

Deteksi Pneumonia pada Citra Akhir X – Ray Dada Menggunakan Convolutional Neural Networks Berdasarkan Fitur Prewitt Operator

Raihan¹, Cecep Nurul Alam², Wildan Budiawan Zulfikar³

^{1,2,3}Teknik Informatika, UIN Sunan Gunung Djati Bandung, Indonesia
rans190802@gmail.com

Info Artikel

Sejarah artikel:

Diterima Mei 2025

Direvisi Juni 2025

Disetujui Juni 2025

Diterbitkan Juni 2025

ABSTRACT

Pneumonia is a lung infection that is a leading cause of death, especially in children and adults in developing countries. The diagnosis of pneumonia is usually made through physical examination and interpretation of chest X-rays, but the results can vary depending on the experience of the doctor, potentially leading to misdiagnosis. This study uses a convolutional neural network (CNN) to detect pneumonia in X-ray images, with additional feature processing methods, such as the Prewitt operator to handle class imbalance. The goal is to improve the accuracy of pneumonia detection so that it can assist medical personnel in decision making and reduce misdiagnosis. As a result, the developed model achieved an accuracy of 96.59% on training data with consistent improvement, demonstrating the potential of CNN in supporting pneumonia diagnosis more accurately and reliably.

Keywords : *Convolutional Neural Network; Medical Image Analysis; Pneumonia; Prewitt Operator; X-Ray Diagnosis.*

ABSTRAK

Pneumonia adalah penyakit infeksi paru-paru yang menjadi penyebab utama kematian, khususnya pada anak-anak dan orang dewasa di negara berkembang. Diagnosis pneumonia biasanya dilakukan melalui pemeriksaan fisik dan interpretasi rontgen dada, namun hasilnya dapat bervariasi tergantung pada pengalaman dokter, yang berpotensi menyebabkan kesalahan diagnosis. Penelitian ini menggunakan jaringan saraf konvolusi (CNN) untuk mendeteksi pneumonia pada gambar x-ray, dengan tambahan metode pengolahan fitur, seperti Prewitt Operator untuk menangani ketidakseimbangan kelas. Tujuannya adalah meningkatkan akurasi deteksi pneumonia sehingga dapat membantu tenaga medis dalam pengambilan keputusan dan mengurangi kesalahan diagnosis. Hasilnya, model yang dikembangkan mencapai akurasi 96.59% pada data pelatihan dengan peningkatan konsisten, menunjukkan potensi CNN dalam mendukung diagnosis pneumonia secara lebih akurat dan andal.

Kata Kunci : *Convolutional Neural Network; Medical Image Analysis; Pneumonia; Prewitt Operator; X-Ray Diagnosis.*

PENDAHULUAN

Pneumonia adalah infeksi paru-paru yang disebabkan oleh virus, bakteri, atau jamur. Penyakit ini merupakan penyebab utama kematian di seluruh dunia, baik pada anak-anak maupun orang dewasa. [1] Di Indonesia, pneumonia menempati urutan kedua sebagai penyebab kematian pada balita, setelah diare. [2]

Diagnosis pneumonia biasanya dilakukan melalui pemeriksaan fisik, *auskultasi* (mendengarkan suara paru-paru), dan pemeriksaan rontgen dada. [3]

Rontgen dada adalah metode *diagnosis* yang sering dipilih karena mudah diakses dan terjangkau, terutama di negara-negara berkembang. [4] Meskipun demikian, interpretasi hasil rontgen dada dapat berbeda-beda tergantung pada pengalaman dokter [5], yang dapat menyebabkan kesalahan *diagnosis*, khususnya pada kasus *pneumonia* ringan. [6] Hal ini menjadi tantangan besar dalam memastikan *diagnosis* yang akurat dan penanganan yang tepat. Untuk mengatasi tantangan tersebut, *Convolutional Neural Networks (CNN)* telah digunakan dalam berbagai aplikasi pengolahan gambar, termasuk untuk mendeteksi *pneumonia* pada gambar *x-ray* dada. [7] *CNN* dapat mempelajari pola-pola kompleks dalam citra dan menggunakan pola tersebut untuk klasifikasi, yang membantu dalam meningkatkan akurasi *diagnosis pneumonia*. Berbagai studi menunjukkan bahwa *CNN* dapat mencapai akurasi yang tinggi dalam mendeteksi *pneumonia* pada gambar *X-ray* dada. [8] [9] [10]


