



## MODEL MACHINE LEARNING CNN BERBASIS DENSENET UNTUK IDENTIFIKASI PNEUMONIA MELALUI CITRA SINAR-X

Mohamad Firdaus<sup>a\*</sup>, Aditya Herliawan<sup>b</sup>

<sup>a</sup> Fakultas Teknik dan Ilmu Komputer / Teknik Industri, mfirdausmumu@gmail.com, Universitas Indraprasta PGRI, Jakarta, DKI Jakarta

<sup>a</sup> Fakultas Ekonomi dan Bisnis / Program Doktor Ilmu Ekonomi, mfirdausmumu@gmail.com, Universitas Borobudur, Jakarta, DKI Jakarta

<sup>b</sup> Fakultas Teknik dan Ilmu Komputer / Teknik Industri, herliawan.aditya@gmail.com, Universitas Indraprasta PGRI, Jakarta, DKI Jakarta

\* Korespondensi

### ABSTRACT

*The application of machine learning, particularly the \*Convolutional Neural Network\* (CNN) method, has experienced rapid development in the medical field. Through the process of image data grouping, CNN is capable of classifying based on the similarity of characteristics and attributes of the images. This capability is highly beneficial in the healthcare sector, especially in differentiating chest X-ray images. This study aims to evaluate the DenseNet architecture while applying it to classify Covid-19 disease by utilizing 98 chest X-ray images as training data. The test results showed that the average \*loss\* value on the training data was 0.8621, with an average accuracy of 0.6950. Meanwhile, the average \*loss\* value on the validation data was recorded at 1.0682, with an average accuracy of 0.6399. From these results, it can be concluded that the model performed better on the training data than on the validation data, indicating the occurrence of \*overfitting\*. Therefore, further adjustments to the model are necessary to improve its performance on the validation data.*

**Keywords:** DenseNet, Convolutional Neural Network, Chest X-ray Images

### Abstrak

Penerapan machine learning, khususnya metode Convolutional Neural Network(CNN), telah mengalami perkembangan pesat dalam bidang medis. Melalui proses pengelompokan data gambar, CNN mampu melakukan klasifikasi berdasarkan kemiripan karakteristik dan atribut gambar tersebut. Kemampuan ini sangat berguna dalam sektor kesehatan, terutama dalam membedakan hasil citra rontgen dada. Penelitian ini bertujuan untuk mengevaluasi arsitektur DenseNet sekaligus menerapkannya dalam klasifikasi penyakit Covid-19 dengan memanfaatkan 98 gambar rontgen dada sebagai data latih. Hasil pengujian menunjukkan bahwa nilai \*loss\* rata-rata pada data pelatihan sebesar 0,8621, dengan akurasi rata-rata 0,6950. Sementara itu, nilai \*loss\* rata-rata pada data validasi tercatat sebesar 1,0682, dengan akurasi rata-rata 0,6399. Dari hasil tersebut, dapat disimpulkan bahwa model memiliki performa yang lebih baik saat diterapkan pada data pelatihan dibandingkan data validasi, yang mengindikasikan terjadinya \*overfitting\*. Oleh sebab itu, diperlukan penyesuaian lebih lanjut pada model guna meningkatkan performanya terhadap data validasi.

**Kata kunci:** DenseNet, Convolutional Neural Network, Citra Rontgen Dada


### 1. PENDAHULUAN

Indonesia adalah negara kepulauan yang memiliki banyak wilayah perbatasan dengan negara lain[1], di tengah situasi pandemi COVID-19 yang melanda seluruh dunia. Penyakit ini disebabkan oleh virus corona yang dapat memicu gangguan pernapasan akut. Kasus positif COVID-19 pertama kali diumumkan di Indonesia pada 2 Maret 2020, dan sejak itu jumlah kasus meningkat pesat hingga mencapai sekitar 2 juta

kasus. Kondisi ini turut berdampak signifikan terhadap penurunan pendapatan dan kondisi ekonomi global. Pandemi ini juga mengubah tatanan perekonomian dunia secara keseluruhan. Seluruh sistem kerja, termasuk sumber daya manusia di bidang teknologi, harus melakukan penyesuaian besar-besaran akibat peralihan dari metode kerja konvensional ke sistem daring berbasis cloud.

