

Penerapan Machine Learning Dalam Sistem Klasifikasi Paru-paru Yang Terkena Pneumonia Menggunakan Model Convolutional Neural Network (CNN) Dengan Tensorflow

Sitti Khairunnisak¹, Anang Habibi, S.ST., M.T.², M. Jasa Afroni, S.ST., M.T., P.hD.³

¹Universitas Islam Malang

²Universitas Islam Malang

22101053032@unisma.ac.id¹, ananghabibi@unisma.ac.id², jasa.afroni@unisma.ac.id³

Abstract

Pneumonia is a lower respiratory tract infection that can be fatal, especially in children and the elderly, with symptoms that often resemble other pulmonary diseases, making diagnosis challenging. This study develops a deep learning model based on Convolutional Neural Network (CNN) to detect pneumonia from chest X-ray images. The dataset consists of 8,864 images, evenly distributed between 4,432 normal and 4,432 pneumonia cases. The initial CNN model achieved an accuracy of 91.4%, precision of 91.7%, recall of 97.3%, and F1-score of 94.4%. To improve performance, a deeper architecture, Residual Network (ResNet), was implemented, achieving an accuracy of 92.8%, precision of 93.3%, recall of 98.3%, and F1-score of 95.7%. These results indicate that both models are effective for classifying chest X-ray images, with ResNet offering more stable and optimal performance.

Keywords— Pneumonia, Machine Learning, ResNet, CNN, Classification

Abstrak

Pneumonia adalah infeksi saluran pernapasan bawah yang berpotensi fatal, terutama pada anak-anak dan lansia, dengan gejala mirip penyakit paru lain sehingga menyulitkan diagnosis. Penelitian ini mengembangkan model deep learning berbasis Convolutional Neural Network (CNN) untuk mendeteksi pneumonia dari citra X-ray dada. Dataset terdiri dari 8.864 gambar, 4.432 normal dan 4.432 pneumonia terbagi seimbang antara kondisi normal dan pneumonia. Model CNN awal mencapai akurasi 91,4%, presisi 91,7%, recall 97,3%, dan F1-score 94,4%. Untuk peningkatan performa, digunakan arsitektur ResNet yang lebih dalam, menghasilkan akurasi 92,8%, presisi 93,3%, recall 98,3%, dan F1-score 95,7%. Hasil ini menunjukkan bahwa kedua model efektif dalam klasifikasi citra X-ray, dengan ResNet memberikan performa yang lebih stabil dan optimal.

Kata Kunci— Pneumonia, Pembelajaran mesin, ResNet, CNN, Klasifikasi

I. PENDAHULUAN

Pneumonia merupakan penyakit infeksi saluran pernapasan bagian bawah, ditandai dengan gejala seperti batuk, sesak napas, demam, nyeri dada, serta kelelahan. Penyakit ini menjadi perbincangan hangat di media sosial dan disebabkan oleh berbagai agen infeksius, termasuk virus, bakteri, jamur (mycoplasma), serta aspirasi zat asing yang dapat mengakibatkan penumpukan cairan dan bercak-bercak di paru-paru. Pneumonia termasuk dalam kategori infeksi akut yang terjadi pada jaringan paru-paru, khususnya di alveoli, dan dapat disebabkan oleh berbagai mikroorganisme, baik virus, bakteri, jamur, maupun mikroorganisme lainnya. Pneumonia dapat berakibat fatal, terutama pada anak-anak dan lansia.

Diagnosis pneumonia yang sering kali menghadapi tantangan karena kesamaan gejala dengan penyakit paru lainnya, seperti tuberkulosis dan kanker paru. Solusi mengatasi masalah ini, perkembangan teknologi Computer Aided Diagnostic (CAD) menggunakan metode machine learning, khususnya deep learning, semakin banyak diterapkan dalam analisis citra medis.