Selain itu, beberapa penelitian telah mengeksplorasi penggunaan teknik deteksi tepi dalam pengolahan citra untuk mendeteksi *pneumonia*. Salah satu contohnya adalah penggunaan algoritma deteksi tepi berbasis logika *fuzzy* dan modifikasi operator *Prewitt* untuk meningkatkan deteksi tepi pada gambar yang berisik. [11] [12] Penelitian juga mengembangkan pendekatan yang menggabungkan operator *Prewitt* tradisional dengan *diferensiasi* urutan pecahan untuk memperbaiki kualitas deteksi tepi pada gambar yang lebih sulit. [13]

Penelitian yang dilakukan oleh Yopento, Jopa et al. (2022) yang menggunakan *CNN* berdasarkan ekstraksi fitur *sobel*, penelitian ini menggunakan *CNN* dengan ekstraksi fitur *Sobel* untuk mendeteksi *pneumonia* pada citra *x-ray* dada. *CNN* dengan ekstraksi fitur *Sobel* mencapai akurasi 92% dengan menggunakan arsitektur *AlexNet* [14]. Selain itu, *augmentasi* data juga merupakan teknik penting dalam meningkatkan kinerja *CNN*. Dengan *augmentasi* data, ukuran kumpulan data dapat ditambah secara artifisial melalui variasi gambar seperti rotasi, pembalikan, atau penyesuaian kecerahan, sehingga model dapat mempelajari fitur lebih canggih dan mengurangi risiko *overfitting*. [15] Berbagai arsitektur *CNN*, seperti *VGG19*, *InceptionV3*, *Xception*, dan *DenseNet169*, telah diuji dalam mendeteksi *pneumonia*, dengan *DenseNet169* menunjukkan akurasi tertinggi di antara model yang diuji. [16]

Tujuan dari penelitian ini adalah mengembangkan suatu sistem deteksi *pneumonia* menggunakan gambar *X-ray* dada dengan bantuan *CNN*. Sistem ini diharapkan dapat membantu dokter untuk mendiagnosis *pneumonia* dengan lebih tepat dan efisien.


METODE

Metode penelitian untuk mengembangkan sistem deteksi *pneumonia* menggunakan *CNN* pada gambar *X-ray* dada menggunakan *Cross-Industry Standard Process for Data Mining (CRISP-DM)*. Selanjutnya algoritma yang digunakan untuk mendeteksi *pneumonia* yaitu *Convolutional Neural Network (CNN)* dan *Prewitt Operator* untuk mendeteksi tepi. Berikut gambar tahapan *CRISP-DM*.




Gambar 1. Tahapan CRISP-DM

CRISP-DM, atau *Cross-Industry Standard Process for Data Mining*, adalah metode yang paling umum digunakan dalam proyek *data mining*. Singkatnya, metode *CRISP-DM* (*Cross-Industry Standard Process for Data Mining*) bertujuan untuk menyediakan panduan langkah demi langkah dalam proses pengumpulan data [17]. Pendekatan yang digunakan pada penelitian ini adalah *CRISP-DM* yang terdiri dari 5 tahapan, meliputi : *Business Understanding*, *Data Understanding*, *Data Preparation*, *Modelling*, *Evaluation*. Tahapan *Business Understanding* mencakup penentuan tujuan bisnis, penilaian situasi, dan penetapan tujuan untuk melakukan *data mining*. Selanjutnya, *Data Understanding* melibatkan persiapan, evaluasi kebutuhan data, dan pengumpulan data. Tahapan *Data Preparation*, setelah data dikumpulkan, data tersebut diidentifikasi, dipilih, dibersihkan, dan disusun dalam format yang ditentukan. *Modelling* adalah langkah di mana algoritma diterapkan untuk menemukan, mengidentifikasi, dan menampilkan pola. Selanjutnya tahap *Evaluation* berfungsi untuk mengukur efektivitas model dan menentukan model mana yang paling sesuai untuk proses *data mining*.



Gambar 2. Tahapan Pendekatan Penelitian


Business Understanding merupakan penjelasan dari sebuah proses analisis model yang akan dibuat. Prosesnya dapat dilihat pada gambar dibawah ini.



