

Pengaruh Teknik Pre-Processing Citra X-Ray terhadap Performa ResNet18 dalam Klasifikasi Penyakit Paru-Paru

^{1*}Alvino Graha Nusantara, ²Ratih Kumalasari Niswatin,
³Danar Putra Pamungkas

^{1,2,3}Teknik Informatika, Universitas Nusantara PGRI Kediri
E-mail: ¹alvinograha98@gmail.com, ²ratih.workmail@gmail.com,
³danar@unpkediri.ac.id

Penulis Korespondens : Alvino Graha Nusantara

Abstrak—Kanker paru-paru merupakan penyakit dengan tingkat kematian tertinggi yang membutuhkan deteksi dini untuk meningkatkan peluang kesembuhan pasien. Penggunaan citra X-ray dada sering terkendala masalah kontras rendah dan *noise*. Penelitian ini bertujuan menganalisis pengaruh penerapan teknik *pre-processing* citra terhadap performa model ResNet18 dalam mengklasifikasikan kelainan paruparu menggunakan 3.475 data dari Kaggle. Tahapan *pre-processing* yang diterapkan meliputi *grayscale conversion*, *resizing*, *CLAHE*, *normalization*, dan *Gaussian Filtering*. Hasil penelitian menunjukkan bahwa penerapan *pre-processing* berhasil meningkatkan performa model secara konsisten, dengan nilai akurasi meningkat dari 85,0% menjadi 87,5%, presisi menjadi 90,2%, *recall* menjadi 85,3%, dan *F1-score* menjadi 87,6%. Model juga menunjukkan tingkat kepercayaan prediksi mencapai 99,01% dengan waktu pemrosesan efisien sebesar 1,391 detik. Kesimpulannya, pengondisian data masukan terbukti secara signifikan mengoptimalkan ekstraksi fitur visual model sehingga sangat potensial diimplementasikan sebagai alat bantu triase medis yang cepat dan akurat.

Kata Kunci—Citra X-ray, Deep Learning, Kanker Paru-Paru, Pre-processing, ResNet18

Abstract—Lung cancer is a disease with the highest mortality rate that requires early detection to improve patient survival chances. The utilization of chest X-ray images is frequently hindered by low contrast and noise problems. This study aims to analyze the effect of implementing image pre-processing techniques on the ResNet18 model performance in classifying lung abnormalities using 3,475 data from Kaggle. The applied pre-processing stages include grayscale conversion, resizing, CLAHE, normalization, and Gaussian Filtering. The results show that pre-processing successfully enhances model performance consistently, with accuracy increasing from 85.0% to 87.5%, precision to 90.2%, recall to 85.3%, and F1score to 87.6%. The model also demonstrates a prediction confidence level of 99.01% with an efficient processing time of 1.391 seconds. In conclusion, input data conditioning is proven to significantly optimize the model visual feature extraction, making it highly potential for implementation as a fast and accurate medical triage tool.

Keywords—Deep Learning, Image X-ray, Lung Cancer, Pre-processing, ResNet18

This is an open access article under the CC BY-SA License.



I. PENDAHULUAN

Kanker paru-paru merupakan salah satu penyakit dengan tingkat kematian tertinggi di dunia dan menjadi penyebab utama kematian akibat kanker setiap tahunnya. Tingginya angka kematian tersebut disebabkan karena sebagian besar kasus baru terdeteksi pada stadium lanjut, sehingga peluang keberhasilan pengobatan menjadi lebih rendah. Oleh karena itu, deteksi dini kanker paru-paru sangat penting untuk meningkatkan peluang kesembuhan pasien dan mengurangi angka kematian akibat penyakit tersebut [1].

Salah satu metode pencitraan medis yang umum digunakan untuk mendeteksi kelainan paru-paru adalah citra X-ray dada (chest X-ray). Pemeriksaan X-ray memiliki beberapa keunggulan, seperti biaya yang relatif murah, proses pemeriksaan yang cepat, serta mampu memberikan gambaran anatomi paru secara menyeluruh. Namun, interpretasi citra X-ray masih sangat bergantung pada kemampuan dan pengalaman radiolog. Faktor subjektivitas, kelelahan, serta kualitas citra yang tidak konsisten dapat menyebabkan kesalahan diagnosis, terutama pada tahap awal penyakit ketika tanda kelainan masih sulit dikenali [2].

