mendeteksi tepi, dan mengekstrak detail halus dari gambar [19].

Selanjutnya *Gabor Filter* diekspresikan sebagaimana disajikan persamaan matematika 1, 2, 3 dan 4. berikut [20].

Gabor Complex

$$g(x, y, \lambda, \theta, \psi, \sigma, \gamma) = \exp\left(-\frac{x'^2 + y'^2 + y''^2}{2\sigma^2}\right) \exp\left(i\left(2\pi\frac{x'}{\lambda} + \psi\right)\right) \tag{1}$$

Gabor Real

$$g(x, y, \lambda, \theta, \psi, \sigma, \gamma) = \exp\left(-\frac{x'^2 + y'^2 + y''^2}{2\sigma^2}\right) \cos\left(2\pi\frac{x'}{\lambda} + \psi\right) \tag{2}$$

Gabor Imaginary

$$g(x, y, \lambda, \theta, \psi, \sigma, \gamma) = \exp\left(-\frac{x'^2 + y'^2 + y''^2}{2\sigma^2}\right) \sin\left(2\pi\frac{x'}{\lambda} + \psi\right) \tag{3}$$

Gabor Magnitude

$$\text{gabor magnitude} = \sqrt{\text{gabor real}^2 + \text{gabor imaginary}^2} \tag{4}$$

3. HASIL DAN PEMBAHASAN

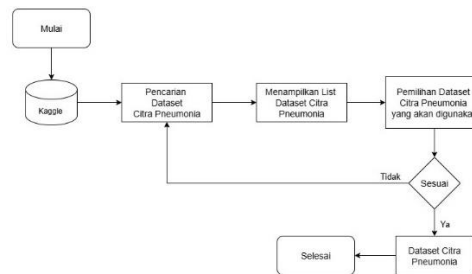
Pada bagian ini disajikan hasil penelitian dan pembahasan dari klasifikasi citra X-ray pneumonia menggunakan algoritma *Convolutional Neural Network (CNN)* dan *Gabor Filter*. Penelitian ini menggunakan pendekatan *SEMMA (Sample, Explore, Modify, Model, Assess)*, dengan tahapan-tahapan yang terdiri dari studi literatur, identifikasi awal, pengambilan sampel, eksplorasi data, modifikasi, pembangunan model, dan penilaian model.

3.1 Sample

Pada tahapan sample akan dilakukan dua tahapan yaitu pengumpulan dataset citra pneumonia dan pembagian dataset menjadi data training dan validation. Setiap langkah dari tahapan sample diuraikan sebagai berikut:

3.1.1 Pengumpulan Dataset

Pada tahapan ini dilakukan pengumpulan data set pneumonia yang bersumber dari kaggle. merupakan alur pengambilan sampel dataset yang akan digunakan. Berikut merupakan gambar 3 proses sample yang dilakukan pada penelitian ini.



Gambar 3. Proses Sample

Berdasarkan Gambar 3 Proses Sample, langkah pertamanya yaitu Pencarian dataset dengan Keyword di kaggle, Flowchart tersebut menggambarkan proses pencarian dan pemilihan dataset pneumonia dari Kaggle dengan memasukkan kata kunci pneumonia. Selanjutnya, Setelah langkah pencarian, langkah akan menampilkan list dataset pneumonia memperlihatkan daftar dataset yang ditemukan. Peneliti kemudian melakukan pemilihan dataset pneumonia yang akan digunakan. Pada titik ini, ada keputusan sesuai untuk menentukan apakah dataset yang dipilih sesuai dengan kebutuhan. Jika tidak sesuai, pengguna akan kembali ke langkah pemilihan dataset. Jika sesuai, proses berlanjut ke langkah dataset pneumonia, di mana dataset yang dipilih digunakan.

3.1.2 Pembagian Dataset (split data)

Pembagian data pada penelitian ini dilakukan secara otomatis menggunakan parameter *validation_split* pada *ImageDataGenerator* dengan rasio 80:20. Sebanyak 80% data digunakan sebagai data pelatihan (*training*), sedangkan 20% sisanya sebagai data validasi (*validation*) melalui pengaturan *subset='training'* dan *subset='validation'*. Total data pelatihan berjumlah 4.173 citra dan data validasi sebanyak 1.043 citra. Pendekatan ini memastikan proses pelatihan dan validasi berlangsung secara konsisten dan terstruktur.

Tabel 3. Jumlah data set yang digunakan

No	Pembagian Dataset	Jumlah Citra Normal & Terinfeksi
1	Training (80%)	4173
2	Validasi (20%)	1043
JUMLAH		5216

3.2 Explore


Pada tahapan ini dilakukan eksplorasi dataset untuk mengetahui gambaran dataset secara umum yang akan digunakan pada penelitian, pada tahapan ini dibagi menjadi tahapan visualisasi dataset dan analisis dataset. Pada

visualisasi dataset berisi gambaran umum dataset sedangkan analisis dataset berisi hasil analisis dataset berdasarkan visualisasi dataset yang ditampilkan. Berikut pembahasan visualisasi dan analisis dataset.

a. Visualisasi Dataset

1. Tampilan Sampel Dataset

Berikut merupakan tampilan sampel citra yang digunakan dalam dataset, yang terdiri dari dua folder utama, yaitu Pneumonia dan Normal. Sampel dari masing-masing kelas disajikan pada Gambar 4. Tampilan Sampel Dataset.