Gambar 3. Tahapan *Business Understanding*

Gambar 3 adalah proses yang dimulai dengan identifikasi masalah, di mana tujuan utama proyek diidentifikasi. Setelah itu, langkah tujuan untuk mengetahui *pneumonia* pada hasil *x-ray* dada, sementara data yang diperlukan adalah data hasil dari *x-ray* dada yang didapat dari *platform kaggle*. Setelah data hasil *x-ray* dada tersedia baru dilakukan deteksi *pneumonia* menggunakan *CNN & Prewitt Operator*. Selanjutnya, evaluasi dan validasi memastikan data yang telah dilakukan deteksi *valid* dan sesuai dengan tujuan dari *data science*.

Data Understanding merupakan sebuah proses yang meliputi pemahaman data pada penelitian, mengumpulkan dataset *x-ray* dada dengan kasus *pneumonia* dan tanpa *pneumonia*. Proses dari *Data Understanding* ini dapat dilihat pada gambar dibawah ini.




Gambar 4. Tahapan *Data Understanding*

Gambar 4 menunjukkan alur yang menunjukkan proses pengumpulan dan persiapan data mentah untuk dimasukkan ke dalam model. Langkah ini dimulai dari *raw data*, yaitu data awal yang belum diolah yang didapat dari *platform kaggle*. Kemudian, data dikumpulkan melalui *collecting data* dan dibersihkan pada tahap *cleaning data* untuk menghilangkan *anomali* atau kesalahan yang mungkin ada, data yang telah bersih kemudian di bagi menjadi 3 folder yaitu test, train, dan validasi. Setelah data bersih dan telah dibagi, tahap *modelling* melibatkan penerapan model *CNN* dan *Prewitt Operator* dengan arsitektur *EfficientNet* untuk analisis lebih lanjut, berdasarkan data yang telah disiapkan.

Data Preparation merupakan sebuah proses yang meliputi *labelling*, *split data*, dan *augmentasi data* untuk memperbaiki keberagaman dataset untuk memudahkan model dalam melakukan deteksi agar mendapatkan hasil yang


optimal sehingga akan mendapatkan tingkat akurasi yang optimal. Berikut proses dari *data preparation* dapat dilihat dari gambar dibawah ini.



Gambar 5. Tahapan *Data Preparation*


Gambar 5 menunjukkan tahap yang lebih mendalam dalam pra-pemrosesan data. Langkah - langkah yang ditampilkan termasuk *cleaning data* untuk memastikan kualitas data yang baik, *labelling data* ini untuk memberikan label atau kategori pada data, dan diberikan 2 label yang berbeda yaitu “*Pneumonia*” dan “*Normal*”. *Split data* digunakan untuk membagi data menjadi 3 folder yang berbeda yaitu menjadi data pelatihan, pengujian, dan validasi. *Prewitt operator* ini digunakan untuk pemrosesan deteksi tepi pada data gambar. *augmentation data* yang digunakan yaitu adalah *image data generator*, yang dimana inipada augmentasi ini bukan untuk memperkaya atau memperbesar jumlah data melainkan menggunakan augmentasi dari *prewitt operator* yang fungsinya untuk meningkatkan fitur tepi pada gambar.

CNN Development Model merupakan sebuah proses untuk merancang arsitektur CNN untuk deteksi *pneumonia*, dengan pembagian data pelatihan, pengujian, dan validasi. Proses dari *development model* dapat dilihat pada gambar dibawah ini.



Gambar 6. Tahapan *CNN Development Model*

Gambar 6 menggambarkan struktur dasar CNN yang terdiri dari beberapa lapisan. Lapisan *Global Max Pooling* berfungsi untuk mengubah fitur CNN menjadi vector kecil. Kemudian, lapisan *Batch Normalization* berfungsi untuk menormalkan fitur agar stabil, sementara *Dense* berfungsi untuk *fully connected layer* utama. Setelah itu, lapisan *Dropout* untuk mencegah *overfitting*, dan lapisan berikutnya, yaitu *SoftMax* berperan untuk menghasilkan probabilitas untuk setiap kelas. *Modelling* ini merupakan sebuah proses dimana membuat dan melatih model CNN dengan dataset yang diproses untuk mempelajari pola dan fitur pneumonia. Proses *modelling* dapat dilihat pada gambar dibawah ini



Gambar 7. Tahapan *Modelling*

Gambar 7 memberikan gambaran tentang model yang menggabungkan *EfficientNet* dengan *Adamax* sebagai optimizer. *EfficientNet* adalah salah satu arsitektur CNN yang menggunakan skala efisien dalam jumlah layer, ukuran filter dan resolusi gambar untuk mencapai kinerja tinggi dengan lebih sedikit parameter.

