

Perbandingan Arsitektur EfficientNetB4 dengan dan tanpa Progressive Resizing untuk Klasifikasi Pneumonia Bakterial dan Viral pada Citra X-Ray Dada

Benedict Michael Pepper¹, Elroi Yonatan Raharjo², dan Windra Swastika³

Teknik Informatika, Universitas Ma Chung, Villa Puncak Tidar Blok N No. 1, Kabupaten Malang, Jawa Timur, Indonesia, 65151

Correspondence: Benedict Michael Pepper (312310007@student.machung.ac.id)
085161618852

Received: DD MM YY – Revised: DD MM YY - Accepted: DD MM YY - Published: DD MM YY

Abstrak. Pneumonia merupakan masalah kesehatan global yang menjadi salah satu penyebab utama mortalitas pada anak. Diagnosis yang cepat dan akurat untuk membedakan etiologi pneumonia antara bakteri dan virus sangat krusial untuk penanganan klinis yang tepat. Namun, diagnosis berbasis citra X-ray dada seringkali menjadi tantangan karena kemiripan manifestasi visual antara kedua jenis pneumonia tersebut. Penelitian ini membandingkan dua strategi pelatihan menggunakan arsitektur CNN EfficientNetB4 untuk mengklasifikasikan pneumonia bakterial dan viral. Strategi pertama menggunakan pendekatan ukuran citra tetap (384x384 piksel), sementara strategi kedua menerapkan *Progressive Resizing* secara bertahap. Kedua model memanfaatkan *transfer learning*, fungsi kerugian *Focal Loss*, augmentasi data *Albumentations*, dan evaluasi akhir dengan *Test-Time Augmentation* (TTA). Hasil penelitian menunjukkan bahwa model yang dilatih dengan strategi ukuran citra tetap mencapai kinerja yang lebih unggul. Hasil yang didapatkan oleh model dengan ukuran citra tetap adalah akurasi sebesar 87,14% dan ROC AUC 0,9431, lebih tinggi dibandingkan model dengan *Progressive Resizing* yang mencapai akurasi 84,78% dan ROC AUC 0,9238. Temuan ini mengindikasikan bahwa pelatihan langsung pada resolusi target lebih efektif untuk tugas klasifikasi ini.

Kata kunci: Pneumonia Bakteri, Pneumonia Virus, CNN, EfficientNet, Progressive Resizing.

PENDAHULUAN

Pneumonia, atau radang paru-paru, adalah penyakit infeksi akut yang menyerang jaringan paru (alveoli) dan menjadi salah satu masalah kesehatan global utama, terutama pada populasi anak-anak. Menurut Organisasi Kesehatan Dunia (WHO), pneumonia menyumbang sekitar 15% dari seluruh kematian anak di bawah usia lima tahun. Penyebab utama pneumonia dapat dibedakan menjadi dua kategori utama: bakteri dan virus. Perbedaan etiologi ini sangat penting karena implikasi terapeutiknya sangat berbeda. Infeksi bakteri umumnya memerlukan terapi antibiotik, sementara infeksi virus tidak merespons antibiotik dan memerlukan penanganan suportif atau antivirus.

Dalam beberapa tahun terakhir, kemajuan dalam bidang kecerdasan buatan, khususnya *deep learning* (DL), telah menunjukkan potensi luar biasa dalam analisis citra medis (Alzubaidi et al., 2021; Mienye et al., 2025). Model *Convolutional Neural Networks* (CNN), salah satu arsitektur DL yang paling populer, terinspirasi dari arsitektur dan fungsi

dasar sistem visual biologis (Celeghin et al., 2023). CNN mampu mempelajari fitur-fitur hierarkis yang kompleks secara otomatis dari data citra dalam jumlah besar, yang seringkali melampaui kemampuan persepsi manusia (Taye, 2023). Berbagai penelitian telah menunjukkan keberhasilan CNN dalam mendeteksi pneumonia pada anak-anak dari citra X-ray (Subiakto et al., 2023).

Arsitektur seperti EfficientNet, yang dirancang melalui pencarian arsitektur neural (*neural architecture search*), telah menetapkan standar baru dalam efisiensi dan akurasi pada tugas klasifikasi citra (Li et al., 2022). Untuk meningkatkan performa, model-model ini seringkali dilatih menggunakan teknik *transfer learning*, di mana pengetahuan yang didapat dari pelatihan pada dataset besar (seperti ImageNet) ditransfer untuk menyelesaikan tugas spesifik pada dataset yang lebih kecil (Wijaya et al., 2021). Selain itu, strategi pelatihan seperti *Progressive Resizing*, di mana model dilatih secara bertahap dengan ukuran citra yang semakin besar, telah terbukti efektif dalam beberapa kasus, seperti deteksi COVID-19 (Bhatt et al., 2021).

