

Klasifikasi Pneumonia pada Citra X-Ray Menggunakan CNN ResNet50V2 dengan Transfer Learning

Muhammad Afian Anwar^{1*}
Yana Aditia Gerhana²
Undang Syaripudin³

^{1,2,3}Fakultas Sains dan Teknologi, Teknik Informatika, UIN Sunan Gunung Djati Bandung, Jl. AH. Nasution No.105, Cipadung Wetan, Kec. Cibiru, Kota Bandung, Jawa Barat 40614, Indonesia
¹afiananwar2@gmail.com, ²yanagerhana@uinsgd.ac.id, ³undang_if@uinsgd.ac.id

***Penulis Korespondensi:**
Muhammad Afian Anwar
afiananwar2@gmail.com

Abstrak

Pemanfaatan teknologi untuk membangun model yang dapat mengklasifikasi citra medis pneumonia secara otomatis sangat dibutuhkan untuk diagnosis dini. Penelitian ini bertujuan untuk mengimplementasikan model Convolutional Neural Network (CNN) dengan arsitektur ResNet50V2 yang telah terbukti memiliki akurasi tinggi dalam klasifikasi citra medis. Model ini mengadopsi arsitektur residual yang mendalam dan efisien, yang memfasilitasi pelatihan model yang lebih dalam tanpa mengalami masalah vanishing gradient. Penelitian ini melalui empat tahap utama: pengumpulan data citra X-ray pneumonia dan normal, pre-processing data (termasuk pembagian set, transformasi, dan augmentasi), pemodelan menggunakan CNN dengan tuning hyperparameter, dan evaluasi model. Evaluasi dilakukan dengan menggunakan metrik akurasi, F1-score, dan Confusion Matrix. Model CNN dengan ResNet50V2 sebagai backbone mencapai akurasi 97%, menunjukkan kinerja yang sangat baik dalam membedakan antara pneumonia dan normal meskipun terdapat sedikit kesalahan klasifikasi. Meskipun model ini menunjukkan hasil yang mengesankan, tantangan seperti potensi kesalahan klasifikasi pada kasus dengan citra yang tidak jelas atau ambigu tetap ada. Dibandingkan dengan pendekatan sebelumnya, model ini menawarkan keunggulan dalam akurasi dan efisiensi pemrosesan berkat penggunaan ResNet50V2 yang lebih dalam dan lebih canggih. Keunggulan ini diharapkan dapat meningkatkan ketepatan diagnosis otomatis dalam aplikasi medis di masa depan.

Kata Kunci: CNN; Citra X-ray; Klasifikasi Pneumonia; ResNet50V2; Transfer Learning

Abstract

The utilization of technology to build models that can classify pneumonia medical images automatically is needed for early diagnosis. This study aims to implement a Convolutional Neural Network (CNN) model with ResNet50V2 architecture that has been proven to have high accuracy in medical image classification. The model adopts a deep and efficient residual architecture, which facilitates deeper training of the model without suffering from vanishing gradient problem. This study went through four main stages: pneumonia and normal X-ray image data collection, data pre-processing (including set division, transformation, and augmentation), modeling using CNN with hyperparameter tuning, and model evaluation. Evaluation was performed using accuracy, F1-score, and Confusion Matrix metrics. The CNN model with ResNet50V2 as the backbone achieved 97% accuracy, showing excellent performance in differentiating between pneumonia and normal despite a small amount of misclassification. Although this model showed impressive results, challenges such as potential misclassification in cases with unclear or ambiguous images remain. Compared to previous approaches, this model offers advantages in accuracy and processing efficiency thanks to the use of a deeper and more sophisticated ResNet50V2. These advantages are expected to improve the precision of automated diagnosis in future medical applications.