Convolutional Neural Network (CNN) adalah salah satu arsitektur deep learning yang efektif dalam mengklasifikasikan citra X-ray dan mendeteksi pneumonia dengan akurasi tinggi. Penelitian ini bertujuan mengembangkan model CNN untuk

mendeteksi pneumonia pada citra X-ray dada. Model ini memanfaatkan lapisan konvolusi, normalisasi batch, pooling, dan dropout untuk meningkatkan akurasi serta mencegah overfitting. Dataset yang digunakan diambil dari Kaggle yang sumbernya diambil dari pasien anak-anak berusia 1 hingga 5 tahun di *Guangzhou Women and Children's Medical Center, Guangzhou, Tiongkok*. Seluruh gambar diperoleh secara retrospektif dari arsip klinik sebagai bagian dari pemeriksaan medis rutin pasien.


Gambar-gambar tersebut telah melalui proses kurasi kualitas, di mana citra yang tidak terbaca atau berkualitas rendah dihapus. terdiri dari 8.864 gambar X-ray, yang meliputi 4.432 gambar normal dan 4.432 gambar pneumonia. Metode diharapkan, ini dapat mempercepat dan meningkatkan akurasi diagnosis pneumonia, membantu tenaga medis dalam pengambilan keputusan.



Gambar 1. Atas normal bawah pneumonia


II. METODE PENELITIAN

Penelitian ini bertujuan mengembangkan sistem klasifikasi citra X-ray pneumonia menggunakan Convolutional Neural Networks (CNN).



Gambar 2. Desain system klasifikasi

Proses dimulai dengan Masukan (Input), di mana data gambar X-ray dimasukkan ke dalam sistem. Lembar Data (Datasheet) berisi label yang menunjukkan apakah gambar tersebut menunjukkan pneumonia atau tidak. Data ini digunakan dalam tahap Pelatihan & Validasi (Training & Validation) untuk melatih model CNN, dengan validasi untuk mencegah overfitting. Model CNN belajar mengenali pola-pola pneumonia dari gambar. Setelah pelatihan, model digunakan untuk Klasifikasi Pneumonia (Pneumonia Classification) pada gambar baru. Kemudian, model diuji dengan data yang belum pernah dilihat pada Pengujian (Testing) dan hasilnya dievaluasi dengan metrik seperti akurasi dan F1-score pada tahap Evaluasi & Uji Akurasi (Evaluation & Accuracy Test). Proses berakhir pada Selesai (End).



Gambar 3. Arsitektur CNN

Proses dimulai dengan Input, di mana gambar masukan dengan dimensi tertentu (misalnya, 224x224 piksel) akan diterima oleh jaringan. Kemudian, lapisan Convolution melakukan konvolusi dengan filter untuk mengekstrak fitur penting dari citra, menghasilkan feature maps yang merepresentasikan berbagai fitur yang ada pada citra tersebut. Setelah itu, lapisan ReLU (Rectified Linear Unit) diterapkan untuk memperkenalkan non-linearitas dalam model dengan

mengubah nilai negatif menjadi nol, mempercepat pelatihan, dan meningkatkan kinerja jaringan.

Selanjutnya, lapisan Pooling digunakan untuk mengurangi dimensi spasial dari feature maps, yang bertujuan untuk mengurangi jumlah komputasi, mempercepat pelatihan, serta membuat model lebih tahan terhadap perubahan posisi fitur dalam citra. Proses ini diulang dengan lapisan Convolution + ReLU untuk mengekstrak fitur yang lebih kompleks dan lapisan Pooling berikutnya untuk kembali mengurangi dimensi spasial. Setelah beberapa tahap ekstraksi fitur, lapisan Flatten meratakan hasil dari feature maps 2D menjadi vektor 1D, mempersiapkan data untuk dimasukkan ke dalam lapisan Fully Connected, yang berfungsi untuk melakukan klasifikasi berdasarkan fitur yang telah diekstrak. Pada lapisan terakhir, Softmax digunakan untuk menghasilkan probabilitas setiap kelas, memberikan output berupa vektor probabilitas yang menunjukkan kemungkinan citra termasuk dalam kelas tertentu, seperti "normal", "pneumonia", atau kategori lainnya.