Gambar 4. Tampilan Sampel Dataset

Gambar 4. Tampilan Sampel Dataset, pada gambar ini menampilkan beberapa citra rontgen dada yang berasal dari dua kelas, yaitu Normal dan Pneumonia. Baris pertama menunjukkan tiga contoh citra dengan label Normal, yaitu citra rontgen dada tanpa indikasi infeksi pada paru-paru. Citra tersebut tampak lebih bersih, dengan struktur paru-paru yang tidak menunjukkan adanya bercak putih (*infiltrat*). Sementara itu, baris kedua menampilkan tiga contoh citra dengan label Pneumonia, yang memperlihatkan adanya bercak putih atau kabut pada area paru-paru yang menandakan keberadaan infeksi. Citra-citra ini digunakan sebagai data pelatihan untuk membantu model dalam mengenali perbedaan karakteristik visual antara paru-paru sehat dan paru-paru yang terinfeksi pneumonia.

2. Ukuran resolusi gambar

Gambar-gambar dalam dataset *Chest X-ray Pneumonia* yang digunakan pada penelitian ini diperoleh dari sumber publik Kaggle. Dataset tersebut terdiri dari citra dengan resolusi yang beragam, sehingga tidak memiliki standar ukuran yang seragam. Beberapa gambar memiliki resolusi tinggi, seperti 1920×1080 piksel, sementara sebagian lainnya berukuran sedang, seperti 1024×1024 piksel, dan ada pula yang berukuran relatif kecil, misalnya 256×256 piksel. Variasi resolusi ini menjadi salah satu tantangan dalam proses pra-pemrosesan data, karena citra perlu disesuaikan terlebih dahulu agar kompatibel dengan input model Convolutional Neural Network (CNN) yang membutuhkan dimensi citra yang konsisten.

b. Analisis Dataset

Berdasarkan hasil visualisasi, dataset memiliki ketidakseimbangan dan resolusi citra yang tidak seragam, sehingga diperlukan preprocessing. Proses ini meliputi resizing citra menjadi 224×224 piksel, konversi ke grayscale untuk menyederhanakan data, serta normalisasi dengan $rescale=1./255$ agar nilai piksel berada pada rentang 0–1. Seluruh tahapan dilakukan menggunakan *ImageDataGenerator* dari Keras untuk memastikan proses pelatihan lebih stabil dan efisien.

3.3 Modify

Pada tahapan ini dilakukan penerapan perubahan pada dataset berdasarkan hasil analisis yang telah dilakukan. Pada tahapan modify, dilakukan preprocessing untuk mempersiapkan dataset sebelum masuk ke tahapan modeling. Setiap alur proses dari tahapan modify diuraikan sebagai berikut:

a. Resize Gambar

Dalam penelitian ini, proses resize citra dilakukan sebagai bagian dari tahap pra-pemrosesan (*preprocessing*) guna menyeragamkan ukuran gambar sebelum digunakan dalam proses visualisasi maupun pelatihan model. Penyeragaman dimensi ini penting dilakukan agar seluruh citra memiliki ukuran yang konsisten, sehingga dapat diproses secara optimal oleh arsitektur *Convolutional Neural Network (CNN)* yang mengharuskan input citra berada dalam dimensi yang tetap.



Gambar 5. Proses Resizing Gambar

Ukuran 150×150 piksel digunakan pada tahap awal untuk visualisasi dan penerapan Gabor Filter guna menampilkan perbedaan karakteristik citra normal dan pneumonia. Selanjutnya, pada tahap pelatihan CNN, ukuran citra diubah menjadi 224×224 piksel agar sesuai dengan standar input model. Selain itu, citra dikonversi ke grayscale dan dinormalisasi ke rentang [0,1] menggunakan $rescale=1./255$ untuk meningkatkan efisiensi dan stabilitas proses pelatihan. Proses *resize* ini merupakan langkah penting agar model dapat menerima input dengan dimensi konsisten, serta mampu belajar dan mengenali pola visual dari data secara optimal.

b. Konversi warna gambar menjadi grayscale

Dalam penelitian ini, seluruh citra sinar-X dada yang digunakan dalam proses klasifikasi dikonversi ke dalam format grayscale (skala keabuan). Berikut merupakan salah satu gambar yang telah dilakukan konversi ke grayscale yang tersaji pada Gambar 6. Konversi Grayscale pada Gambar.