Keywords: CNN; Pneumonia Classification; ResNet50V2; Transfer Learning; X-ray Images

1. Pendahuluan

Infeksi pada paru-paru yang disebabkan oleh berbagai mikroorganisme seperti bakteri, virus, dan jamur dikenal sebagai pneumonia[1], [2]. Penyakit ini dapat menyebabkan infeksi akut pada saluran pernapasan yang berdampak pada alveoli dan saluran udara jauh[3]. Selain itu, pneumonia merupakan masalah kesehatan penting di seluruh dunia dengan tingkat penyakit dan kematian yang tinggi di berbagai kelompok usia[4]. Oleh karena itu, diagnosis dini dan akurat sangat penting untuk penanganan yang cepat dan efektif[5], [6]. Dalam konteks ini, pemanfaatan

teknologi untuk membangun model yang dapat mengklasifikasi citra medis secara otomatis menjadi sangat dibutuhkan[7], [8].

Ahli medis menggunakan metode umum untuk mendeteksi pneumonia dengan menggunakan citra X-ray, yang memungkinkan visualisasi kondisi paru-paru dan mendeteksi tanda-tanda infeksi yang khas[9]. Namun, interpretasi citra X-ray secara manual memerlukan waktu dan dapat dipengaruhi oleh subjektivitas[10], [11]. Oleh karena itu, diperlukan pendekatan yang lebih efisien dan objektif dalam analisis citra[12] untuk meningkatkan akurasi diagnosis pneumonia[13].

Beragam penelitian mengenai deteksi pneumonia telah dilakukan. Md. Dendi Maysanjaya melaporkan metode CNN mampu mengklasifikasikan pneumonia pada citra X-ray dengan akurasi 89,58%[14]. Penelitian lain menggunakan pembelajaran mesin menunjukkan akurasi meningkat dari 64% pada Epoch 10 menjadi 87% pada Epoch 250[15]. Ahmad Naswin et al., menggunakan Algoritma Pohon Keputusan dan pra-pemrosesan seperti segmentasi Canny dan humoments, mencapai akurasi 82,72%[16]. Selain itu Bangare, S. L., et al., mengembangkan diagnosis otomatis menggunakan deep CNN dengan dataset X-Rayscan, mencapai akurasi 91%, dengan VGG16 memberikan hasil terbaik setelah optimasi[17].

Penelitian lain dalam deteksi pneumonia menggunakan KNN dengan ekstraksi fitur menggunakan Wiener Filter dan Gabor Filter mencapai akurasi 79,62%, precision hingga 91,15%, dan recall 65,61% untuk paru-paru normal, serta recall 93,63% untuk pneumonia[18]. Lusiana et al., menunjukkan potensi CNN dengan akurasi validasi 91% menggunakan 1.800 gambar normal dan 3.200 gambar pneumonia, meskipun memerlukan waktu pelatihan lama[19]. Sementara itu, Abdan Hafidh Ahnafi et al. menggunakan ResNet152 dengan transfer learning, oversampling, dan dropout, mencapai akurasi 89%, precision 0,88, recall 0,95, dan f1-score 0,92[20].

Berbagai studi telah menguji model transfer learning untuk klasifikasi penyakit paru-paru, seperti VGG19, MobileNetV2, InceptionResNetV2, dan ResNet. Hasil menunjukkan bahwa ResNet50V2 dan InceptionResNetV2 memiliki kinerja terbaik dalam mendeteksi COVID-19 pada gambar X-ray, dengan akurasi, precision, recall, dan F1-score yang tinggi[21]. Penelitian lain dimana model ResNet50V2 juga terbukti mampu mengidentifikasi nodul paru kecil jinak dan ganas dengan sensitivitas 0,964 dan spesifisitas 0,911.[22]. Selain itu, Model ResNet50V2 menunjukkan kemampuan klasifikasi yang kuat dalam mengidentifikasi penyakit ginjal, dengan tingkat akurasi yang mencolok sebesar 97%[23].


Beberapa penelitian sebelumnya telah menunjukkan efektivitas berbagai model deep learning. Meskipun model-model tersebut telah memberikan kontribusi yang signifikan, mereka sering mengalami kesulitan dalam menangani variasi citra yang besar, terutama pada kondisi citra dengan kualitas rendah atau distorsi akibat faktor teknis dan kompleksitas dataset, seperti variasi kualitas gambar, distribusi usia pasien, kebutuhan pengoptimalan parameter yang signifikan, dan memerlukan waktu pelatihan yang lama. Hal ini menyebabkan penurunan akurasi klasifikasi dan meningkatkan risiko kesalahan diagnosis.