Tabel 1. Ringkasan parameter CNN


Layer (type)	Output Shape	Param #
input_layer (InputLayer)	(None, 224, 224, 1)	0
conv2d (Conv2D)	(None, 222, 222, 16)	160
batch_normalization	(None, 222, 222, 16)	64
max_pooling2d	(None, 111, 111, 16)	0
dropout (Dropout)	(None, 111, 111, 16)	0
conv2d_1 (Conv2D)	(None, 109, 109, 32)	4,640
batch_normalization	(None, 109, 109, 32)	128
activation_1 (Activation)	(None, 109, 109, 32)	0
max_pooling2d_1	(None, 52, 52, 32)	0
Dropout_1 (Dropout)	(None, 52, 52, 32)	0
conv2d_2 (Conv2D)	(None, 52, 52, 64)	18,496
batch_normalization	(None, 52, 52, 64)	256
activation_2 (Activation)	(None, 52, 52, 64)	0
max_pooling2d	(None, 26, 26, 64)	0

(MaxPooling2D)	64)	
Dropout_2 (Dropout)	(None, 26, 26, 64)	0
flatten (Flatten)	(None, 43264)	0
dense (Dense)	(None, 64)	2,768,96
dropout_3 (Dropout)	(None, 64)	0
Dense_1 (Dense)	(None, 1)	65

III. HASIL DAN PEMBAHASAN

Pada tahap pengujian model, citra yang digunakan dalam pelatihan memiliki ukuran 224x224 piksel dengan tiga saluran warna RGB. Batch size yang diterapkan adalah 32, yang menunjukkan jumlah sampel yang diproses dalam satu iterasi sebelum pembaruan bobot model. Untuk memastikan hasil eksperimen yang konsisten, peneliti menetapkan SEED 42, yang menjamin eksperimen dapat diulang dengan hasil yang sama meskipun dilakukan di waktu atau platform yang berbeda.

Pemilihan jumlah epoch juga sangat penting dalam pengujian ini untuk menghindari masalah underfitting atau overfitting. Underfitting terjadi jika model tidak cukup memahami data karena epoch yang terlalu sedikit, sementara overfitting muncul ketika model menghafal data pelatihan secara berlebihan dan kesulitan dalam menggeneralisasi data baru, seperti gambar dibawah ini.




Gambar 4. Overfitting & underfitting

Pengujian dilakukan setiap 10 epoch, dari epoch ke-10 hingga ke-100, untuk mencari jumlah epoch yang optimal yang menghasilkan keseimbangan antara akurasi pelatihan dan pengujian serta nilai kesalahan (loss) pada kedua fase tersebut. Hasil pengujian menunjukkan bahwa pada epoch ke-50, model CNN menunjukkan performa yang baik dengan Test Accuracy sebesar 94.63% dan Val Accuracy 95.33%. Model terus meningkat dan mencapai performa terbaik pada epoch ke-100, dengan Test Accuracy 95.08% dan Val Accuracy 95.73%. Meskipun terjadi penurunan kecil pada akurasi dan loss setelah epoch ke-100, model tetap stabil dan menunjukkan hasil yang sangat baik, seperti diperlihatkan tabel 1 dan gambar grafik dibawah ini.

Tabel 2. Hasil pengujian dan pelatihan CNN

Epoch	Test Accuracy	Test loss	Val loss	Val accuracy
10	0.9369	0.1902	0.1931	0.9437
20	0.9425	0.1671	0.1758	0.9483
30	0.9431	0.1621	0.1673	0.9498
40	0.9447	0.1579	0.1604	0.9524
50	0.9463	0.1540	0.1547	0.9533
60	0.9480	0.1500	0.1507	0.9543
70	0.9488	0.1482	0.1490	0.9552
80	0.9497	0.1468	0.1475	0.9561
90	0.9503	0.1460	0.1462	0.9569
100	0.9508	0.1451	0.1455	0.9573