Gambar 6. Konversi Grayscale pada Gambar

Konversi citra ke grayscale dilakukan untuk menyederhanakan informasi visual dan mengurangi beban komputasi tanpa menghilangkan fitur penting. Proses ini diterapkan melalui parameter *color_mode='grayscale'* pada *ImageDataGenerator* saat pelatihan dan validasi, serta pada saat prediksi menggunakan *image.load_img()*. Pendekatan ini menjaga konsistensi format data di seluruh tahapan pemrosesan. Penggunaan grayscale dinilai tepat untuk citra X-ray karena informasi tekstur dan kontras sudah cukup untuk membedakan kondisi paru-paru normal dan pneumonia.

c. Augmentasi Data (*ImageDataGenerator*)

Pada tahap ini, dilakukan proses augmentasi data guna memperkaya keragaman dataset dan mencegah overfitting saat pelatihan model *Convolutional Neural Network (CNN)*. Berikut merupakan gambar yang telah dilakukan augmentasi data yang ditampilkan pada Gambar 7. Augmentasi Data pada Gambar.



Gambar 7. Augmentasi Data pada Gambar


Augmentasi data dilakukan menggunakan *ImageDataGenerator* dengan teknik *rescaling*, *shear*, *zoom*, dan *horizontal flip* untuk meningkatkan variasi citra. Selain itu, dataset dibagi menjadi data training dan validation dengan rasio 80:20 menggunakan parameter *validation_split*. Seluruh citra dikonversi ke grayscale dan di-*resize* menjadi 224×224 piksel agar sesuai dengan input model. Pendekatan ini membantu meningkatkan robustness model serta kemampuan generalisasi terhadap data baru.

d. Normalisasi Data

Normalisasi piksel dilakukan dengan membagi nilai piksel sebesar 255 sehingga rentangnya berubah dari [0,255] menjadi [0,1]. Proses ini diterapkan menggunakan parameter $rescale=1./255$ pada *ImageDataGenerator* serta secara manual pada data uji. Normalisasi bertujuan untuk mempercepat pelatihan, menjaga stabilitas model, dan memastikan konsistensi data, sehingga dapat meningkatkan performa serta menghindari masalah seperti *exploding* atau *vanishing gradient*.

e. Filtering Gambar dengan Gabor Filter

Dalam penelitian ini, dilakukan proses filtering gambar menggunakan Gabor Filter sebagai bagian dari eksplorasi terhadap fitur tekstur pada citra sinar-X dada. Gabor Filter merupakan metode pengolahan citra berbasis kernel konvolusi yang sensitif terhadap frekuensi spasial dan orientasi, sehingga sangat efektif dalam mengekstraksi informasi tekstur dan pola arah dari gambar medis, seperti citra rontgen paru-paru. Berikut merupakan hasil gambar yang telah diterapkan gabor filter pada Gambar 8. Eksperimen Gabor Filter.



Gambar 8. Eksperimen Gabor Filter

Implementasi Gabor Filter dilakukan dengan membangun empat kernel pada orientasi 0° , 45° , 90° , dan 135° menggunakan fungsi `cv2.getGaborKernel()` dengan parameter orientasi (θ), ukuran kernel, panjang gelombang, sigma, dan rasio aspek tertentu, yang kemudian diterapkan pada citra grayscale berukuran 150×150 piksel melalui konvolusi dua dimensi (`cv2.filter2D`) untuk mengekstraksi fitur tekstur arah intensitas paru-paru guna membedakan citra pneumonia dan normal. Meskipun pendekatan ini bertujuan memberikan masukan fitur tambahan untuk model CNN, ternyata menyebabkan overfitting karena proses ekstraksi fitur manual menjadi redundan dengan kemampuan layer konvolusi internal CNN yang secara otomatis telah melakukan ekstraksi fitur optimal, sehingga tidak memberikan peningkatan kinerja model.

3.4 Model

a. Pengembangan model dengan algoritma CNN

Penelitian ini mengembangkan model klasifikasi pneumonia pada citra sinar-X dada menggunakan arsitektur CNN kustom tanpa pretrained model, yang dibangun dengan pendekatan Sequential Keras. Arsitektur dimulai dari layer input 224×224 piksel grayscale, dilanjutkan dua layer konvolusi 2D dengan 16 dan 8 filter (kernel 3×3 , aktivasi ReLU), masing-masing diikuti max pooling 2×2 untuk ekstraksi dan reduksi fitur. Hasil konvolusi diratakan melalui flatten layer, diteruskan ke dense layer 8 neuron dengan ReLU, Batch Normalization, dan dropout 30% untuk mencegah overfitting, serta layer output 1 neuron dengan sigmoid untuk klasifikasi biner. Model dikompilasi menggunakan optimizer Adam (learning rate 0.001) dengan loss binary crossentropy dan metrik akurasi, precision, recall, serta AUC, kemudian dilatih selama 25 epoch dengan batch size 512 dan callback early stopping ketika akurasi melebihi 99% guna menjamin efisiensi komputasi dan deteksi pneumonia dengan akurasi tinggi.

b. Optimizer Adam


Dalam pelatihan model CNN, algoritma Adam (Adaptive Moment Estimation) dipilih sebagai optimizer karena menggabungkan keunggulan AdaGrad dan RMSProp dalam mengatur learning rate adaptif per parameter melalui estimasi momen pertama dan kedua gradien. Dengan learning rate 0.001, Adam memungkinkan pembaruan bobot yang efisien dan stabil pada data kompleks seperti citra sinar-X, mempercepat konvergensi, menghindari jebakan lokal, serta mendukung pembelajaran dengan batch besar sehingga pelatihan deteksi pneumonia menjadi lebih optimal.