Teknologi kecerdasan buatan atau Artificial Intelligence (AI), khususnya metode Convolutional Neural Network (CNN)[2], kini dimanfaatkan untuk memprediksi hasil citra rontgen dada pada pasien COVID-19. Penelitian ini bertujuan untuk memperoleh performa terbaik dari arsitektur CNN DenseNet dalam mendeteksi infeksi COVID-19 melalui citra rontgen dada[3][4]. Pneumonia merupakan salah satu penyakit umum di dunia yang membutuhkan keahlian khusus dalam proses diagnosis. Dalam penelitian ini, dilakukan klasifikasi pneumonia dari citra rontgen dada menggunakan arsitektur deep learning DenseNet. Tujuan utamanya adalah membantu tenaga medis dalam mendiagnosis pneumonia dengan lebih akurat melalui analisis citra rontgen. Infeksi pada paru-paru akibat virus SARS-CoV-2 umumnya terlihat jelas melalui teknologi X-ray, terutama pada kasus yang cukup parah.

Untuk memaksimalkan informasi yang terkandung dalam citra tersebut, berbagai pendekatan berbasis deep learning terus dikembangkan karena telah terbukti mampu memberikan performa tinggi di berbagai bidang medis. Beberapa penelitian sebelumnya lebih banyak berfokus pada klasifikasi biner antara pasien sehat dan pasien COVID-19. Dalam studi ini, dilakukan percobaan klasifikasi pneumonia menggunakan dataset khusus yang terdiri dari berbagai koleksi data publik terkait pneumonia dan COVID-19. Dataset yang digunakan memiliki dimensi gambar rontgen yang bervariasi karena berasal dari beragam institusi penelitian [5][6][7]. Data ini kemudian dibagi menjadi dua kelompok, yakni citra pasien COVID-19 dan non-COVID-19, untuk diolah menggunakan metode machine learning.




Gambar 1. Skema pembagian dataset.

Tujuan akhir dari penelitian ini adalah mendeteksi perbedaan antara pasien COVID-19 dan non-COVID-19 melalui analisis citra rontgen dada menggunakan arsitektur DenseNet. Adapun dataset yang digunakan diperoleh secara terbuka dari situs <https://www.kaggle.com>, yang menyediakan berbagai data publik untuk keperluan penelitian[8][9].

## 2. TINJAUAN PUSTAKA


Di era perkembangan teknologi saat ini, hampir seluruh aspek kehidupan memanfaatkan kecerdasan buatan (AI), di mana deep learning (DL) menjadi salah satu metode paling populer dalam pendekatan komputasi di bidang machine learning (ML). Beragam aplikasi modern saat ini dikembangkan dengan dukungan teknologi ML. Salah satu jenis DL yang paling sering diterapkan dalam berbagai kebutuhan manusia adalah Convolutional Neural Network (CNN). Struktur lapisan yang lebih dalam dibandingkan metode ML konvensional menjadikan CNN termasuk dalam kategori DL. Berkat kemampuannya dalam mengenali dan membedakan objek pada gambar, metode ini dikenal luas dengan sebutan CNN (lihat Gambar 2). Pada subbab ini, beberapa istilah penting serta proses yang terdapat dalam CNN akan dijelaskan secara singkat.



Gambar 2. Klasifikasi CNN dalam AI

## 2.1. Convolutional Neural Networks

Pemikiran awal CNN adalah jaringan saraf (neuron) pada manusia dan hewan. CNN terdiri dari tumpukan lapisan konvolusional dengan parameter berbeda (filter, padding, stride, dan lainnya). Masing-masing masukan disusun dalam bentuk matriks tiga dimensi yaitu tinggi (height), lebar (width) dan kedalaman (kedalaman), umumnya nilai tinggi sama dengan nilai lebar. Untuk masukan matriks RGB, nilai salurannya adalah 3, saluran tersebut mewakili nilai kedalaman dalam matriks. Akhir dari rangkaian lapisan CNN menghasilkan model kernel, kemudian dilanjutkan dengan proses yang terhubung sepenuhnya. Proses konvolusi adalah perhitungan perkalian titik antara matriks masukan dan matriks filter[8]. Matriks filter adalah matriks persegi panjang (tinggi=lebar) yang merupakan kumpulan nilai bobot, terkadang juga disebut sebagai matriks kernel. Ukuran tinggi dan lebarnya selalu lebih kecil dari masukan, namun nilai kedalaman (saluran) sama dengan kedalaman masukan. Proses konvolusi umumnya menggunakan lebih dari satu jenis matriks kernel (filter 1, filter 2, dan seterusnya). Besar kecilnya matriks keluaran baris dan kolom dapat digunakan dengan syarat  $O = I - F + 1$ . (Gambar 3).