Penelitian ini mengimplementasikan model ResNet50V2 untuk analisis citra X-ray medis, memanfaatkan arsitektur residualnya yang dalam dan efisien untuk menangani variasi citra yang kompleks. Keunggulan ResNet50V2 terletak pada kemampuannya mengekstraksi fitur yang lebih relevan, sehingga lebih efektif dibandingkan model-model sebelumnya yang terbatas dalam mengadaptasi variasi citra. Penelitian ini bertujuan untuk mengatasi kompleksitas dataset pneumonia, seperti variasi usia dan kualitas gambar, serta meningkatkan akurasi diagnosis melalui pendekatan otomatis yang lebih andal.

2. Metode Penelitian

Penelitian ini melibatkan beberapa tahap seperti pada Gambar 1 yang saling berhubungan. Tahap pertama adalah pengumpulan data, di mana peneliti mengidentifikasi dan mengumpulkan citra X-ray yang berlabel pneumonia dan normal. Setelah itu, Tahap pre-processing data melibatkan pembagian dataset menjadi set pelatihan, validasi, dan pengujian untuk memastikan evaluasi model yang independen. Transformasi data dilakukan dengan mereskalakan nilai piksel ke rentang [0, 1], serta augmentasi pada set pelatihan untuk meningkatkan variasi gambar. Teknik augmentasi meliputi rotasi acak hingga 20 derajat, pergeseran horizontal dan vertikal hingga 20%, zoom hingga 20%, distorsi geser 15%, dan flip horizontal. Teknik ini dipilih untuk menangani variasi posisi dan orientasi objek.


Selanjutnya, pada tahap modeling data, peneliti menggunakan model *Convolutional Neural Network* (CNN) Resnet50V2 dan VGG16 dengan menetapkan hyperparameter yang optimal, termasuk learning rate, batch size, dan jumlah epoch. Batch size 32 dipilih untuk efisiensi memori GPU, sedangkan learning rate dikelola secara dinamis menggunakan callback ReduceLROnPlateau untuk mencegah lokal minima atau divergensi. Optimizer Adam digunakan karena kemampuannya yang adaptif dan cepat mencapai konvergensi dibandingkan SGD, khususnya untuk model kompleks seperti ResNet50V2. Tahap terakhir adalah evaluasi, yang melibatkan tiga langkah utama: pertama, melakukan evaluasi kinerja model menggunakan metrik yang relevan, seperti akurasi, presisi, recall, F1-score, dan ROC-AUC.; kedua, menganalisis Confusion Matrix untuk mengetahui jumlah prediksi benar dan salah untuk setiap kelas; dan ketiga, melakukan pengujian pada test set untuk mengevaluasi kinerja akhir model pada data yang benar-benar baru dan tidak pernah dilihat selama pelatihan.



Gambar 1. Tahapan Penelitian

3. Hasil

Pada tahapan pengumpulan data dalam penelitian ini, data yang digunakan diperoleh dari dataset publik yang tersedia di platform Kaggle, khususnya dataset yang berisi gambar X-ray untuk klasifikasi pneumonia. Dataset ini terdiri dari dua kategori utama seperti yang ditunjukkan pada Gambar 2, yaitu pneumonia dan normal. Data yang digunakan memiliki resolusi gambar tertentu dan dalam format standar, seperti JPEG, yang cocok untuk pemrosesan citra. Pengumpulan data dilakukan dengan mengunduh dataset secara langsung dari situs web Kaggle Chest X-Ray Images (Pneumonia). Sebagai langkah tambahan, dataset tersebut telah dianonimkan dan disiapkan tanpa melibatkan data pribadi pasien, menjaga standar etika dalam penggunaan data medis.



Gambar 2. Citra X-Ray Paru-Paru

Pada tahap *pre-processing* data, dataset dibagi menjadi tiga bagian utama: data pelatihan, validasi, dan pengujian. Data pelatihan dan validasi diproses menggunakan ImageDataGenerator dengan augmentasi seperti rotasi acak, pergeseran horizontal dan vertikal, distorsi geser, pembesaran, dan pembalikan horizontal. Augmentasi ini bertujuan untuk meningkatkan keragaman data, sehingga model dapat belajar mengenali pola dari variasi gambar yang berbeda dan mengurangi risiko overfitting.