Adamax adalah variasi dari optimasi *adam* yang lebih stabil pada data dengan skala besar atau vector dengan dimensi tinggi. *Evaluation* adalah sebuah proses untuk melakukan validasi model dengan data terpisah dan evaluasi menggunakan metrik seperti akurasi, presisi, *recall*, dan *F1-score*.

HASIL DAN PEMBAHASAN

Berdasarkan tahapan yang telah dipaparkan sebelumnya, dilakukan proses implementasi dan pengujian pada dataset hasil *x-ray* yang telah tersedia dengan tujuan untuk mengetahui apakah hasil penelitian telah sesuai dengan tujuan penelitian yang diharapkan.

Business Understanding

Pneumonia adalah infeksi paru-paru yang serius dan bisa mengancam jiwa. [18] Salah diagnosis dari *x-ray* dada dapat berakibat fatal karena pasien mungkin tidak mendapat pengobatan yang tepat. Penelitian ini menggunakan algoritma CNN dengan fitur *Prewitt Operator* dan arsitektur *EfficientNet* untuk meningkatkan akurasi dan efisiensi diagnosis pneumonia, setelah metode sebelumnya hanya mencapai akurasi di atas 70%. Penelitian ini diharapkan dapat memberikan kemudahan dan efisiensi waktu untuk mendiagnosa *Pneumonia* dan diharapkan meningkatkan hasil akurasi yang tinggi.


Tabel 1. Kinerja Arsitektur Penelitian Sebelumnya

Model Name	Accuracy	Recall	F1 Score
VGG16	87.18%	96%	90%
VGG19	88.46%	95%	91%
ResNet50	77.565	97%	84%
Inception-v3	70.99%	84%	78%

Data Understanding

Dataset yang digunakan pada penelitian ini berasal dari *platform Kaggle*, data yang digunakan merupakan data hasil *X - Ray* dada yang digabungkan dari 2 dataset yang tersedia pada *platform Kaggle* dan dibagi menjadi 3 bagian yaitu pelatihan, pengujian, dan validasi. Setiap bagian dataset dibuat menjadi dua kategori, yaitu hasil *X - Ray* dada yang menunjukkan paru - paru normal dengan data di pelatihan 234 data, di pengujian 1314 data, di validasi 8 data, dengan total data normal 1556 data. Dan yang menunjukkan paru - paru terkena *Pneumonia* dengan data di pelatihan 390 data, di pengujian 3875 data, di validasi 8 data, dengan total *pneumonia* 4273 data.

Gambar 8 terlihat bahwa data yang digunakan dalam pelatihan model deteksi *pneumonia* pada gambar *x-ray* memiliki ketidakseimbangan. Grafik batang pada gambar menunjukkan bahwa jumlah data *pneumonia* lebih banyak daripada data normal dengan perbandingan yang cukup signifikan.




Gambar 8. Data Hasil X - Ray Dada

Data Preparation

Berdasarkan data hasil *x - ray* dada yang telah tersedia di *kaggle*, dilakukan *cleaning data* atau pembersihan data dengan cara membagi dataset menjadi 3 bagian yang berbeda untuk pelatihan, pengujian, dan validasi. Lalu *labelling* pada setiap bagian menjadi 2 label yaitu “normal” dan “*pneumonia*” sehingga pada saat akan diimplementasikan datanya telah siap untuk digunakan., maka didapatkan tahapan untuk proses *cleaning data*, yaitu :

1. Labelling & Split Data



Gambar 9. Hasil Read Data yang telah diberi Label

Gambar 9 menunjukkan hasil dari membaca data dari direktori yang telah berisikan dua kelas (*Pneumonia* dan Normal), gambar tersebut adalah hasil dari proses sebelumnya yang telah merubah ukurannya serta menerapkan *prewitt* operator untuk deteksi tepi dan disimpan bersama dengan label.