Gambar 3. Detail proses konvolusi

Tahapan Utama dalam Proses CNN:

- Inisialisasi Awal:**  
Pada tahap ini dilakukan pengimporan pustaka yang diperlukan, penentuan model dasar, serta pengaturan awal seperti memuat dataset, menetapkan hyperparameter, dan melakukan berbagai persiapan sebelum proses pelatihan dimulai.
- Perancangan Arsitektur Model:**  
Bagian ini mencakup penyusunan struktur model CNN yang terdiri atas beberapa jenis lapisan, di antaranya lapisan konvolusi, pooling, normalisasi, aktivasi, dan lapisan lainnya yang mendukung. Penentuan jumlah lapisan, jenis lapisan, serta pengaturan parameter seperti ukuran kernel, jumlah filter, dan fungsi aktivasi dilakukan di tahap ini.
- Proses Pelatihan Model:**  
Pada fase ini, data gambar dimasukkan ke dalam model untuk melatih bobot dan bias agar mampu mengenali fitur-fitur penting yang berkaitan dengan tugas klasifikasi. Proses ini memanfaatkan algoritma optimasi seperti Stochastic Gradient Descent (SGD), Adam, atau RMSprop, serta fungsi loss seperti categorical cross-entropy atau binary cross-entropy.
- Uji Validasi Model:**  
Setelah pelatihan selesai, model diuji menggunakan data validasi untuk menilai seberapa baik performanya secara objektif. Beberapa metrik seperti akurasi, presisi, recall, dan F1-score digunakan untuk mengukur hasil model pada data yang belum pernah dilatih sebelumnya.
- Melakukan Prediksi:**  
Saat model telah dilatih, ia dapat digunakan untuk memprediksi kategori atau nilai probabilitas dari gambar-gambar baru yang belum dikenal sebelumnya. Model akan menghasilkan hasil klasifikasi sesuai kategori yang telah ditentukan.

f. Analisis dan Evaluasi Kinerja:

Tahap terakhir adalah meninjau hasil prediksi model secara menyeluruh, menganalisis kelebihan dan kekurangannya, serta menentukan langkah-langkah perbaikan yang diperlukan untuk meningkatkan akurasi atau performa model ke depannya.

## 2.2. Heading Densenet Architecture

DenseNet atau *Densely Connected Convolutional Network* adalah salah satu arsitektur Convolutional Neural Network (CNN) yang diperkenalkan oleh Huang dan tim pada tahun 2017[10]. Arsitektur ini menawarkan konsep konektivitas yang sangat rapat antar lapisan dalam jaringan, sehingga memungkinkan informasi mengalir lebih lancar dan mendukung proses pembelajaran yang lebih cepat serta efisien. Berikut beberapa ciri utama dari arsitektur DenseNet:

a. Keterhubungan Antar Lapisan yang Intensif (Dense Connectivity):

Pada DenseNet, setiap lapisan terhubung secara langsung ke seluruh lapisan sebelumnya. Artinya, setiap lapisan tidak hanya menerima input dari lapisan tepat di atasnya, melainkan juga dari seluruh lapisan yang ada sebelumnya dalam jaringan. Mekanisme ini menciptakan jalur aliran data yang lebih efisien, serta memanfaatkan kembali fitur yang sudah dipelajari di berbagai tahapan klasifikasi.

b. Struktur Blok Berlapis (Dense Blocks):

Komponen utama dalam DenseNet terdiri dari *dense blocks*, yakni sekumpulan lapisan konvolusi yang diatur secara berurutan dan dipasangkan dengan fungsi aktivasi ReLU. Antara blok-blok ini, biasanya ditambahkan lapisan pooling atau normalisasi guna menurunkan dimensi dan menjaga stabilitas proses pelatihan.

c. Penyebaran Fitur Secara Efektif (Feature Propagation):