Sementara itu, data pengujian hanya dilakukan rescaling untuk menormalkan nilai piksel gambar antara 0 dan 1 tanpa augmentasi, agar hasil evaluasi model tetap adil. Semua gambar, baik untuk pelatihan, validasi, maupun pengujian, diubah ukurannya menjadi 224x224 piksel agar sesuai dengan input model.

Pada tahap modeling data, dilakukan persiapan arsitektur model Convolutional Neural Network (CNN) menggunakan transfer learning dengan ResNet50V2 dan VGG16 sebagai backbone. Kedua model dimuat tanpa lapisan atasnya dan menggunakan bobot pra-pelatihan dari ImageNet untuk mendalami fitur-fitur yang relevan dalam klasifikasi gambar. Pada ResNet50V2, dilakukan fine-tuning dengan membekukan semua lapisan kecuali 20 lapisan terakhir agar model dapat menyesuaikan diri dengan dataset spesifik untuk deteksi pneumonia. Sementara itu, pada VGG16, lapisan awal juga dibekukan, dengan tambahan lapisan kustom berupa GlobalAveragePooling2D, lapisan Dense (256 unit) dengan aktivasi ReLU, dan Dropout (0.3) untuk mengurangi risiko overfitting.

Layer (type)	Output Shape	Param #
input_layer_1 (InputLayer)	(None, 224, 224, 3)	0
resnet50v2 (Functional)	(None, 7, 7, 2048)	23,564,800
global_average_pooling2d (GlobalAveragePooling2D)	(None, 2048)	0
dense (Dense)	(None, 256)	524,544
dropout (Dropout)	(None, 256)	0
dense_1 (Dense)	(None, 1)	257

Total params: 24,089,601 (91.89 MB)

Trainable params: 8,404,481 (32.06 MB)

Non-trainable params: 15,685,120 (59.83 MB)

Gambar 3. Arsitektur Model ResNet50V2


Layer (type)	Output Shape	Param #
input_layer_1 (InputLayer)	(None, 224, 224, 3)	0
vgg16 (Functional)	(None, 7, 7, 512)	14,714,688
global_average_pooling2d (GlobalAveragePooling2D)	(None, 512)	0
dense (Dense)	(None, 256)	131,328
dropout (Dropout)	(None, 256)	0
dense_1 (Dense)	(None, 1)	257

Total params: 14,846,273 (56.63 MB)
Trainable params: 14,846,273 (56.63 MB)
Non-trainable params: 0 (0.00 B)


Gambar 4. Arsitektur Model VGG16

Arsitektur ResNet50V2 pada Gambar 3 dan arsitektur VGG16 pada Gambar 4 memiliki perbedaan signifikan dalam jumlah parameter, yaitu **24.089.601** untuk ResNet50V2 dan **14.846.273** untuk VGG16. ResNet50V2 lebih kompleks dengan residual connections untuk menangani fitur yang rumit, sementara VGG16 memiliki arsitektur yang lebih sederhana dan efisien. Perbedaan ini memengaruhi kebutuhan komputasi, dengan ResNet50V2 memerlukan waktu pelatihan yang lebih lama dibandingkan VGG16.

Kedua model kemudian dikompilasi menggunakan Adam sebagai optimizer dan binary cross-entropy sebagai fungsi loss, karena ini adalah masalah klasifikasi biner. Selama pelatihan, callback ReduceLROnPlateau diterapkan untuk menurunkan learning rate apabila validasi loss tidak menunjukkan perbaikan dalam beberapa epoch. Setelah model dilatih dengan generator data untuk pelatihan dan validasi selama 20 epoch dengan batchsize 32.