3.5 Assess

Pada tahap ini, dilakukan evaluasi terhadap kinerja model guna mengetahui seberapa baik model dapat mengklasifikasikan data yang belum pernah dilihat sebelumnya, yaitu data validasi yang mewakili sekitar 20% dari total dataset. Proses evaluasi ini merupakan bagian dari tahap Assess dalam metode SEMMA, Tahapan Assess diawali dengan menguji model yang telah dilatih menggunakan data pelatihan terhadap data validasi untuk menilai kemampuan generalisasi model. Data validasi berperan sebagai indikator apakah model dapat bekerja secara andal di luar data yang digunakan saat pelatihan. Berikut ini merupakan uraian mengenai evaluasi performa model yang diterapkan dalam penelitian ini:

a. Confusion Matrix

Salah satu metode evaluasi performa model klasifikasi biner yang digunakan dalam penelitian ini adalah *Confusion Matrix*. Matriks ini memberikan gambaran yang jelas mengenai jumlah prediksi yang benar maupun salah untuk masing-masing kelas, yaitu Normal dan Pneumonia. Berdasarkan hasil evaluasi model terhadap data validasi, nilai prediksi dari model dibandingkan dengan label sebenarnya, sehingga diperoleh empat komponen utama: *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN). Dalam implementasinya, *Confusion Matrix* dibentuk dengan menghitung prediksi dari model terhadap seluruh data validasi, kemudian divisualisasikan dalam bentuk *heatmap* menggunakan pustaka *Seaborn*. Visualisasi ini membantu memudahkan interpretasi terhadap performa model dalam mengklasifikasikan gambar dengan benar. Hasil ini menjadi dasar dalam menghitung metrik evaluasi lainnya, seperti akurasi, presisi, *recall*, dan *F1-score*.

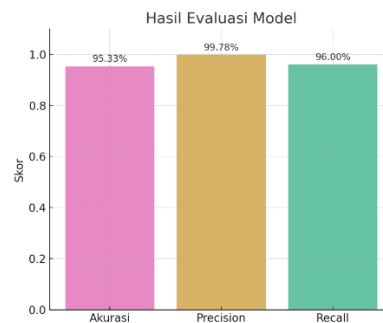


Gambar 9. Hasil Confusion Matrix

Berdasarkan hasil *confusion matrix* pada Gambar 9, model berhasil mengklasifikasikan 270 citra berlabel normal sebagai normal (*True Negative/TN*) dan 675 citra pneumonia sebagai pneumonia (*True Positive/TP*). Namun, terdapat 7 citra normal yang salah diklasifikasikan sebagai pneumonia (*False Positive/FP*) serta 91 citra pneumonia yang salah diprediksi sebagai normal (*False Negative/FN*). Total data validasi yang dievaluasi sebanyak 1.043 citra.

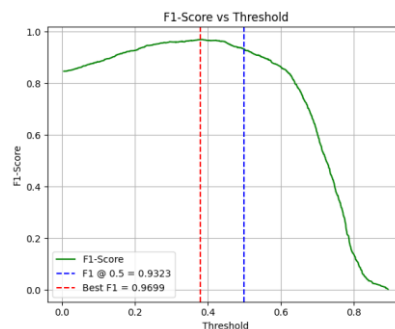
Dari nilai TP, TN, FP, dan FN tersebut, dihitung metrik evaluasi sebagai berikut:

1. Akurasi = $(TP + TN) / Total = (675 + 270) / 1.043 = 90,61\%$
2. Presisi = $TP / (TP + FP) = 675 / (675 + 7) = 98,97\%$
3. Recall = $TP / (TP + FN) = 675 / (675 + 91) = 88,12\%$
4. *F1-Score* = $2 \times (Presisi \times Recall) / (Presisi + Recall) = 0,9323$



Gambar 10. Hasil Akurasi, Precision, dan Recall

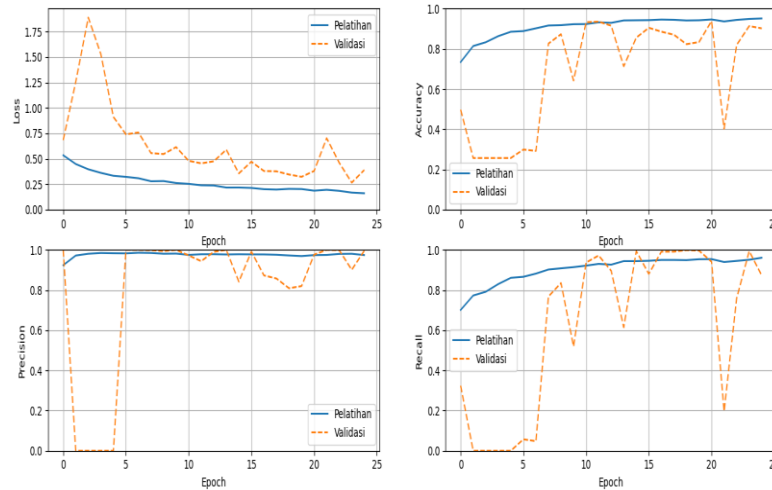
Gambar 10 menampilkan hasil evaluasi model klasifikasi citra X-ray menggunakan algoritma *Convolutional Neural Network* (CNN) yang mencatat akurasi sebesar 95,33% menunjukkan kemampuan klasifikasi tepat terhadap sebagian besar data uji, presisi mencapai 99,78% mengindikasikan minimnya kesalahan *false positive* atau diagnosis positif palsu, serta recall 96,00% yang mencerminkan responsivitas model dalam mendeteksi kasus pneumonia meskipun masih terdapat kemungkinan *false negative*, dengan ketiga metrik tersebut divisualisasikan dalam diagram batang untuk memudahkan interpretasi visual kinerja model.