Gambar 5. Hasil pengujian dan pelatihan epoch 100

Dari hasil tersebut, dapat disimpulkan bahwa model CNN tidak mengalami overfitting, namun justru semakin memperbaiki akurasi seiring bertambahnya epoch. Pada epoch awal, seperti epoch ke-10, akurasi pengujian masih berada di angka 94.37%, namun seiring berjalannya waktu, akurasi terus meningkat, yang menunjukkan bahwa model berhasil mempelajari pola data dengan baik. Secara keseluruhan, eksperimen ini menunjukkan bahwa model CNN dapat mengoptimalkan akurasi tanpa mengalami overfitting, dengan perbedaan akurasi pelatihan dan pengujian yang sangat kecil. Nilai loss yang rendah juga menandakan bahwa model mampu mengenali data pengujian dengan baik, yang menunjukkan bahwa model ini cukup efektif untuk klasifikasi citra.


	precision	recall	f1-score	support
Pneumonia (Class 0)	0.83	0.60	0.70	65
Normal (Class 1)	0.92	0.97	0.94	296
accuracy			0.91	361
macro avg	0.87	0.79	0.82	361
weighted avg	0.90	0.91	0.90	361

Gambar 6. hasil prediksi matriks CNN

Model klasifikasi ini menunjukkan kinerja yang sangat baik dengan akurasi 91.4%, presisi 91.7%, dan recall 97.3%. Ini berarti model berhasil mendeteksi

hampir semua kasus pneumonia tanpa banyak kesalahan dalam memprediksi data normal. F1-Score yang tinggi (0.944) menandakan keseimbangan yang baik antara presisi dan recall, menjadikan model ini sangat efektif dalam memisahkan data normal dan pneumonia. Secara keseluruhan, model ini memiliki performa yang kuat dan dapat diandalkan untuk deteksi pneumonia.

Dalam penelitian ini, dilakukan pendekatan *transfer learning* dengan menggunakan arsitektur ResNet sebagai model dasar untuk meningkatkan akurasi klasifikasi. Pemilihan ResNet didasarkan pada kemampuannya dalam mengekstraksi fitur yang kompleks melalui penggunaan *residual block*, sehingga memungkinkan pelatihan model yang lebih dalam tanpa mengalami degradasi performa. Strategi ini terbukti efektif dalam meningkatkan kinerja model pada data citra medis yang memiliki kompleksitas tinggi. Adapun parameter model yang digunakan terdapat ditabel bawah ini.



Gambar 7. Arsitektur ResNet

Model menggunakan arsitektur ResNet152V2 sebagai ekstraktor fitur, menghasilkan feature maps berdimensi 2048 kanal. Fitur ini kemudian diratakan dan diproses melalui lapisan dense berlapis dengan dropout untuk mencegah overfitting. Lapisan output menggunakan fungsi aktivasi sigmoid untuk menghasilkan probabilitas klasifikasi.

Tabel 3. Ringkasan parameter ResNet

Layer	Output Shape	Param
input_layer (InputLayer)	(None, 224, 224, 3)	0
resnet152v2 (Functional)	(None, 7, 7, 2048)	58,331,648
global_average_pooling2d (GlobalAveragePooling2D)	(None, 2048)	0
dense (Dense)	(None, 128)	262,272
dropout (Dropout)	(None, 128)	0
dense_1 (Dense)	(None, 1)	129
Total params: 58,594,049 (223.52 MB)		
Trainable params: 262,401 (1.00 MB)		

Non-trainable params: 58,331,648 (222.52 MB)