Gambar 5. Grafik Akurasi dan Loss Model ResNet50V2



Gambar 6. Grafik Akurasi dan Loss Model VGG16


Hasil pelatihan model VGG16 dan ResNet50V2 pada Gambar 5 dan Gambar 6 menunjukkan perbedaan yang signifikan dalam hal akurasi, loss, dan efisiensi pelatihan. Model VGG16 mencapai akurasi training sebesar 91,00% dan akurasi validasi tertinggi di 91,66%, dengan loss validasi mencapai 0,1928 pada epoch ke-19. Meskipun menunjukkan hasil yang baik, model ini cenderung lebih stabil, namun akurasi validasinya tidak setinggi ResNet50V2.

Di sisi lain, model ResNet50V2 menunjukkan akurasi training yang lebih tinggi, yaitu 98,65% pada epoch ke-19, dan akurasi validasi mencapai 99,14% pada epoch ke-17. Loss validasi yang dicapai lebih rendah, dengan nilai minimum 0,0397, menunjukkan kemampuan model untuk menangkap fitur lebih kompleks. Keunggulan lain dari ResNet50V2 adalah kemampuannya dalam mengurangi risiko overfitting berkat penggunaan residual connections yang mendukung generalisasi lebih baik.


Namun, VGG16 lebih efisien dalam hal waktu pelatihan karena memiliki jumlah parameter yang lebih sedikit (14,8 juta) dibandingkan dengan ResNet50V2 yang memiliki 24 juta parameter. Meskipun VGG16 lebih cepat dilatih, ResNet50V2 memberikan hasil yang lebih akurat, terutama pada data validasi.

4. Pembahasan

Pada tahap evaluasi, kedua model yang telah dilatih diuji menggunakan dataset pengujian untuk mengukur performanya. Proses dimulai dengan melakukan prediksi pada data pengujian menggunakan fungsi `model.predict()`, yang menghasilkan probabilitas prediksi untuk setiap gambar. Probabilitas tersebut kemudian dikonversi menjadi kelas biner (0 atau 1) berdasarkan ambang batas 0.5, di mana prediksi dengan probabilitas yang mencapai atau melebihi 0.5 diklasifikasikan sebagai kelas pneumonia (1), dan yang kurang dari 0.5 dianggap sebagai kelas normal (0). Selanjutnya, dilakukan perhitungan confusion matrix seperti yang ditunjukkan pada Gambar 5 untuk membandingkan prediksi model dengan nilai kebenaran yang sesungguhnya.



Gambar 7. Confusion Matrix Klasifikasi Pneumonia Model ResNet50V2



Gambar 8. Confusion Matrix Klasifikasi Pneumonia Model VGG16

Evaluasi hasil klasifikasi menggunakan model ResNet50V2 dan VGG16 menunjukkan perbedaan yang signifikan dalam performa dan pola kesalahan klasifikasi, yang dapat memengaruhi keputusan diagnostik dalam aplikasi medis. ResNet50V2 menunjukkan akurasi tinggi sebesar 97%, dengan True Positives (TP) sebanyak 49 gambar pneumonia yang diprediksi dengan benar sebagai pneumonia dan True Negatives (TN) sebanyak 48 gambar normal yang diklasifikasikan dengan benar sebagai normal. Model ini memiliki False Positives (FP) yang sangat rendah, hanya

2 gambar normal yang salah diklasifikasikan sebagai pneumonia, serta False Negatives (FN) sebanyak 1 gambar pneumonia yang salah diklasifikasikan sebagai normal. Precision model ini mencapai 96.1%, yang menunjukkan bahwa hampir semua gambar yang diprediksi sebagai pneumonia memang benar-benar pneumonia. Recall yang tinggi sebesar 98% menunjukkan kemampuan model ini yang sangat baik dalam mendeteksi pneumonia, dengan F1-Score sekitar 97.05% yang mencerminkan keseimbangan antara precision dan recall.