Penelitian ini berfokus pada penerapan dan perbandingan dua strategi pelatihan model EfficientNetB4 untuk tugas klasifikasi pneumonia bakterial versus viral. Tujuannya adalah untuk mengevaluasi secara kuantitatif strategi mana yang memberikan kinerja klasifikasi terbaik pada dataset citra X-ray dada pediatrik, sehingga dapat memberikan kontribusi bagi pengembangan sistem pendukung keputusan klinis yang lebih andal.

MASALAH

Diagnosis konvensional pneumonia seringkali mengandalkan interpretasi citra radiografi dada (X-ray). Namun, membedakan antara pneumonia bakterial dan viral berdasarkan citra X-ray merupakan tugas yang menantang bahkan bagi ahli radiologi berpengalaman. Hal ini disebabkan oleh adanya tumpang tindih fitur visual dan manifestasi radiologis yang seringkali serupa antara kedua etiologi tersebut. Kesalahan diagnosis dapat menyebabkan penggunaan antibiotik yang tidak perlu, yang berkontribusi pada peningkatan resistensi antimikroba, atau sebaliknya, penundaan terapi antibiotik yang dapat berakibat fatal pada kasus infeksi bakteri.

Tantangan ini mendorong perlunya pengembangan sistem diagnosis berbantuan komputer (CAD) yang akurat dan andal. Meskipun model *deep learning* telah menunjukkan potensi besar, performanya sangat bergantung pada arsitektur model dan

strategi pelatihan yang digunakan (Alzubaidi et al., 2021). Persoalan utamanya adalah bagaimana mengoptimalkan model CNN, dalam hal ini EfficientNetB4, untuk dapat mengekstraksi fitur-fitur pembeda yang sangat halus antara pneumonia bakterial dan viral. Oleh karena itu, penelitian ini menguraikan masalah keilmuan berikut: "Antara strategi pelatihan dengan ukuran citra tetap dan strategi *Progressive Resizing*, manakah yang lebih efektif untuk meningkatkan performa klasifikasi model EfficientNetB4 dalam membedakan pneumonia bakterial dan viral pada citra X-ray dada?"

METODE PELAKSANAAN

Metode pelaksanaan penelitian ini mencakup deskripsi dataset, lingkungan komputasi, tahapan pra-pemrosesan data, desain arsitektur model, dan strategi pelatihan serta evaluasi yang digunakan.

Dataset

Penelitian ini menggunakan dataset publik "Chest X-Ray Images (Pneumonia)" yang tersedia di platform Kaggle, yang bersumber dari Mendeley Data oleh Kermay, Zhang, dan Goldbaum. Dataset ini terdiri dari total 5.863 citra X-ray dada (format JPEG) yang diambil dari pasien anak-anak berusia satu hingga lima tahun. Penelitian ini berfokus pada sub-kategori BACTERIAL dan VIRAL. Diagnosis untuk setiap citra diverifikasi oleh dua dokter ahli, dan set evaluasi diperiksa oleh ahli ketiga untuk meminimalisir kesalahan pelabelan.

Lingkungan Eksperimen

Seluruh proses eksperimen dijalankan pada platform Kaggle Notebook yang didukung oleh akselerator GPU NVIDIA Tesla P100. Kerangka kerja utama yang digunakan adalah TensorFlow dengan bahasa pemrograman Python.

Pra-pemrosesan dan Augmentasi Data

Ditemukan adanya ketidakseimbangan kelas yang signifikan antara citra bakterial (2780) dan viral (1493). Untuk mengatasi ini, dilakukan augmentasi data pada kelas minoritas (viral) hingga jumlahnya seimbang. Dataset yang telah seimbang (total 5560 citra) kemudian dibagi menjadi set pelatihan (80%), validasi (10%), dan pengujian (10%). Untuk meningkatkan generalisasi model, augmentasi data yang lebih kompleks diterapkan secara *on-the-fly* pada set pelatihan menggunakan pustaka *Albumentations*, yang mencakup

transformasi seperti *HorizontalFlip*, *ShiftScaleRotate*, *RandomBrightnessContrast*, dan *CoarseDropout*.

Arsitektur Model

Model yang digunakan adalah EfficientNetB4, sebuah arsitektur CNN modern yang memanfaatkan *transfer learning* dari bobot yang telah dilatih pada dataset ImageNet (Devasia et al., 2023). Di atas arsitektur dasar ini, ditambahkan sebuah *classifier head* kustom yang terdiri dari lapisan *GlobalAveragePooling2D*, *Dense* dengan 512 neuron, *BatchNormalization*, *Dropout (0.5)*, dan lapisan *Dense output* dengan 2 neuron dan aktivasi *Softmax*.