Dengan adanya koneksi langsung antara semua lapisan, informasi dapat dengan mudah diteruskan hingga ke lapisan paling dalam. Mekanisme ini membantu memperkuat pembelajaran representasi fitur sekaligus mengurangi risiko masalah *vanishing gradient* saat proses pelatihan berlangsung.

d. Efisiensi Jumlah Parameter (Parameter Efficiency):

Berkat konektivitas yang rapat antar lapisan, DenseNet cenderung membutuhkan parameter lebih sedikit dibandingkan arsitektur CNN konvensional. Sebab, setiap lapisan hanya perlu mempelajari perbedaan (residual) terhadap fitur yang diterima dari lapisan sebelumnya, bukan membangun fitur dari awal.

e. Fleksibilitas Penggunaan (Versatility):

DenseNet dapat diterapkan untuk berbagai jenis tugas dalam bidang *computer vision*, seperti klasifikasi gambar, segmentasi citra, dan lain-lain, berkat kemampuannya dalam menyebarkan dan memanfaatkan informasi secara optimal di seluruh lapisan jaringan.

Sedangkan [www.kaggle.com](http://www.kaggle.com) [4] adalah platform daring yang populer di kalangan praktisi ilmu data dan para pengembang perangkat lunak. Kaggle terkenal karena menyelenggarakan kompetisi data terbuka bagi para ilmuwan data dan para pengembang perangkat lunak. Dalam kompetisi ini, peserta diminta untuk memecahkan tantangan tertentu dalam analisis data atau pemodelan prediktif. Kompetisi sering kali melibatkan dataset nyata dan masalah dunia nyata yang disediakan oleh perusahaan atau lembaga. Selain kompetisi data, Kaggle menyediakan platform untuk berbagi proyek-proyek data dan kumpulan data

## 3. METODOLOGI PENELITIAN

### 3.1 Desain Penelitian

Penelitian ini menggunakan pendekatan kuantitatif eksperimental dengan metode deep learning berbasis arsitektur Convolutional Neural Network (CNN), khususnya model DenseNet. Tujuan dari penelitian ini adalah untuk mendeteksi penyakit COVID-19 melalui analisis citra rontgen dada. Proses pengembangan model melibatkan tahapan pengumpulan data, preprocessing data, perancangan arsitektur CNN DenseNet, pelatihan model, validasi, dan evaluasi performa.

### 3.2 Dataset

Dataset yang digunakan dalam penelitian ini diperoleh dari platform terbuka Kaggle. Data terdiri atas citra rontgen dada yang terbagi dalam dua kategori, yaitu:

- COVID-19
- Non-COVID-19

Jumlah total gambar yang digunakan sebanyak 98 citra, yang kemudian dibagi menjadi dua subset: data pelatihan dan data validasi, dengan rasio pembagian 80:20.

### 3.3 Arsitektur Model

Penelitian ini menerapkan arsitektur DenseNet (Densely Connected Convolutional Network), yang memiliki keunggulan berupa koneksi langsung antar semua lapisan, sehingga dapat memanfaatkan kembali fitur yang telah dipelajari sebelumnya. Struktur utama terdiri atas:

- Dense Blocks: Sekumpulan lapisan konvolusi berurutan dengan aktivasi ReLU
- Transition Layers: Lapisan pooling dan normalisasi di antara Dense Blocks
- Output Layer: Lapisan fully connected dengan fungsi aktivasi sigmoid/binary classifier

### 3.4 Tahapan Penelitian

Adapun tahapan utama dalam penelitian ini terdiri atas:

- Pendahuluan**  
Melakukan impor pustaka, definisi model, konfigurasi awal, memuat dataset, dan menetapkan hyperparameter yang diperlukan.
- Pembentukan Arsitektur DenseNet**  
Menyusun Dense Blocks, menentukan jumlah filter, kernel size, fungsi aktivasi, dan layer pooling sesuai kebutuhan klasifikasi COVID-19.
- Pelatihan Model**  
Model dilatih menggunakan data latih dengan metode optimasi Adam, fungsi loss binary cross-entropy, dan batch size tertentu. Proses pelatihan dilakukan dalam beberapa epoch hingga diperoleh model terbaik.
- Validasi Model**  
Menggunakan data validasi untuk mengukur akurasi, nilai loss, precision, recall, dan F1-score guna mengevaluasi performa model terhadap data yang belum pernah dilihat.
- Prediksi dan Evaluasi**  
Model yang telah dilatih digunakan untuk melakukan prediksi pada citra rontgen baru. Hasil prediksi kemudian dianalisis untuk mengetahui tingkat keakuratan dan efektivitas model.