2. Prewitt Operator

Prewitt Operator mendeteksi objek dalam citra dengan menyoroti garis tepi yang membentuk batas objek. Tepi ini penting untuk membedakan objek dan latar

belakang. *Prewitt* memberikan bobot lebih pada piksel yang berdekatan, mirip dengan *Sobel*, namun tanpa *High Pass Filter (HPF)* [19]. *Prewitt Operator* menggunakan dua kernel, G_x dan G_y , untuk mendeteksi gradien horizontal dan vertikal pada citra dengan matriks 3×3 . [20]

$$\begin{array}{c} \left| \begin{array}{ccc} 1 & 0 & -1 \\ 1 & 0 & -1 \\ 1 & 0 & -1 \end{array} \right| \quad \left| \begin{array}{ccc} 1 & 1 & 1 \\ 0 & 0 & 0 \\ -1 & -1 & -1 \end{array} \right| \\ \text{Kernel x} \qquad \qquad \text{Kernel y} \end{array}$$

Tabel 2. Contoh kernel x dan y

Kernel atau filter yang digunakan untuk melakukan kovolusi pada gambar untuk mendeteksi tepi adalah x untuk tepi horizontal dan y untuk tepi vertikal. *Kernel x* ini digunakan untuk mendeteksi perubahan intensitas cahaya di arah horizontal dengan nilai di sebelah kiri positif dan di sebelah kanan negatif untuk menghasilkan perbedaan intensitas yang menonjol pada area tepi secara horizontal. *Kernel y* digunakan untuk mendeteksi perubahan intensitas di arah vertikal sehingga dapat lebih terlihat dalam hasilnya. Setelah mendefinisikan *prewitt operator* maka selanjutnya mengaplikasikan filter pada gambar menggunakan *cv2.filter2D*, yang dimana ini digunakan untuk menerapkan kernel *prewitt* pada gambar. Hasil dari konvolusi antara gambar dan kernel x adalah *grad_x* yaitu citra yang menunjukkan perubahan intensitas dalam arah horizontal, dan hasil dari konvolusi antara gambar dan kernel y adalah *grad_y* yaitu yang mendeteksi perubahan intensitas dalam arah vertical.

3. Augmentation Data

Augmentation data adalah teknik yang digunakan untuk meningkatkan variasi data pelatihan tanpa benar-benar menambahkan data baru. Pada penelitian ini augmentasi yang digunakan adalah *Image Data Generator* yaitu menggunakan gambar hasil *Prewitt Operator* untuk training.

Modelling

1. EfficientNet & Global Max Pooling

EfficientNet ini adalah model CNN pertama yang digunakan dan berperan sebagai fitur ekstraksi. Model ini sudah memiliki lapisan *conv2d* dan *maxpooling2d* bawaan, model ini hanya akan melakukan ekstraksi fitur tanpa *fully connected layer* bawaan. *Global Max Pooling* digunakan untuk mereduksi dimensi fitur sebelum masuk ke *fully connected layer*. *Global Max Pooling* berfungsi untuk mengubah fitur dari CNN ke *vector* satu dimensi.

2. Batch Normalization

Batch Normalization adalah fitur yang dihasilkan dan dinormalisasi setelah proses *Global Max Pooling*. Tujuannya adalah untuk menormalkan distribusi nilai fitur agar stabil saat training, dengan menggunakan momentum 0,99 berarti model mempertahankan rata - rata statistic batch sebelumnya sebanyak 99%, dan menggunakan epsilon 0.001 untuk mencegah pembagian nol saat normalisasi.

3. Dense Layer

Dense layer atau yang sering disebut juga *fully connected layer*, digunakan untuk memproses hasil ekstraksi fitur dari lapisan konvolusional dan *pooling*, dan akhirnya menghasilkan output prediksi dari model. Model menggunakan 256 neuron dengan aktivasi *ReLU* untuk menangka pola non - linear. Regularization (L1 dan L2) diterapkan agar bobot model tidak terlalu besar dan mengurangi overfitting.

4. Dropout

Dropout digunakan sebagai teknik regularisasi untuk mengurangi *overfitting* dengan cara menonaktifkan secara acak sebagian neuron selama pelatihan sehingga model tidak menjadi terlalu bergantung pada fitur atau neuron tertentu. Parameter dropout yang digunakan diatur ke 0.45, ini berarti 45% dari neuron akan dimatikan setiap langkah pelatihan.