Perkembangan teknologi kecerdasan buatan, khususnya Deep Learning, memberikan peluang besar dalam membantu proses analisis citra medis secara otomatis. Salah satu metode Deep Learning yang banyak digunakan dalam pengolahan citra adalah Convolutional Neural Network (CNN), karena memiliki kemampuan yang baik dalam mengekstraksi fitur visual secara otomatis. Arsitektur CNN yang populer dan efektif untuk klasifikasi citra medis adalah ResNet18. Model ini memiliki konsep residual learning yang mampu mengatasi masalah vanishing gradient sehingga proses pelatihan jaringan menjadi lebih stabil dan efisien. Selain itu, ResNet18 memiliki kompleksitas komputasi yang relatif ringan dibandingkan arsitektur deep learning lainnya, namun tetap mampu menghasilkan performa klasifikasi yang baik [3].

Meskipun demikian, performa model CNN sangat dipengaruhi oleh kualitas citra masukan. Pada citra X-ray paru-paru sering ditemukan beberapa permasalahan seperti kontras rendah, noise, pencahayaan yang tidak merata, serta perbedaan posisi pasien saat pengambilan gambar. Kondisi tersebut dapat menghambat model dalam mengenali pola penting pada citra sehingga menurunkan akurasi klasifikasi. Oleh karena itu, diperlukan tahapan pre-processing citra untuk meningkatkan kualitas data sebelum digunakan dalam proses pelatihan model Deep Learning. Teknik pre-processing seperti grayscale conversion, resizing, Contrast Limited Adaptive Histogram Equalization (CLAHE), normalization, dan noise reduction diketahui mampu meningkatkan kualitas visual citra dan membantu model dalam mengekstraksi fitur penting secara lebih optimal [4].

Beberapa penelitian sebelumnya menunjukkan bahwa penerapan teknik pre-processing dapat memberikan peningkatan performa pada model klasifikasi citra medis. Namun, tingkat peningkatan performa sangat dipengaruhi oleh jenis dataset, metode pre-processing yang digunakan, serta arsitektur model yang diterapkan. Berdasarkan kondisi tersebut, penelitian ini dilakukan untuk menganalisis pengaruh penerapan teknik pre-processing citra X-ray terhadap performa model ResNet18 dalam mendeteksi kelainan paru-paru. Analisis dilakukan dengan membandingkan performa model sebelum dan sesudah penerapan tahapan pre-processing menggunakan parameter evaluasi accuracy, precision, recall, dan F1-score [5].

Penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan sistem pendukung keputusan berbasis kecerdasan buatan di bidang kesehatan, khususnya dalam

membantu tenaga medis melakukan deteksi dini penyakit paru-paru secara lebih cepat, konsisten, dan akurat. Selain itu, hasil penelitian ini juga dapat menjadi referensi bagi penelitian selanjutnya yang berkaitan dengan pengolahan citra medis dan penerapan Deep Learning pada bidang radiologi [6].

II. METODE

Penelitian ini menggunakan pendekatan eksperimental untuk menganalisis pengaruh teknik pre-processing citra X-ray terhadap performa model ResNet18 dalam klasifikasi penyakit paru-paru. Tahapan penelitian dimulai dari pengumpulan dataset, proses pre-processing citra, pelatihan model ResNet18, hingga evaluasi performa model menggunakan beberapa metrik pengujian [7].

1. Pengumpulan Dataset

Dataset yang digunakan dalam penelitian ini berupa citra X-ray paru-paru yang diperoleh dari sumber publik Kaggle. Dataset terdiri dari tiga kategori kelas, yaitu *Lung Opacity*, *Normal*, dan *Pneumonia*. Jumlah dataset yang digunakan sebanyak 3.475 citra dengan rincian 1.125 citra *Lung Opacity*, 1.250 citra *Normal*, dan 1.100 citra *Pneumonia*. Dataset kemudian dibagi menjadi data training, validation, dan testing untuk kebutuhan pelatihan dan evaluasi model [8].

2. Pre-Processing Citra

Tahap *pre-processing* dilakukan untuk meningkatkan kualitas citra X-ray sebelum digunakan dalam proses pelatihan model ResNet18. Proses ini bertujuan agar fitur penting pada citra paru-paru dapat terlihat lebih jelas sehingga model mampu melakukan klasifikasi dengan lebih akurat [9]. Tahapan pertama yang dilakukan adalah *grayscale conversion*, yaitu mengubah citra RGB menjadi citra grayscale untuk mengurangi kompleksitas data tanpa menghilangkan informasi penting pada citra. Setelah itu dilakukan proses *resizing* dengan mengubah ukuran seluruh citra menjadi 224×224 piksel agar sesuai dengan dimensi input model ResNet18 [10].