### 3.5 Evaluasi Kinerja

Evaluasi kinerja model dilakukan dengan menggunakan beberapa metrik evaluasi, yaitu:

- Akurasi
- Loss
- Precision
- Recall
- F1-score

Perbandingan performa antara data pelatihan dan data validasi digunakan untuk mengetahui potensi overfitting yang terjadi.

### 3.6 Alat dan Perangkat Lunak

Seluruh proses pelatihan dan pengujian dilakukan menggunakan:


- Google Colab
- Python 3.x
- Library: TensorFlow, Keras, NumPy, Matplotlib, dan Pandas

## 4. HASIL DAN PEMBAHASAN

Hasil proses pelatihan dengan input data diperoleh nilai train accuracy, train loss, valid loss dan valid accuracy dari arsitektur Densenet, sebagai berikut (Tabel 1)

Tabel 1. Hasil Pelatihan

		Densenet
Train	Loss	0,8621
	Accuracy	0,6950
Valid	Loss	1,0682
	Accuracy	0,6399


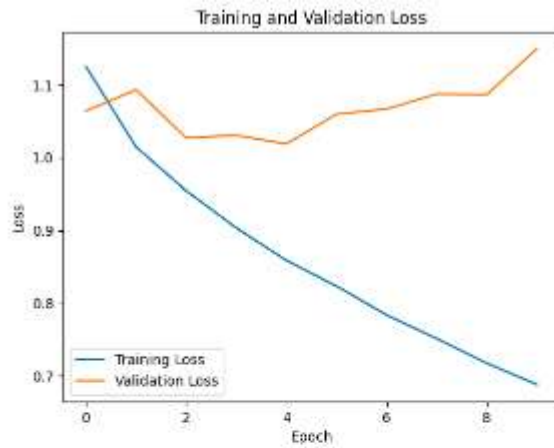


Gambar 4. Grafis Pelatihan

Sedangkan untuk hasil pengulangan (mengacu pada satu putaran lengkap pembelajaran model pada keseluruhan dataset pelatihan) atau yang biasa disebut epoch adalah seperti terlihat di bawah ini

Epoch	Loss	Accuracy	val_loss	val_accuracy
Epoch 1/10	1.05	0.60	1.05	0.60
Epoch 2/10	0.95	0.64	1.03	0.64
Epoch 3/10	0.90	0.68	1.02	0.64
Epoch 4/10	0.85	0.70	1.01	0.64
Epoch 5/10	0.80	0.72	1.05	0.64
Epoch 6/10	0.78	0.74	1.06	0.64
Epoch 7/10	0.75	0.76	1.08	0.64
Epoch 8/10	0.72	0.74	1.09	0.64
Epoch 9/10	0.70	0.76	1.12	0.64
Epoch 10/10	0.68	0.76	1.15	0.64

Gambar 5. Hasil Pelatihan

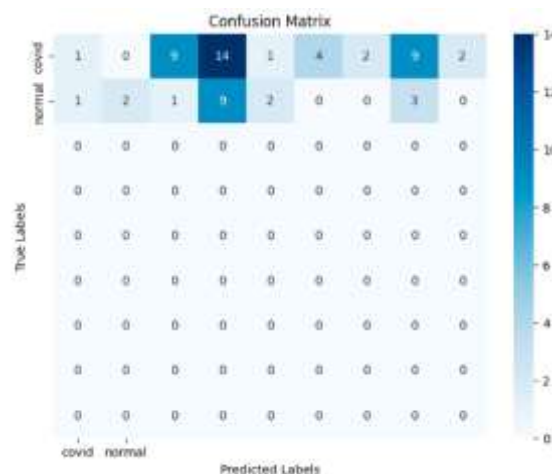


Gambar 6. Grafik Hasil Pelatihan

Epoch 1/10 hingga Epoch 10/10: Setiap baris menyediakan informasi tentang satu epoch dari total 10 epoch yang dilakukan selama pelatihan model. Loss dan Accuracy: Di sisi kiri baris, Anda melihat nilai "loss" (kerugian atau error) dan "accuracy" (akurasi) untuk setiap epoch pada data pelatihan (ditandai dengan "loss" dan "accuracy") dan data validasi (ditandai dengan "val\_loss" dan "val\_accuracy"). Loss adalah ukuran seberapa baik model memprediksi data pelatihan, sedangkan accuracy adalah seberapa akurat model dalam memprediksi label kelas. Nilai loss yang lebih rendah dan nilai accuracy yang lebih tinggi adalah yang diinginkan.