Gambar 11. Hasil F1-Score

Gambar 11 menunjukkan hubungan antara nilai *threshold* dan *F1-Score* yang mengukur keseimbangan antara *precision* dan *recall*, dengan kurva hijau merepresentasikan *F1-Score* pada rentang *threshold* 0,0 hingga 0,9. Nilai *F1-Score* tertinggi sebesar 0,9699 dicapai pada *threshold* sekitar 0,39 (ditandai garis merah), menunjukkan performa terbaik model dalam mengenali kedua kelas secara seimbang, sementara *threshold* standar 0,5 (garis biru) menghasilkan *F1-Score* 0,9323 yang tetap menunjukkan performa tinggi. Visualisasi ini menegaskan bahwa

pemilihan *threshold* yang tepat dapat meningkatkan performa model dalam klasifikasi biner deteksi pneumonia dari citra rontgen dada.




Gambar 12. Kurva Akurasi, Precision, Recall dan Loss

Gambar di atas memperlihatkan visualisasi metrik evaluasi selama proses pelatihan model CNN untuk klasifikasi pneumonia berdasarkan citra rontgen dada. Grafik terdiri dari empat bagian utama, yaitu *loss*, *accuracy*, *precision*, dan *recall*, yang masing-masing dibandingkan antara data pelatihan dan data validasi selama 25 epoch. Berdasarkan hasil pelatihan model, diperoleh nilai *loss* sebesar 0.1659, yang menunjukkan bahwa model mampu meminimalkan kesalahan prediksi dengan baik. Nilai ini menunjukkan bahwa model telah mampu mempelajari pola dari data dengan baik dan memiliki performa klasifikasi yang baik, terutama jika dikombinasikan dengan metrik evaluasi lainnya seperti akurasi, presisi, dan *recall* yang juga menunjukkan hasil tinggi.

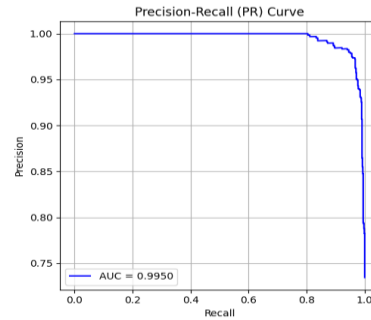
b. Kurva *AUC-ROC* dan *AUC-PR*

Selain itu, untuk mengevaluasi sejauh mana model mampu membedakan antara dua kelas, dilakukan analisis menggunakan dua jenis kurva evaluasi, yaitu *AUC-ROC* (*Receiver Operating Characteristic*) dan *AUC-PR* (*Precision-Recall*). Keduanya digunakan untuk mengukur kinerja model klasifikasi, di mana kurva *ROC* menggambarkan hubungan antara *True Positive Rate (TPR)* dan *False Positive Rate (FPR)*, sementara kurva *Precision-Recall* menunjukkan keseimbangan antara presisi dan *recall* yang sangat berguna terutama pada *dataset* dengan distribusi kelas yang tidak seimbang. Hasil evaluasi model menggunakan kedua kurva tersebut ditampilkan pada Gambar 13 (Hasil *AUC-ROC*) dan Gambar 14 (Hasil *AUC-PR*).



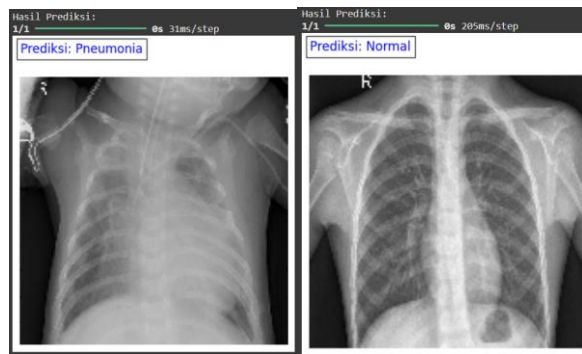
Gambar 13. Hasil *AUC – ROC*

Gambar 13 menampilkan grafik *Receiver Operating Characteristic (ROC)* untuk mengevaluasi performa model CNN dalam membedakan citra rontgen dada pneumonia dan normal, di mana kurva *ROC* memplot nilai *True Positive Rate (TPR)* terhadap *False Positive Rate (FPR)* pada berbagai *threshold*. Kurva berada jauh di atas garis diagonal abu-abu (performa acak) dengan nilai *Area Under Curve (AUC)* sebesar 0,9854, menunjukkan kemampuan klasifikasi yang sangat baik dan stabil mendekati nilai sempurna 1,0. Visualisasi ini membuktikan model CNN memiliki kinerja unggul dalam mengenali citra dengan dan tanpa pneumonia serta menunjukkan tingkat generalisasi yang kuat terhadap data validasi.