Tabel 4. Hasil pengujian dan pelatihan ResNet


Epoch	Test Accuracy	Test loss	Val loss	Val accuracy
10	0.9576	0.1243	0.1146	0.9570
20	0.9723	0.0999	0.0686	0.9734
30	0.9857	0.0368	0.0416	0.9846
40	0.9894	0.0276	0.0442	0.9844
50	0.9920	0.0215	0.0285	0.9885
60	0.9946	0.0164	0.0120	0.9968
70	0.9911	0.0265	0.0267	0.9917
80	0.9948	0.0132	0.0166	0.9942
90	0.9963	0.0101	0.0491	0.9910
100	0.9963	0.0100	0.0069	0.9994

```
[ ] print(classification_report(y_test, pred_labels, target_names = ['Pneumonia (Class 0)', 'Normal'])
```


	precision	recall	f1-score	support
Pneumonia (Class 0)	0.98	0.68	0.77	65
Normal (Class 1)	0.93	0.98	0.96	296
accuracy	0.92	0.83	0.93	361
macro avg	0.92	0.83	0.86	361
weighted avg	0.93	0.93	0.92	361

Gambar 8. Hasil prediksi matriks ResNet

Model klasifikasi menunjukkan performa yang baik dengan akurasi sebesar 92,8%. Nilai presisi sebesar 93,3% dan recall sebesar 98,3% mengindikasikan kemampuan model dalam mendeteksi kasus positif secara akurat dan konsisten. F1-score yang tinggi (95,7%) mencerminkan keseimbangan yang optimal antara presisi dan recall, menandakan bahwa model mampu mengklasifikasikan data dengan baik dan andal.



Gambar 9. hasil uji citra normal



Gambar 10. hasil uji citra pneumonia

Sistem ini menunjukkan kinerja sangat baik dalam mendeteksi pneumonia dan normal. Model berhasil mengidentifikasi citra pneumonia dengan akurasi tinggi, serta mendeteksi normal dengan presisi yang sama, menunjukkan kinerja model yang konsisten ini menegaskan bahwa sistem mampu melakukan klasifikasi dengan akurat pada kedua kondisi tersebut.

IV. KESIMPULAN

Penelitian ini berhasil mengembangkan model Convolutional Neural Network (CNN) untuk klasifikasi citra X-ray paru-paru dalam mendeteksi pneumonia. Model CNN menghasilkan akurasi sebesar 91,4%, dengan presisi 91,7%, recall 97,3%, dan F1-score 94,4%. Sementara itu, model ResNet sebagai arsitektur yang lebih dalam menunjukkan hasil yang lebih optimal, dengan akurasi 92,8%, presisi 93,3%, recall 98,3%, dan F1-score 95,7%. Hasil ini menunjukkan bahwa baik CNN maupun ResNet efektif dalam mendeteksi pneumonia melalui citra X-ray, dengan ResNet menunjukkan keseimbangan performa yang lebih akurat. Sistem ini dapat menjadi solusi pendukung diagnosis medis yang cepat dan akurat.