Waktu Pelatihan: Di sisi kanan baris, Anda melihat informasi tentang waktu yang diperlukan untuk menyelesaikan satu epoch dalam pelatihan. Ini mencakup waktu dalam hitungan detik dan rata-rata kecepatan (misalnya, 204s 130ms/step), di mana "s" menunjukkan detik dan "ms" menunjukkan milidetik. Average Training Loss dan Accuracy: Di bawah output, Anda melihat rata-rata dari nilai loss dan accuracy dari seluruh epoch pelatihan. Ini adalah statistik ringkasan tentang kinerja model selama proses pelatihan. Average Validation Loss dan Accuracy: Ini adalah rata-rata dari nilai loss dan accuracy dari seluruh epoch pada data validasi. Ini memberikan gambaran tentang seberapa baik model dapat melakukan generalisasi pada data baru yang belum terlihat. Berdasarkan hasil tersebut,

Anda dapat melihat perubahan dalam kinerja model selama pelatihan, serta evaluasi akhir tentang bagaimana model tersebut berkinerja pada data pelatihan dan validasi. Misalnya, jika loss pada data validasi lebih tinggi daripada pada data pelatihan, ini bisa menjadi indikasi overfitting. Sedangkan, jika accuracy pada data validasi tidak terlalu jauh dari accuracy pada data pelatihan, maka model mungkin berhasil dalam melakukan generalisasi pada data baru.



Gambar 7. Grafik Confusion Matrix

Dalam hal ini terlihat ada gambar yang diprediksi covid dan memang actualnya covid 1 buah, 1 buah gambar diprediksi covid ternyata actualnya normal, diprediksi normal ternyata normal ada 2 gambar, sedangkan gambar yang diprediksi covid ternyata normal tidak dijumpai atau 0 gambar.

Tabel 2. Laporan Klasifikasi

	precision	recall	f1-score	support
0	0.50	0.02	0.05	42
1	1.00	0.11	0.20	18
2	0.00	0.00	0.00	0
3	0.00	0.00	0.00	0
4	0.00	0.00	0.00	0
6	0.00	0.00	0.00	0
7	0.00	0.00	0.00	0
8	0.00	0.00	0.00	0
9	0.00	0.00	0.00	0
accuracy			0.05	60
macro avg	0.17	0.01	0.03	60
weighted avg	0.65	0.05	0.09	60

Laporan klasifikasi di atas memberikan evaluasi kinerja model klasifikasi pada suatu dataset. Precision mengukur seberapa tepat model dalam memprediksi positif dari semua prediksi yang dilakukan untuk kelas tertentu. Dalam laporan ini, nilai precision untuk kelas 0 adalah 0.50, yang berarti dari semua prediksi yang dilakukan oleh model untuk kelas 0, 50% adalah benar-benar positif. Recall mengukur seberapa baik model dapat mengenali kelas tertentu dari semua instance yang sebenarnya milik kelas tersebut. Dalam laporan ini, nilai recall untuk kelas 0 adalah 0.02, yang berarti model hanya berhasil mengenali 2% dari semua instance yang sebenarnya milik kelas 0. F1-score adalah rata-rata harmonik dari precision dan recall. Ini memberikan gambaran tentang keseimbangan antara precision dan recall. Dalam laporan ini, nilai F1-score untuk kelas 0 adalah 0.05.