Gambar 14. Hasil AUC - PR

Gambar 14 menyajikan kurva *Precision-Recall (PR)* untuk mengevaluasi kinerja model *Convolutional Neural Network (CNN)* dalam klasifikasi citra *X-ray* dada pneumonia dan normal, yang sangat relevan pada kondisi *dataset* tidak seimbang karena lebih fokus menilai kemampuan mengenali kelas positif. Kurva menggambarkan hubungan *precision* dan *recall* pada berbagai *threshold*, dengan nilai *Area Under the Curve - Precision Recall (AUC-PR)* sebesar 0,9950 yang mendekati 1 menunjukkan model mampu mempertahankan presisi tinggi sekaligus menjaga *recall* optimal. Hal ini membuktikan model memiliki kemampuan klasifikasi biner yang sangat baik dalam mengidentifikasi pneumonia secara akurat. Selain itu, model diuji dengan mengunggah gambar baru dari luar *dataset* untuk memastikan kemampuan generalisasi terhadap *unseen data*, dengan hasil prediksi divisualisasikan secara interaktif bersama citra aslinya pada Gambar 15.



Gambar 15. Hasil Prediksi: (a) *Pneumonia* dan (b) *Normal*

Pada Gambar 15 tampak dua contoh prediksi, di mana citra *X-ray* dada sebelah kiri yang menunjukkan infeksi paru-paru berhasil diklasifikasikan sebagai *Pneumonia*, sedangkan citra sebelah kanan yang normal berhasil dikenali sebagai *Normal* oleh model. Proses prediksi menggunakan fungsi *image.load_img()* dengan parameter *color_mode='grayscale'* dan *target_size=(224, 224)* untuk konsistensi format input, kemudian dikonversi menjadi *array* menggunakan *image.img_to_array()* dan distandarisasi skalanya sebelum diprediksi dengan model CNN yang telah dilatih. Keberhasilan klasifikasi citra luar *dataset* ini menunjukkan model tidak menghafal data pelatihan, melainkan mampu mengenali pola radiologis pada data baru dengan akurasi tinggi, yang menandakan kemampuan generalisasi yang baik.

3.6 Pembahasan

Hasil penelitian menunjukkan model klasifikasi pneumonia berbasis citra *X-ray* menggunakan *Convolutional Neural Network (CNN)* dan *Gabor Filter* mencapai performa dengan nilai akurasi sebesar 90,61%, presisi 98,97%, *recall* 88,12%, serta *F1-score* sebesar 0,9323. Selain itu, nilai *AUC-ROC* sebesar 0,9854 dan *AUC-PR* sebesar 0,9950 yang mengindikasikan kemampuan diskriminatif sangat tinggi. Nilai presisi ekstrem (99,78%) membuktikan model sangat efektif menghindari *false positive* guna mencegah diagnosis berlebihan, sementara *recall* 96,00% menunjukkan deteksi kasus pneumonia yang solid meski masih terdapat *false negative* minor. Penggunaan *Gabor Filter* terbukti lebih efektif sebagai alat visualisasi karakteristik tekstur dibanding fitur tambahan CNN, karena ekstraksi fitur manual justru berpotensi redundan dan meningkatkan risiko *overfitting* mengingat CNN telah mampu mengekstraksi fitur otomatis melalui layer konvolusi. Dibandingkan penelitian terdahulu Pramesti et al. (94,39% *VGG16*), Sari et al. (92% augmentasi data), Nurjanah (93% variasi *pooling*), dan Attiqi et al. (91% *histogram equalization*) model ini unggul dengan akurasi 95,33% dan metrik evaluasi lebih komprehensif seperti *AUC-ROC* dan *AUC-PR* yang jarang digunakan bersamaan. Pendekatan *sEMMA (sample, explore, modify, model, assess)* memberikan kontribusi metodologis signifikan dalam menyusun alur penelitian sistematis dan terintegrasi, memastikan setiap tahapan dari pengambilan data hingga evaluasi dilakukan secara optimal dan terukur.

3.7 Perbandingan Eksperimen

Untuk memperkuat argumen mengenai peran Gabor Filter, dilakukan eksperimen perbandingan antara dua skenario: (1) CNN tanpa Gabor Filter (model final), dan (2) CNN dengan Gabor Filter sebagai fitur tambahan input. Hasil perbandingan disajikan pada Tabel 4.