5. Softmax

Softmax ini untuk menentukan kategori output, *Softmax* ini digunakan karena ini adalah klasifikasi multi - kelas. *Softmax* juga menghasilkan probabilitas untuk setiap kelas.

6. Adamax

Adamax adalah variasi dari optimasi *Adam*, yang lebih stabil pada data dengan skala besar atau vector dengan dimensi tinggi. Pada penelitian ini *Adamax* digunakan dengan laju pembelajaran yang cukup rendah untuk stabilitas dan mengukur performa model berdasarkan akurasi.

Evaluation

Ketidakseimbangan kelas antara *Pneumonia* dan Normal untuk menangannya model menggunakan *Regularization L1 & L2* yang dibuat agar bobot model tidak terlalu besar. Selama evaluasi model, ukuran *batch* yang lebih kecil (10) digunakan untuk meminimalkan penggunaan memori. *Classification report* dan *confusion matrix* digunakan untuk mengukur performa model. *Classification report* memberikan metrik seperti *precision*, *recall*, dan *F1-score*, yang penting dalam situasi data tidak seimbang, sementara *confusion matrix* memberikan gambaran yang jelas mengenai prediksi benar dan salah untuk masing-masing kelas.

Tabel 3. Tahapan Proses Modelling dan Validation

<i>Epoch</i>	<i>Train_Loss</i>	<i>Train_Accu</i>	<i>Val_Accu</i>	<i>Val_Loss</i>
1/10	4.555%	92.76%	96.17%	2.910%
2/10	2.266%	96.86%	95.37%	1.738%
3/10	1.388%	97.82%	98.40%	1.067%
4/10	86.81%	98.37%	98.72%	65.85%
5/10	57.05%	98.59%	96.96%	51.16%
6/10	39.51%	98.95%	98.40%	33.29%
7/10	30.47%	98.90%	99.36%	24.47%
8/10	23.30%	99.14%	99.04%	20.26%
9/10	18.83%	99.52%	98.88%	17.39%
10/10	15.65%	99.50%	98.88%	15.02%

Tabel 2 menunjukkan hasil pelatihan model selama 10 *epoch*. Di setiap *epoch*, terdapat empat metrik utama yang dicatat, yaitu *Train_Accuracy* (akurasi pada data pelatihan yang mencerminkan kinerja model pada data yang digunakan untuk dilatih), *Train_Loss* (nilai kehilangan pada data pelatihan), *Val_Accu* (akurasi pada data validasi yang mencerminkan kinerja model pada data yang tidak dilatih untuk memberikan gambaran seberapa baik model akan bekerja di dunia nyata), dan *Val_Loss* (nilai kehilangan pada data validasi). Pada awal pelatihan (*epoch* pertama), *loss* model cukup tinggi di angka 4.555% untuk data pelatihan, sementara akurasi untuk data pelatihan cukup tinggi di 92.76% dan *val_loss* juga cukup tinggi di 2.910%.


Akurasi pada data pelatihan meningkat secara signifikan dan konsisten, mencapai 99.50% pada *epoch* terakhir (10/10). Namun, akurasi pada data validasi tidak menunjukkan peningkatan yang stabil dan fluktuatif, meskipun di akhir *epoch* juga mengalami peningkatan. Nilai *loss* pada data pelatihan terus menurun hingga 15.65% di *epoch* terakhir, menunjukkan bahwa model semakin baik dalam menyesuaikan diri dengan data pelatihan. Namun, nilai *val_accu* pada data validasi cenderung berfluktuasi, yang dapat menjadi indikasi adanya masalah *overfitting*, di mana model terlalu menyesuaikan diri dengan data pelatihan dan kurang mampu melakukan generalisasi dengan baik pada data validasi.

Ketidakseimbangan data antara *pneumonia* dan normal mungkin menjadi salah satu faktor yang menyebabkan fluktuasi ini, karena model mungkin lebih mudah mengidentifikasi kasus *pneumonia* daripada kasus normal. Upaya yang dapat dilakukan untuk mengatasi hal ini meliputi penyeimbangan data atau penggunaan teknik lain, seperti *focal loss* dan mekanisme perhatian yang dapat membantu model dalam menangani data yang tidak seimbang.