Support adalah jumlah instance yang sebenarnya milik kelas tertentu dalam dataset. Dalam laporan ini, untuk kelas 0, terdapat 42 instance yang sebenarnya milik kelas tersebut. Accuracy: Accuracy adalah rasio dari jumlah prediksi yang benar (positif dan negatif) terhadap total jumlah prediksi. Dalam laporan ini, accuracy adalah 0.05, yang berarti model hanya benar dalam memprediksi 5% dari seluruh instance dalam dataset. Macro average adalah rata-rata dari metrik evaluasi (precision, recall, dan F1-score) untuk setiap kelas, di mana setiap kelas diberi bobot yang sama. Weighted average adalah rata-rata dari metrik evaluasi dengan memberikan bobot pada setiap kelas sesuai dengan proporsi support-nya dalam dataset. Dari laporan ini, dapat disimpulkan bahwa model memiliki kinerja yang buruk dalam memprediksi kelas-kelas tertentu (seperti kelas 0 dan 1) karena nilai precision, recall, dan F1-score yang rendah. Ini bisa disebabkan oleh ketidakseimbangan kelas, di mana jumlah instance untuk beberapa kelas sangat sedikit atau nol. Diperlukan analisis lebih lanjut untuk memahami dan memperbaiki kinerja model.

## 5. KESIMPULAN DAN SARAN

Hasil optimasi penelitian ini adalah:

Rata-rata loss pada data pelatihan (train) adalah sebesar 0.8621. Rata-rata akurasi pada data pelatihan (train) adalah sebesar 0.6950. Rata-rata loss pada data validasi (valid) adalah sebesar 1.0682. Rata-rata akurasi pada data validasi (valid) adalah sebesar 0.6399. Dari hasil tersebut, dapat dilihat bahwa model memiliki performa yang lebih baik pada data pelatihan dibandingkan dengan data validasi, yang menunjukkan adanya overfitting. Oleh karena itu, perlu dilakukan penyesuaian pada model untuk meningkatkan kinerjanya pada data validasi.

## DAFTAR PUSTAKA

- [1] M. Firdaus, *Profil Potensi Kawasan Perbatasan Darat 2019*, 1st ed. Jakarta: Internasional, Expoindo Media, 2023.
- [2] I. Bakti and M. Firdaus, "Classification of Image Files of Lung X-Ray Results with Architecture Convolution Neural Network (CNN)," *JIFOTECH J. Inf. Technol. Inst. Shanti Bhauana*, vol. 3, no. 1, pp. 26–34, 2023, doi: DOI: <https://doi.org/10.46229/jifotech.v3i1.590>.
- [3] M. Firdaus, "KNN Machine Learning Architecture for Pneumonia Chest X-Ray Clustering," *Telecommun. Comput. Electr. Eng. J.*, vol. 2, no. 1, pp. 43–51.
- [4] Mohamad Firdaus, "CNN Inceptionresnet-V2 Machine Learning Architecture For Pneumonia Chest X-Ray Clustering," *J. Ilm. Multidisiplin Ilmu*, vol. 1, no. 2, pp. 19–29, 2024.
- [5] I. P. Y. R. R. S. N. Y. B. M. F. P. R. S. N. M. F. A. S. W. Muhammad Hasan Acai Sudirman, "Human Capital Management (Teori dan Aplikasi)." Media Sains Indonesia, Jakarta, 2023.
- [6] A. Susanto *et al.*, *MSDM Membentuk SDM Unggul dan Kompetitif*. 2023.

- [7] M. Meisuri, Y. A. Siregar, A. Halik, I. Bakti, and M. Firdaus, "Evaluation of the Effect of Teacher Training on the Use of Learning Technology," *JETE*, vol. 2, no. 1, pp. 8–20, 2024, doi: <https://doi.org/10.55849/jete.v2i1.733>.
- [8] I. Bakti and M. Firdaus, "Arsitektur CNN InceptionResNet-V2 Untuk Pengelompokan Pneumonia Chest X-Ray," *J. Komput. dan Teknol.*, vol. 1, no. 2, pp. 35–42, Jan. 2023, doi: 10.58290/jukomtek.v1i2.66.
- [9] G. Maulani *et al.*, *Development Of Artificial Intelligence Applications*. HEI Publishing Indonesia, 2024.
- [10] and K. Q. W. G. Huang, Z. Liu, L. Van Der Maaten, "Densely Connected Convolutional Networks," *Proc. IEEE Conf. Comput. Vis. Pattern Recognit.*, pp. 4700–4708, 2017, doi: 10.1109/CVPR.2017.243.