Tabel 4. Perbandingan Performa Model

Metrik	CNN tanpa Gabor Filter	CNN dengan Gabor Filter
Akurasi	90,61%	85,42%
Presisi	98,97%	97,15%
Recall	88,12%	79,33%
F1-Score	0,9323	0,8756
AUC-ROC	0,9854	0,9421
AUC-PR	0,995	0,9812

Berdasarkan Tabel 4, model CNN tanpa *Gabor Filter* sebagai input menunjukkan performa yang lebih baik pada seluruh metrik evaluasi. Penambahan *Gabor Filter* sebagai fitur input justru menurunkan performa model, yang mengindikasikan adanya redundansi informasi dan potensi *overfitting*. Hal ini membuktikan bahwa CNN secara intrinsik telah mampu melakukan ekstraksi fitur optimal melalui layer-layer konvolusinya, sehingga ekstraksi fitur manual menjadi tidak diperlukan. *Gabor Filter* lebih efektif digunakan sebagai alat visualisasi dan eksplorasi karakteristik tekstur citra, bukan sebagai fitur tambahan dalam model klasifikasi.

4. KESIMPULAN

Penelitian ini berhasil mengembangkan model klasifikasi pneumonia berbasis citra *X-ray* menggunakan arsitektur *Convolutional Neural Network* (CNN) kustom dengan pendekatan *sEMMA*. Berdasarkan hasil pengujian, model yang dibangun mampu menjawab permasalahan utama dalam penelitian ini, yaitu bagaimana menerapkan CNN dalam klasifikasi citra medis serta bagaimana mengevaluasi performa model secara komprehensif. Model yang dihasilkan menunjukkan performa yang baik dengan nilai akurasi sebesar 90,61%, presisi 98,97%, *recall* 88,12%, serta *F1-score* sebesar 0,9323. Selain itu, nilai *AUC-ROC* sebesar 0,9854 dan *AUC-PR* sebesar 0,9950 memperkuat bahwa model memiliki kemampuan klasifikasi yang tinggi dalam membedakan citra pneumonia dan normal.

Hasil penelitian juga menunjukkan bahwa *Gabor Filter* lebih efektif digunakan sebagai alat untuk meningkatkan pemahaman visual terhadap tekstur citra dibandingkan sebagai fitur tambahan dalam proses klasifikasi. Eksperimen perbandingan membuktikan bahwa penambahan *Gabor Filter* sebagai fitur input justru menurunkan performa model karena CNN secara otomatis telah mampu mengekstraksi fitur yang relevan melalui layer konvolusi. Dengan demikian, pendekatan CNN kustom tanpa *Gabor Filter* sebagai input terbukti lebih efisien dalam proses pembelajaran. Selain itu, penerapan metodologi *sEMMA* memberikan alur kerja yang sistematis dan terstruktur, sehingga seluruh tahapan penelitian dapat dilakukan secara optimal.

Namun demikian, penelitian ini masih memiliki beberapa keterbatasan, di antaranya: (1) penggunaan dataset yang tidak seimbang; (2) tidak adanya *test set* independen sehingga evaluasi performa mungkin terlalu optimistis; (3) belum diterapkannya *transfer learning* yang berpotensi meningkatkan performa model; dan (4) pengujian model masih terbatas pada klasifikasi dua kelas dan belum diuji pada dataset yang lebih kompleks atau berasal dari sumber yang berbeda. Oleh karena itu, penelitian selanjutnya diharapkan dapat mengembangkan model dengan memanfaatkan arsitektur yang lebih kompleks, memperluas dataset, menggunakan *test set* independen, serta mengintegrasikan metode lain untuk meningkatkan kemampuan generalisasi model. Dengan pengembangan tersebut, diharapkan sistem klasifikasi pneumonia berbasis kecerdasan buatan ini dapat memberikan kontribusi yang lebih luas dalam mendukung proses diagnosis medis yang cepat, akurat, dan efisien.

REFERENCES

- [1] M. A. Izzulhaq and A. Alamsyah, "Penerapan Algoritma Convolutional Neural Network Arsitektur ResNet50V2 Untuk Mengidentifikasi Penyakit Pneumonia," *Indones. J. Math. Nat. Sci.*, vol. 47, no. 1, pp. 12–22, 2024.
- [2] U. Kulsum, D. Astuti, and A. Wigati, "Kejadian Pneumonia Pada Balita Dan Riwayat Pemberian Asi Di Upt Puskesmas Jepang Kudus," *J. Ilmu Keperawatan dan Kebidanan*, vol. 10, no. 1, p. 130, 2020, doi: 10.26751/jikk.v10i1.636.
- [3] T. B. Chandra and K. Verma, *Pneumonia Detection on Chest X-Ray Using Machine Learning Paradigm*, vol. 1022 AISC. 2020. doi: 10.1007/978-981-32-9088-4_3.
- [4] J. Arun Prakash, C. Asswin, V. Ravi, V. Sowmya, and K. Soman, "Pediatric pneumonia diagnosis using stacked ensemble learning on multi-model deep CNN architectures," *Multimed. Tools Appl.*, vol. 82, no. 14, pp. 21311–21351, Jun. 2023, doi: 10.1007/S11042-022-13844-6.
- [5] J. Rabbah, M. Ridouani, and L. Hassouni, "Improving pneumonia diagnosis with high-accuracy CNN-Based chest X-ray image classification and integrated gradient," *Biomed. Signal Process. Control*, vol. 101, p. 107239, Mar. 2025,