Tabel 4. Model Evaluasi

<i>Train_Loss</i>	<i>Train_Accu</i>	<i>Test_loss</i>	<i>Test_Accu</i>	<i>Val_loss</i>	<i>Val_Accu</i>
12.43%	100%	16.22%	98%	18.28%	96.59%


Tabel 3 menunjukan hasil dari evaluasi model, model memiliki akurasi tinggi di semua kategori, tetapi perbedaan *loss* antara *train*, *test*, dan *val* tetap menunjukkan adanya kemungkinan *overfitting*, namun model sudah memiliki performa yang baik pada data uji.



Gambar 10. Grafik Pelatihan & Validasi Model

Gambar 10 menampilkan dua grafik yang menggambarkan perkembangan *loss* dan akurasi model selama proses pelatihan. Grafik *loss* menunjukkan perubahan nilai *loss* terhadap jumlah *epoch*, dimana garis biru mewakili data training dan garis oranye menunjukkan data validasi. Keduanya mengalami penurunan secara bertahap, yang mengindikasikan bahwa model semakin baik dalam mempelajari pola data. *Loss* yang hampir sejajar diakhir *epoch* menandakan model tidak mengalami *overfitting* yang signifikan.

Grafik sebelah kanan yang menggambarkan akurasi model selama pelatihan. Garis biru menunjukkan akurasi pada data training, garis oranye menunjukkan akurasi pada data validasi. Akurasi mengalami peningkatan seiring bertambahnya *epoch*, dan pada akhirnya mencapai nilai yang sangat tinggi mendekati 100%. Meskipun terdapat sedikit fluktuasi pada akurasi validasi, secara keseluruhan, grafik ini menunjukkan bahwa model mampu belajar dengan baik dan memiliki performa yang stabil.



Gambar 11. Hasil Heatmap Prediction Confusion Matriks

Gambar 11 adalah *confusion matriks* yang digunakan untuk mengevaluasi kinerja model klasifikasi dalam memprediksi *pneumonia* dan normal. Sumbu *vertikal* menunjukkan kelas sebenarnya, sementara sumbu *horizontal* menunjukkan prediksi model. Matriks ini mencakup 319 kasus di mana model benar memprediksi *Pneumonia* (*True Positive*), 0 kasus di mana model salah memprediksi Normal padahal sebenarnya *Pneumonia* (*False Negative*), 8 kasus di mana model salah memprediksi *Pneumonia* padahal sebenarnya Normal (*False Positive*), dan 91 kasus di mana model benar memprediksi Normal (*True Negative*). Warna dalam matriks menunjukkan intensitas jumlah sampel, dengan warna lebih gelap menunjukkan jumlah yang lebih besar.

PENUTUP

Penelitian ini berhasil mengembangkan sistem deteksi *pneumonia* berbasis *Convolutional Neural Network* (CNN) yang mampu mengidentifikasi *pneumonia* pada gambar *x-ray* dengan lebih akurat dan konsisten. Dengan menggunakan teknik

CNN yang dipadukan dengan *Prewitt Operator* serta *EfficientNet*, dan optimisasi ketidakseimbangan kelas melalui *Regularization*, sistem ini menunjukkan potensi untuk meningkatkan akurasi diagnosis *pneumonia*.

Hasil implementasi menunjukkan bahwa algoritma *Prewitt* berhasil mendeteksi tepi dan fitur penting pada gambar, sementara *EfficientNet* berperan penting dalam mengidentifikasi pola yang lebih kompleks dan dalam pada citra *x-ray*. Penggunaan *Global Max Pooling* juga berhasil mereduksi dimensi data dengan efisien sebelum dikirim ke lapisan akhir model. Dengan demikian, model ini dapat menjadi alat bantu yang efektif bagi dokter dalam mendiagnosis *pneumonia* secara lebih cepat dan akurat. Penelitian ini membuktikan potensi besar yang dimiliki oleh CNN dalam mendukung proses *diagnosis pneumonia* melalui analisis citra *x-ray* dada. Implementasi teknologi ini diharapkan mampu mengurangi kesalahan *diagnosis* serta memberikan efisiensi waktu bagi para dokter, terutama di negara-negara berkembang di mana akses terhadap alat diagnostik yang lebih canggih mungkin masih terbatas.