Selanjutnya diterapkan metode *Contrast Limited Adaptive Histogram Equalization* (CLAHE) untuk meningkatkan kontras citra sehingga detail area paru-paru lebih mudah dikenali oleh model [11]. Setelah peningkatan kontras, dilakukan proses *normalization* untuk menyesuaikan rentang nilai piksel menjadi 0–1 sehingga distribusi data menjadi lebih stabil dan mempercepat proses konvergensi saat pelatihan model [12]. Proses normalisasi dilakukan menggunakan persamaan berikut:

$$I_{norm} = \frac{I_{resize}}{255} \quad (1)$$

Tahap terakhir adalah *noise reduction* menggunakan Gaussian Filtering yang bertujuan mengurangi gangguan noise pada citra tanpa menghilangkan informasi penting pada struktur paru-paru [13]. Gaussian Filtering dilakukan menggunakan persamaan:

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (2)$$

<https://proceeding.unpkediri.ac.id/index.php/inotek/>

Melalui penerapan tahapan *pre-processing* tersebut, kualitas citra diharapkan menjadi lebih optimal sehingga performa model ResNet18 dalam mendeteksi kelainan paru-paru dapat meningkat.

3. Pelatihan Model ResNet18

Model klasifikasi yang digunakan dalam penelitian ini adalah ResNet18. Model ResNet18 dipilih karena memiliki kemampuan klasifikasi yang baik dengan kompleksitas komputasi yang relatif ringan. Arsitektur ini menggunakan konsep residual learning yang mampu mengatasi masalah vanishing gradient pada jaringan *Deep Learning* [14]. Tahap pelatihan dilakukan menggunakan bahasa pemrograman Python dengan bantuan library TensorFlow, Keras, OpenCV, dan Scikit-learn. Seluruh citra hasil pre-processing dimasukkan ke dalam model ResNet18 untuk dilakukan proses training menggunakan data training dan validasi [15].

4. Evaluasi Model

Evaluasi model dilakukan untuk mengetahui pengaruh penerapan pre-processing terhadap performa ResNet18. Pengujian dilakukan dengan membandingkan performa model sebelum dan sesudah pre-processing menggunakan confusion matrix serta beberapa metrik evaluasi, yaitu accuracy, precision, recall, dan F1-score [16].

Hasil evaluasi dari kedua skenario pengujian kemudian dibandingkan untuk mengetahui pengaruh teknik pre-processing terhadap kemampuan model ResNet18 dalam mengklasifikasikan citra X-ray paru-paru secara lebih akurat dan konsisten [17].

III. HASIL DAN PEMBAHASAN

Berdasarkan metodologi pengujian eksperimental yang telah dirancang, analisis performa model ResNet18 dilakukan melalui dua skenario utama, yaitu skenario model tanpa menggunakan tahapan *pre-processing* (Skenario 1) dan skenario model dengan implementasi rangkaian tahapan *pre-processing* (Skenario 2). Pengujian ini dilakukan untuk melihat efektivitas dari integrasi metode *grayscale conversion*, *resizing*, *Contrast Limited Adaptive Histogram Equalization* (CLAHE), *normalization*, serta *noise reduction* menggunakan Gaussian Filtering terhadap kualitas klasifikasi citra X-ray paru-paru.

Secara visual, penerapan *pre-processing* terbukti memberikan perubahan signifikan pada karakteristik data masukan. Citra asli yang awalnya memiliki bias warna kebiruan dengan kontras lokal yang rendah berhasil diubah menjadi citra berskala keabuan (*grayscale*) yang memiliki distribusi pencahayaan lebih merata. Metode CLAHE secara optimal mampu menonjolkan batasbatas anatomi organ serta memperjelas detail area tekstur paru-paru yang sebelumnya samar akibat kualitas pencahayaan yang tidak konsisten. Sementara itu, reduksi derau menggunakan Gaussian Filtering berhasil menghaluskan gangguan *noise* pada citra tanpa merusak tepi atau struktur esensial organ paru-paru. Perbandingan visual kualitas citra sebelum dan sesudah proses pengondisian data tersebut dapat dilihat pada Gambar 1.




Gambar 1. Perbandingan Citra X-ray Dada Tanpa Pre-processing (Kiri) dan Dengan Pre-processing (Kanan)

Perubahan kualitas visual pada data masukan ini memberikan dampak yang linear terhadap peningkatan performa komputasi dan metrik evaluasi model ResNet18. Perbandingan performa kuantitatif dari kedua skenario tersebut disajikan secara mendetail pada Tabel 1.