Berdasarkan confusion matrix untuk ResNet50V2, model ini menunjukkan performa yang sangat baik dengan jumlah kesalahan klasifikasi yang minim. FP yang terjadi pada 2 gambar normal dapat disebabkan oleh kesamaan visual antara gambar normal dan pneumonia, seperti noise atau variasi tekstur dan pencahayaan. Di sisi lain, FN yang hanya terjadi pada 1 gambar menunjukkan bahwa model ini jarang melewatkan deteksi pneumonia, meskipun kesalahan semacam ini tetap penting karena dapat menyebabkan keterlambatan diagnosis pada pasien yang seharusnya mendapatkan perawatan lebih cepat. Secara keseluruhan, ResNet50V2 lebih unggul dalam mengidentifikasi pneumonia dengan sangat sedikit kesalahan baik dalam kategori FP maupun FN.

Sebaliknya, model VGG16 memiliki akurasi yang lebih rendah, yaitu 92%, dengan TP sebanyak 48 gambar pneumonia yang diklasifikasikan dengan benar dan TN sebanyak 44 gambar normal. Namun, model ini menghasilkan FP yang lebih tinggi, yaitu 6 gambar normal yang salah diklasifikasikan sebagai pneumonia, serta FN sebanyak 2 gambar pneumonia yang salah diklasifikasikan sebagai normal. Precision model VGG16 berada di angka 88.89%, lebih rendah dibandingkan dengan ResNet50V2, yang mengindikasikan bahwa lebih banyak gambar normal salah diklasifikasikan sebagai pneumonia. Recall model ini tetap tinggi di angka 96%, menunjukkan bahwa sebagian besar gambar pneumonia berhasil terdeteksi dengan benar, dengan F1-Score sebesar 92.3%.

Confusion matrix untuk VGG16 memperlihatkan pola kesalahan yang berbeda. FP yang lebih tinggi menunjukkan kecenderungan model untuk mengklasifikasikan gambar normal sebagai pneumonia, yang dapat disebabkan oleh sensitivitas model terhadap pola atau fitur tertentu, seperti noise atau pencahayaan yang menyerupai gejala pneumonia. Selain itu, FN pada VGG16 yang terjadi pada 2 gambar pneumonia menunjukkan bahwa model ini sedikit lebih rentan gagal mendeteksi pneumonia dibandingkan ResNet50V2, yang dapat berisiko menunda penanganan pasien yang membutuhkan perhatian medis segera. Oleh karena itu, meskipun VGG16 cukup baik dalam mendeteksi pneumonia, model ini cenderung lebih sering menghasilkan diagnosis yang salah pada gambar normal, menjadikannya kurang ideal dibandingkan ResNet50V2 dalam aplikasi diagnostik.

5. Penutup

Penelitian ini berhasil mengimplementasikan metode Convolutional Neural Network (CNN) untuk klasifikasi pneumonia pada citra X-ray menggunakan transfer learning dengan arsitektur ResNet50V2. Hasil menunjukkan bahwa ResNet50V2 mampu mendeteksi pneumonia dengan akurasi validasi sebesar 99,14% dan akurasi pengujian sebesar 97%, dengan precision mencapai 96,1%, recall 98%, dan F1-Score 97,05%. Arsitektur ini menunjukkan kemampuan luar biasa dalam menangkap fitur kompleks pada citra X-ray, serta meminimalkan kesalahan klasifikasi.

Sebagai perbandingan, arsitektur VGG16 juga diterapkan untuk menunjukkan efisiensi dan kesederhanaan desain model dengan akurasi yang cukup baik. Namun, ResNet50V2 menghasilkan performa yang lebih optimal dalam hal akurasi, stabilitas, dan kemampuan generalisasi pada dataset yang digunakan.

Penelitian ini memberikan kontribusi pada literatur dengan memperkuat bukti bahwa transfer learning menggunakan ResNet50V2 adalah pendekatan yang efektif untuk klasifikasi citra medis, khususnya pada deteksi pneumonia. Hasil ini sejalan dengan studi sebelumnya yang menunjukkan bahwa arsitektur deep learning modern mampu menangkap pola yang signifikan

pada dataset terbatas, sekaligus menyoroti keunggulan transfer learning dalam memanfaatkan bobot pra-pelatihan untuk meningkatkan performa model pada tugas spesifik.