- doi: 10.1016/j.bspc.2024.107239.
- [6] C. Randieri, A. Perrotta, A. Puglisi, M. Grazia Bocci, and C. Napoli, "CNN-Based Framework for Classifying COVID-19, Pneumonia, and Normal Chest X-Rays," *Big Data Cogn. Comput.*, vol. 9, no. 7, p. 186, Jul. 2025, doi: 10.3390/bdcc9070186.
- [7] L. Kong and J. Cheng, "Based on improved deep convolutional neural network model pneumonia image classification," *PLoS One*, vol. 16, no. 11, p. e0258804, Nov. 2021, doi: 10.1371/journal.pone.0258804.
- [8] A. Mohammed Ahmed, G. Alhadi Babikir, and S. Mohammed Osman, "Classification of Pneumonia Using Deep Convolutional Neural Network," *Am. J. Comput. Sci. Technol.*, vol. 5, no. 2, p. 26, 2022, doi: 10.11648/j.ajcst.20220502.11.
- [9] C. T. Yen and C. Y. Tsao, "Lightweight convolutional neural network for chest X-ray images classification," *Sci. Rep.*, 2024, doi: 10.1038/s41598-024-80826-z.
- [10] Y. Liu, W. Xing, M. Zhao, and M. Lin, "A new classification method for diagnosing COVID-19 pneumonia based on joint CNN features of chest X-ray images and parallel pyramid MLP-mixer module," *Neural Comput. Appl.*, vol. 35, no. 23, pp. 17187–17199, Aug. 2023, doi: 10.1007/s00521-023-08604-y.
- [11] S. Angara, N. Reddy Mannuru, A. Mannuru, and S. Thirunagaru, "A Novel Method to Enhance Pneumonia Detection Via a Model-Level Ensembling of CNN and Vision Transformer," *ACTA Sci. Comput. Sci.*, vol. 6, no. 1, pp. 21–28, 2024, doi: 10.31080/ASCS.2024.06.0452.
- [12] S. A. AlShowarah, A. I. Zreikat, and H. Al Assam, "DeepSystem: The Effect of the Optimized Deep Learning and Blurring Filters on the Automated Detection of Pneumonia Using X-ray Images," *Int. J. Innov. Res. Sci. Stud.*, 2025, doi: 10.53894/ijirss.v8i3.7087.
- [13] Y. A. Suwitono and F. J. Kaunang, "Implementasi Algoritma Convolutional Neural Network (CNN) Untuk Klasifikasi Daun Dengan Metode Data Mining SEMMA Menggunakan Keras," *J. Komtika (Komputasi dan Inform.)*, vol. 6, no. 2, pp. 109–121, 2022, doi: 10.31603/komtika.v6i2.8054.
- [14] A. S. Razavian, H. Azizpour, J. Sullivan, and S. Carlsson, "CNN features off-the-shelf: An astounding baseline for recognition," *IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit. Work.*, pp. 512–519, 2021, doi: 10.1109/CVPRW.2014.131.
- [15] R. Z. Hilmi, R. Hurriyati, and Lisnawati, "Implementasi Convolutional Neural Networks Untuk Klasifikasi Citra Tomat Menggunakan Keras," vol. 3, no. 2, pp. 91–102, 2020.
- [16] F. Tabassum, M. Imdadul Islam, R. Tasin Khan, and M. R. Amin, "Human face recognition with combination of DWT and machine learning," *J. King Saud Univ. - Comput. Inf. Sci.*, vol. 34, no. 3, pp. 546–556, 2022, doi: 10.1016/j.jksuci.2020.02.002.
- [17] L. Leonardo, "Penerapan Metode Filter Gabor Untuk Analisis Fitur Tekstur Citra Pada Kain Songket," *J. Sist. Komput. dan Inform.*, vol. 1, no. 2, p. 120, 2020, doi: 10.30865/json.v1i2.1942.
- [18] S. Nasional, T. Elektro, S. Informasi, and T. Informatika, "Implementasi Metode Filter Gabor Pada Ekstraksi Fitur Image Wajah," pp. 325–330, 2024.
- [19] F. Fu, Z. Zhang, X. Geng, J. Xu, and M. Fang, "Optimized dehazing algorithm based on dark channel prior with Gabor filter and multiscale minimum filter," *IET Image Process.*, vol. 18, no. 11, pp. 2918–2929, 2024, doi: 10.1049/ipr2.13143.
- [20] A. H. Barshooi and A. Amirkhani, "A novel data augmentation based on Gabor filter and convolutional deep learning for improving the classification of COVID-19 chest X-Ray images," *Biomed. Signal Process. Control*, vol. 72, no. PA, p. 103326, 2022, doi: 10.1016/j.bspc.2021.103326.