DAFTAR PUSTAKA

- UNICEF Indonesia, “Kenali 6 Fakta tentang Pneumonia pada Anak Semua hal yang perlu Anda ketahui tentang pneumonia pada anak,” [unicef.org](https://www.unicef.org/indonesia/id/kesehatan/cerita/kenali-6-fakta-tentang-pneumonia-pada-anak?gad_source=1). Accessed: Dec. 26, 2024. [Online]. Available: https://www.unicef.org/indonesia/id/kesehatan/cerita/kenali-6-fakta-tentang-pneumonia-pada-anak?gad_source=1
- D. Gunawan and H. Setiawan, “Convolutional Neural Network dalam Analisis Citra Medis,” 2022.
- [1] I. Bakti, M. Firdaus, and S. Artikel, “Arsitektur Convolutional Neural Network InceptionResNet-V2 Untuk Pengelompokan Pneumonia Chest X-Ray INFO ARTIKEL ABSTRAK,” Daerah Khusus Ibukota Jakarta, vol. 12530, no. 77, pp. 35–42, 2023, [Online]. Available: <https://doi.org/10.58290/jukomtek>.
- B. Nugroho and E. Y. Puspaningrum, “Kinerja Metode CNN untuk Klasifikasi Pneumonia dengan Variasi Ukuran Citra Input,” *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 8, no. 3, pp. 533–538, 2021, doi: 10.25126/jtiik.2021834515.
- [2] I. Md. D. Maysanjaya, “Klasifikasi Pneumonia pada Citra X-rays Paru-paru dengan Convolutional Neural Network,” *Jurnal Nasional Teknik Elektro dan Teknologi Informasi*, vol. 9, no. 2, pp. 190–195, 2020, doi: 10.22146/jnteti.v9i2.66.
- [3] 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, 2022, doi: 10.29207/resti.v6i1.3373.
- Bambang Pulu Hartato, “Penerapan Convolutional Neural Network pada Citra Rontgen Paru-Paru untuk Deteksi SARS-CoV-2,” *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 5, no. 4, pp. 747–759, 2021, doi: 10.29207/resti.v5i4.3153.
- H. Herdianto and D. Nasution, “Implementasi Metode Cnn Untuk Klasifikasi Objek,” *METHOMIKA Jurnal Manajemen Informatika dan Komputerisasi Akuntansi*, vol. 7, no. 1, pp. 54–60, 2023, doi: 10.46880/jmika.vol7no1.pp54-60.
- R. Atunnisa and R. Sumiharto, “Pneumonia Detection Using Extraction Features Oriented Fast and Rotated Brief and Convolutional Neural Network,” vol. 7, no. 4, pp. 103–107, 2022.
- [4] A. A. Kurniawan and M. Mustikasari, “Implementasi Deep Learning Menggunakan Metode CNN dan LSTM untuk Menentukan Berita Palsu dalam Bahasa Indonesia,” *Jurnal Informatika Universitas Pamulang*, vol. 5, no. 4, p. 544, 2021, doi: 10.32493/informatika.v5i4.6760.
- [5] V. Maha, P. Salawazo, D. Putra, J. Gea, R. F. Gea, and F. Azmi, “Terakreditasi DIKTI No.SK 1,2,3 Mahasiswa Teknik Informatika,” *Indonesia Jalan Sekip Sikambing*, vol. 3, no. 1, pp. 74–79, 2019.
- [6] P. Adi Nugroho, I. Fenriana, and R. Arijanto, “IMPLEMENTASI DEEP LEARNING MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK (CNN) PADA EKSPRESI MANUSIA,” *JURNAL ALGOR*, vol. 2, no. 1, 2020, [Online]. Available: <https://jurnal.buddhidharma.ac.id/index.php/algor/index>
- J. Vicky, F. Ayu, and B. Julianto, “Implementasi Pendeteksi Penyakit pada Daun Alpukat Menggunakan Metode CNN.”
- J. Yopento, E. Ernawati, and F. F. Coastera, “Identifikasi Pneumonia Pada Citra X-Ray Paru-Paru Menggunakan Metode Convolutional Neural Network (CNN) Berdasarkan Ekstraksi Fitur Sobel,” *Rekursif: Jurnal Informatika*, vol. 10, no. 1, pp. 40–47, 2022, doi: 10.33369/rekursif.v10i1.17247.
- wikipedia, “Wilhelm Conrad Röntgen,” [wikipedia.org](https://www.wikipedia.org). Accessed: Dec. 26, 2024. [Online]. Available:

- https://id.wikipedia.org/wiki/Wilhelm_Conrad_R%C3%B6ntgen
- B. M. Sapata and D. Juniati, “RAY THORAX MENGGUNAKAN METODE FRAKTAL BOX COUNTING”.
- Paul Mooney, “Chest X-Ray Images (Pneumonia),” kaggle.com. Accessed: Dec. 26, 2024. [Online]. Available:
<https://www.kaggle.com/datasets/paultimothymooney/chest-xray-pneumonia>
- Jan Wira Gotama Putra, Pengenalan Konsep Pembelajaran Mesin dan Deep Learning, 4th ed., vol. 1. Tokyo, Jepang: Jan Wira Gotama Putra, 2020.