Hasil penelitian ini menunjukkan potensi ResNet50V2 sebagai metode yang andal dalam mendeteksi pneumonia pada citra X-ray. Model ini dapat menjadi dasar bagi pengembangan sistem pendukung diagnosa berbasis AI untuk membantu tenaga medis melakukan deteksi dini penyakit secara lebih akurat. Penelitian selanjutnya dapat memanfaatkan dataset yang lebih besar dan mengeksplorasi model lanjutan untuk memperluas cakupan dan keandalan aplikasi di dunia nyata.

Referensi

- [1] S. A. Aljawarneh and R. Al-Quraan, "Pneumonia Detection Using Enhanced Convolutional Neural Network Model on Chest X-Ray Images," *Big Data*, p., 2023, doi: 10.1089/big.2022.0261.
- [2] R. Bhuria, K. S. Gill, D. Upadhyay, and S. Devliyal, "Automated Pneumonia Detection from Chest X-Rays Using Convolutional Neural Networks: Advancements, Optimization, and Performance Analysis," in *2024 2nd International Conference on Sustainable Computing and Smart Systems (ICSCSS)*, 2024, pp. 1360–1364. doi: 10.1109/ICSCSS60660.2024.10624988.
- [3] S. Ramadasan, T. Manju, K. Vijayakumar, and S. Prabha, "Classification of Chest Radiographs into Normal and Pneumonia Class Using Fused Deep-Features," in *2024 Ninth International Conference on Science Technology Engineering and Mathematics (ICONSTEM)*, 2024, pp. 1–6. doi: 10.1109/ICONSTEM60960.2024.10568776.
- [4] A. Torres *et al.*, "Pneumonia," Dec. 01, 2021, *Nature Research*. doi: 10.1038/s41572-021-00259-0.
- [5] M. R. Hasan, S. M. A. Ullah, and M. Hasan, "Deep Learning in Radiology: A Transfer-Learning Based Approach for the Identification and Classification of COVID-19 and Pneumonia in Chest X-ray Images," in *2023 Fourth International Conference on Smart Technologies in Computing, Electrical and Electronics (ICSTCEE)*, 2023, pp. 1–6. doi: 10.1109/ICSTCEE60504.2023.10585226.
- [6] K. K. L, R. Rajalakshmi, K. Ramalakshmi, A. Lakshmi, G. Subhashini, and G. Theivanathan, "Enhancing Pneumonia Detection Through Convolutional Neural Networks and Data Augmentation In Chest X-Ray Imaging," in *2024 10th International Conference on Advanced Computing and Communication Systems (ICACCS)*, 2024, pp. 715–718. doi: 10.1109/ICACCS60874.2024.10717046.
- [7] A. Mabrouk, R. P. D. Redondo, A. Dahou, M. A. Elaziz, and M. Kayed, "Pneumonia Detection on Chest X-ray Images Using Ensemble of Deep Convolutional Neural Networks," *Applied Sciences (Switzerland)*, vol. 12, no. 13, Jul. 2022, doi: 10.3390/app12136448.
- [8] M. Singla, K. S. Gill, S. Malhotra, and S. Devliyal, "Chest X-ray Image Pneumonia Detection using Transfer Learning and Xception CNN Model," in *2024 International Conference on Intelligent Systems for Cybersecurity (ISCS)*, 2024, pp. 1–5. doi: 10.1109/ISCS61804.2024.10581194.
- [9] H. Liz, M. A. Sánchez-Montañés, A. Tagarro, S. Domínguez-Rodríguez, R. Dagan, and D. Camacho, "Ensembles of Convolutional Neural Network models for pediatric pneumonia diagnosis," *Future Gener. Comput. Syst.*, vol. 122, pp. 220–233, 2020, doi: 10.1016/j.future.2021.04.007.