DAFTAR PUSTAKA

- [1] World Health Organization. (2020). Pneumonia.
- [2] Kementerian Kesehatan Republik Indonesia. (2020). Profil Kesehatan Indonesia Tahun 2018.
- [3] American Thoracic Society. (2020). Diagnosis and Treatment of Adult Pneumonia.
- [4] World Health Organization. (2014). Pneumonia : Key Facts
- [5] McHugh, T. D., & Lakshminarayanan, S. (2014). Pneumonia Diagnosis in Children: Challenges and Solutions.
- [6] van der Heijden, J. F., & Hoes, A. W. (2005). Accuracy of chest radiography in the diagnosis of pneumonia: a systematic review and metaanalysis.
- [7] Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. W., Ciompi, F., Ghafoorian, M., ... & van Ginneken, B. (2017). A survey on deep learning in medical image analysis.
- [8] Kermany, D. S., Zhang, K., Li, Q., King, D., & Sun, H. (2018). Identifying Medical Diagnoses and Treatable Diseases by Image-Based Deep Learning.
- [9] Rajpurkar, P., Irvin, J., Zhu, K., Yang, B., Mehta, H., Duan, T., ... & Ng, A. Y. (2017). CheXNet: Radiologist-Level Pneumonia Detection on Chest X-Rays with Deep Learning.
- [10] Wang, X., Peng, Y., Lu, L., Lu, Z., & Bagheri, M. (2017). A Deep Learning
- [11] Tian, X. "A novel image edge detection algorithm based on prewitt operator and wavelet transform." *International Journal of Advancements in Computing Technology* 4.19 (2012): 73-82.
- [12] Yang, Lei, et al. "An improved Prewitt algorithm for edge detection based on noised image." *2011 4th International congress on image and signal processing*. Vol. 3. IEEE, 2011.
- [13] Balochian, Saeed, and Hossein Baloochian. "Edge detection on noisy images using Prewitt operator and fractional order differentiation." *Multimedia Tools and Applications* 81.7 (2022): 9759-9770.
- [14] Yopento, Jopa et al. "Identifikasi Pneumonia Pada Citra X-Ray Paru-Paru

Menggunakan Metode Convolutional Neural Network (CNN) Berdasarkan Ekstraksi Fitur Sobel." *Rekursif: Jurnal Informatika* (2022): n. pag.

- [15] Garstka, Jakob, and Michał Strzelecki. "Pneumonia detection in X-ray chest images based on convolutional neural networks and data augmentation methods." 2020 *Signal Processing: Algorithms, Architectures, Arrangements, and Applications (SPA)*. IEEE, 2020.
- [16] Shazia, Anis, et al. "A comparative study of multiple neural network for detection of COVID-19 on chest X-ray." *EURASIP journal on advances in signal processing* 2021 (2021): 1-16.
- [17] Navisa, S., Luqman Hakim, and Aulia Nabilah. "Komparasi Algoritma Klasifikasi Genre Musik Pada Spotify Menggunakan CRISP-DM: Indonesia". *Jurnal Sistem Cerdas*, Vol. 4, no. 2, Aug. 2021, pp. 114 -25, doi:10.37396/jsc.v4i2.162.
- [18] Josefa, Razky, Rini Sovia, and Eka Praja Wiyata Mandala. "Sistem Pakar Diagnosa Penyakit Pneumonia Pada Anak Menggunakan Metode Case Based Reasoning." *Seminar Nasional Teknologi Komputer & Sains (SAINTEKS)*. Vol. 1. No. 1. 2019.
- [19] Putra, Ardiansyah, Volvo Sihombing, & Mustafha Haris Munandar. "Rancang Bangun Aplikasi Deteksi Tepi Citra Digital Menggunakan Algoritma Prewitt," *Jurnal Tekinkom (Teknik Informasi dan Komputer)* [Online], 4.1 (2021): 83-87. Web. 27 Sep. 2024.
- [20] Masril, M. A., and R. Noviardi. "Analisa Morfologi Dilasi Untuk Perbaikan Kualitas Citra Deteksi Tepi Pada Pola Batik Menggunakan Operator Prewitt Dan Laplacian of Gaussian". *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, Vol. 4, no. 6, Dec. 2020, pp. 1052 -, doi:10.29207/resti.v4i6.2601.