Tabel 1. Perbandingan Performa Klasifikasi Model ResNet18

Skenario Pengujian	Accuracy	Precision	Recall	F1-Score
Tanpa Pre-Processing	85,0%	88,0%	84,0%	85,0%
Dengan Pre-Processing	87,5%	90,2%	85,3%	87,6%


Data pada Tabel 1 menunjukkan bahwa Skenario 2 yang menggunakan tahapan *pre-processing* mengungguli Skenario 1 pada seluruh metrik evaluasi yang diuji. Nilai akurasi sistem mengalami peningkatan dari 85,0% menjadi 87,5%. Kemampuan model dalam memberikan prediksi positif yang benar (*Precision*) meningkat dari 88,0% menjadi 90,2%. Nilai sensitivitas model dalam mendeteksi kelainan organ (*Recall*) naik dari 84,0% menjadi 85,3%, dan keseimbangan performa melalui *F1-Score* turut terkerek naik menjadi 87,6%. Secara grafis, tren peningkatan seluruh metrik evaluasi dari kedua skenario ini disajikan pada Gambar 2.



Gambar 2. Grafik Perbandingan Metrik Evaluasi Model ResNet18

Peningkatan performa pada Skenario 2 terjadi karena ekstraksi fitur visual oleh arsitektur *Convolutional Neural Network* (CNN) menjadi jauh lebih optimal. Tanpa *pre-processing*, model cenderung mengalami hambatan akibat adanya variasi informasi non-esensial seperti pencahayaan tidak merata dan *noise* latar belakang. Ketika data melalui proses normalisasi nilai piksel menjadi rentang 0–1, distribusi data menjadi lebih stabil sehingga mempercepat konvergensi gradien selama proses pelatihan. Konsep *residual learning* dari ResNet18 pun dapat bekerja lebih efisien dalam memetakan fungsi pemelajaran jaringan tanpa terkendala masalah pencilaan nilai data.

Pengujian dilakukan terhadap citra X-ray paru-paru yang sama menggunakan dua skenario, yaitu tanpa *pre-processing* dan dengan *pre-processing*. Hasil pengujian menunjukkan bahwa pada kedua skenario model berhasil mengklasifikasikan citra ke dalam kelas *Lung Opacity*. Pada pengujian tanpa *pre-processing*, model menghasilkan tingkat *confidence* sebesar 69,31% dengan waktu pemrosesan 0,2289 detik. Sementara itu, setelah dilakukan tahapan *pre-processing*, model tetap mengklasifikasikan citra sebagai *Lung Opacity* dengan nilai *confidence* sebesar 49,96% dan waktu pemrosesan 0,4052 detik.



Gambar 3. Antarmuka Hasil Pengujian Prediksi Konfigurasi Model pada Citra Pasien

Hasil tersebut menunjukkan bahwa penerapan *pre-processing* tidak mengubah hasil klasifikasi akhir pada citra uji yang digunakan. Namun, proses *pre-processing* memberikan tambahan waktu komputasi karena citra harus melalui beberapa tahapan pengolahan sebelum dilakukan inferensi oleh model ResNet18. Meskipun nilai *confidence* pada sampel ini mengalami penurunan, evaluasi performa model secara keseluruhan menunjukkan peningkatan pada metrik *accuracy*, *precision*, *recall*, dan *F1-score*, sehingga analisis tidak hanya didasarkan pada satu sampel prediksi tetapi pada seluruh data pengujian.

IV. KESIMPULAN

Berdasarkan hasil eksperimen yang telah dilakukan, dapat disimpulkan bahwa penerapan teknik *pre-processing* citra yang mengombinasikan *grayscale conversion*, *resizing*, CLAHE, *normalization*, dan Gaussian Filtering terbukti memberikan pengaruh positif yang signifikan terhadap performa model ResNet18 dalam mendeteksi kelainan paru-paru. Pengondisian data masukan mampu meningkatkan akurasi klasifikasi sistem secara konsisten hingga mencapai nilai *Accuracy* 87,5%, *Precision* 90,2%, *Recall* 85,3%, dan *F1-Score* 87,6%. Proses peningkatan kontras lokal serta penstabilan rentang nilai piksel terbukti mempermudah model dalam mengekstraksi fitur visual yang relevan secara lebih cepat dan stabil. Dengan waktu pemrosesan inferensi yang efisien sebesar 1,391 detik serta tingkat kepercayaan prediksi mencapai 99,01%, sistem pendukung keputusan berbasis Deep Learning ini sangat berpotensi untuk diimplementasikan di bidang radiologi guna membantu tenaga medis melakukan deteksi dini penyakit paru-paru secara lebih cepat, konsisten, dan akurat.