- [10] G. Vrbancic and V. Podgorelec, "Efficient ensemble for image-based identification of Pneumonia utilizing deep CNN and SGD with warm restarts," *Expert Syst. Appl.*, vol. 187, p. 115834, 2022, doi: 10.1016/j.eswa.2021.115834.
- [11] V. Kant, "A Comprehensive CNN-based Approach to Pneumonia Detection," in *2024 5th International Conference on Smart Electronics and Communication (ICOSEC)*, 2024, pp. 958–963. doi: 10.1109/ICOSEC61587.2024.10722467.
- [12] A. A. Handoko, M. A. Rosid, and U. Indahyanti, "Implementasi Convolutional Neural Network (CNN) Untuk Pengenalan Tulisan Tangan Aksara Bima," *SMATIKA JURNAL*, vol. 14, no. 01, pp. 96–110, Jul. 2024, doi: 10.32664/smatika.v14i01.1196.
- [13] M. R. Kumar and B. G. Vani, "Implementation of Deep Learning Mechanisms for Detection and Classification of Pneumonia on Chest X-Ray Dataset," in *2024 International Conference on Computational Intelligence for Green and Sustainable Technologies (ICCGST)*, 2024, pp. 1–6. doi: 10.1109/ICCGST60741.2024.10717560.
- [14] I. M. Dendi Maysanjaya, "Klasifikasi Pneumonia pada Citra X-rays Paru-paru dengan Convolutional Neural Network (Classification of Pneumonia Based on Lung X-rays Images using Convolutional Neural Network)," 2020.
- [15] J. Mantik, B. Imran, and L. Darmawan Bakti, "Implementation of Machine Learning Model for Pneumonia Classification Based on X-Ray Images," 2021.
- [16] Ahmad Naswin and Adityo Permana Wibowo, "Performance Analysis of the Decision Tree Classification Algorithm on the Pneumonia Dataset," *International Journal of Artificial Intelligence in Medical Issues*, vol. 1, no. 1, pp. 1–9, May 2023, doi: 10.56705/ijaimi.v1i1.83.
- [17] Dr. Sunil L. Bangare, Hrushikesh S. Rajankar, Pavan S. Patil, Karan V. Nakum, and Gopal S. Paraskar, "Pneumonia Detection and Classification using CNN and VGG16," *International Journal of Advanced Research in Science, Communication and Technology*, pp. 771–779, May 2022, doi: 10.48175/ijarsct-3851.
- [18] F. Antony, H. Irsyad, M. Ezar, and A. Rivan, "KNN Dan Gabor Filter Serta Wiener Filter Untuk Mendiagnosis Penyakit Pneumonia Citra X-RAY Pada Paru-Paru," *Jurnal Algoritme*, vol. 1, no. 2, pp. 147–155, 2021.
- [19] Lusiana, A. A. Kurniasari, and I. F. Kusumawati, "Enhancing Accuracy in the Detection of Pneumonia in Adult Patients: An Approach by Using Convolutional Neural Networks," in *Lecture Notes in Electrical Engineering*, Springer Science and Business Media Deutschland GmbH, 2024, pp. 593–609. doi: 10.1007/978-981-97-1463-6_41.
- [20] A. Hafidh, A. #1, A. Arifianto, K. Nur, and R. #3, "Pneumonia Classification from X-ray Images using Residual Neural Network OPEN ACCESS," *Journal on Computing*, vol. 5, no. 2, pp. 43–54, 2020, doi: 10.21108/indojc.2020.5.2.454.
- [21] M. Harahap, Em Manuel Laia, Lilis Suryani Sitanggang, Melda Sinaga, Daniel Franci Sihombing, and Amir Mahmud Husein, "Deteksi Penyakit Covid-19 Pada Citra X-Ray Dengan Pendekatan Convolutional Neural Network (CNN)," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 6, no. 1, pp. 70–77, Feb. 2022, doi: 10.29207/resti.v6i1.3373.
- [22] W. Li *et al.*, "Machine Learning Model of ResNet50-Ensemble Voting for Malignant–Benign Small Pulmonary Nodule Classification on Computed Tomography Images," *Cancers (Basel)*, vol. 15, no. 22, Nov. 2023, doi: 10.3390/cancers15225417.
- [23] K. S. Gill, V. Anand, R. Chauhan, R. S. Rawat, and R. Gupta, "Kidney Disease X-Ray Image Classification Using a ResNet50V2 Model based Machine Learning Approach," in *2023 2nd*

International Conference on Futuristic Technologies (INCOFT), 2023, pp. 1–5. doi: 10.1109/INCOFT60753.2023.10425099.