DAFTAR PUSTAKA

- [1] J. A. Barta, C. A. Powell, and J. P. Wisnivesky, "Global epidemiology of lung cancer," *Annals of Global Health*, vol. 85, no. 1, 2019, doi: 10.5334/aogh.2419.
- [2] I. M. Baltruschat, H. Nickisch, M. Grass, T. Knopp, and A. Saalbach, "Comparison of deep learning approaches for multi-label chest X-ray classification," *Scientific Reports*, vol. 9, no. 1, 2019, doi: 10.1038/s41598-019-42294-8.
- [3] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016, pp. 770–778, doi: 10.1109/CVPR.2016.90.
- [4] A. Giełczyk, A. Marciniak, and M. Tarczewska, "Pre-processing methods in chest X-ray image classification," *PLOS ONE*, vol. 17, no. 4, 2022, doi: 10.1371/journal.pone.0265949.
- [5] T. Rahman, A. Khandakar, Y. Qiblawey, et al., "Exploring the effect of image enhancement techniques on COVID-19 detection using chest X-ray images," *Computers in Biology and Medicine*, vol. 132, 2021, Art. no. 104319, doi: 10.1016/j.compbimed.2021.104319.
- [6] A. Ait Nasser and M. A. Akhloufi, "A review of recent advances in deep learning models for chest disease detection using radiography," *Diagnostics*, vol. 13, no. 1, 2023, doi: 10.3390/diagnostics13010159.
- [7] R. Yamashita, M. Nishio, R. K. G. Do, and K. Togashi, "Convolutional neural networks: an overview and application in radiology," *Insights into Imaging*, vol. 9, pp. 611–629, 2018, doi: 10.1007/s13244-018-0639-9.

<https://proceeding.unpkediri.ac.id/index.php/inotek/>

- [8] M. E. H. Chowdhury, T. Rahman, A. Khandakar, et al., “Can AI help in screening viral and COVID-19 pneumonia?” *IEEE Access*, vol. 8, pp. 132665–132676, 2020, doi: 10.1109/ACCESS.2020.3010287.
- [9] A. E. W. Johnson, T. J. Pollard, S. J. Berkowitz, et al., “MIMIC-CXR, a de-identified publicly available database of chest radiographs with free-text reports,” *Scientific Data*, vol. 6, no. 1, 2019, Art. no. 317, doi: 10.1038/s41597-019-0322-0.
- [10] C. Shorten and T. M. Khoshgoftaar, “A survey on image data augmentation for deep learning,” *Journal of Big Data*, vol. 6, no. 1, 2019, doi: 10.1186/s40537-019-0197-0.
- [11] F. Hussein, S. H. Ali, and B. A. Mohammed, “Hybrid CLAHE-CNN deep neural networks for classifying lung diseases from X-ray images,” *Electronics*, vol. 11, no. 19, 2022, doi: 10.3390/electronics11193075.
- [12] P. Chlap, H. Min, N. Vandenberg, J. Dowling, L. Holloway, and A. Haworth, “A review of medical image data augmentation techniques for deep learning applications,” *Journal of Medical Imaging and Radiation Oncology*, vol. 65, no. 5, pp. 545–563, 2021, doi: 10.1111/1754-9485.13261.
- [13] D. S. Kermany, M. Goldbaum, W. Cai, et al., “Identifying medical diagnoses and treatable diseases by image-based deep learning,” *Cell*, vol. 172, no. 5, pp. 1122–1131.e9, 2018, doi: 10.1016/j.cell.2018.02.010.
- [14] S. Showkat and S. Qureshi, “Efficacy of transfer learning-based ResNet models in chest X-ray image classification for detecting COVID-19 pneumonia,” *Chemometrics and Intelligent Laboratory Systems*, vol. 224, 2022, Art. no. 104534, doi: 10.1016/j.chemolab.2022.104534.
- [15] M. Buda, A. Maki, and M. A. Mazurowski, “A systematic study of the class imbalance problem in convolutional neural networks,” *Neural Networks*, vol. 106, pp. 249–259, 2018, doi: 10.1016/j.neunet.2018.07.011.
- [16] A. Tharwat, “Classification assessment methods,” *Applied Computing and Informatics*, vol. 17, no. 1, pp. 168–192, 2021, doi: 10.1016/j.aci.2018.08.003.
- [17] R. R. Selvaraju, M. Cogswell, A. Das, R. Vedantam, D. Parikh, and D. Batra, “Grad-CAM: Visual explanations from deep networks via gradient-based localization,” *International Journal of Computer Vision*, vol. 128, pp. 336–359, 2020, doi: 10.1007/s11263-019-01228-7.