Strategi Pelatihan

Kedua model dilatih menggunakan *Focal Loss* sebagai fungsi kerugian dan optimizer Adam dengan penjadwal laju pembelajaran *CosineDecayRestarts*.

- Model 1: Pelatihan dengan *Progressive Resizing* Strategi ini, yang terinspirasi dari penelitian seperti oleh Bhatt et al. (2021), melibatkan tiga tahap pelatihan berurutan pada ukuran citra 224x224, 256x256, dan terakhir 384x384 piksel. Bobot dari setiap tahap digunakan kembali pada tahap berikutnya.
- Model 2: Pelatihan Ukuran Tetap (*Fixed-Size*) Strategi ini melatih model secara langsung pada ukuran citra target 384x384 piksel. Pelatihan dibagi menjadi dua fase: *head training* selama 25 *epoch* dan *fine-tuning* (melatih sebagian lapisan dari model dasar) selama 35 *epoch*.

Metrik Evaluasi

Kinerja kedua model dievaluasi pada set data pengujian menggunakan metrik Akurasi, Presisi, *Recall*, *F1-Score*, ROC AUC, dan Matriks Kebingungan. Teknik *Test-Time Augmentation* (TTA) diterapkan pada tahap inferensi untuk meningkatkan akurasi, di mana prediksi akhir adalah rata-rata dari lima prediksi pada versi citra yang diaugmentasi.

HASIL DAN PEMBAHASAN

Hasil evaluasi kuantitatif pada set data pengujian menunjukkan bahwa pendekatan dengan ukuran citra tetap menghasilkan performa yang lebih superior.

Hasil Kinerja Model

Metrik	Model 1 (<i>Progressive Resizing</i>)	Model 2 (Ukuran Tetap)
Akurasi	84,78%	87,14%
ROC AUC	0,9238	0,9431
Presisi (Bakterial)	0,8407	0,8705
Recall (Bakterial)	0,8597	0,8741
F1-Score (Bakterial)	0,8501	0,8723
Presisi (Viral)	0,8548	0,8723
Recall (Viral)	0,8357	0,8687
F1-Score (Viral)	0,8451	0,8705

Tabel 1. Perbandingan Metrik Kinerja Akhir pada Set Pengujian (dengan TTA)

Dari tabel di atas, terlihat jelas bahwa Model 2 (Ukuran Tetap) secara konsisten mengungguli Model 1 (*Progressive Resizing*) di semua metrik evaluasi.

Hasil penelitian ini menunjukkan temuan yang berlawanan dengan hipotesis awal, di mana strategi pelatihan konvensional (Model 2) menghasilkan kinerja yang lebih baik daripada strategi *Progressive Resizing* (Model 1). Keunggulan Model 2 dapat diatribusikan pada beberapa faktor. Pertama, dengan melatih model secara langsung pada resolusi target (384x384 piksel) untuk durasi yang lebih lama, model memiliki lebih banyak kesempatan untuk mempelajari fitur-fitur visual yang halus dan kompleks yang krusial untuk membedakan pneumonia bakterial dan viral. Fitur-fitur diagnostik ini mungkin tidak begitu jelas atau bahkan hilang pada citra beresolusi lebih rendah yang digunakan pada tahap awal *Progressive Resizing*.

Kedua, pendekatan *Progressive Resizing* dapat berisiko mengalami "*negative transfer*", di mana fitur yang dipelajari pada resolusi rendah tidak sepenuhnya relevan atau bahkan mengganggu pembelajaran pada resolusi yang lebih tinggi. Hal ini berbeda dengan beberapa kasus lain seperti deteksi COVID-19 di mana teknik ini terbukti berhasil (Bhatt et al., 2021), yang mungkin mengindikasikan bahwa perbedaan fitur antara pneumonia bakterial dan viral lebih halus dan memerlukan resolusi tinggi secara konsisten selama pelatihan.

Ketiga, arsitektur EfficientNetB4 yang dikombinasikan dengan augmentasi data yang kuat dan fungsi kerugian *Focal Loss* sudah merupakan fondasi yang sangat solid. Kemungkinan, manfaat dari *Progressive Resizing* sebagai teknik regularisasi menjadi kurang signifikan atau bahkan tertutupi oleh kekuatan dari komponen-komponen lain dalam *pipeline* pelatihan.

KESIMPULAN

Penelitian ini berhasil membandingkan dua strategi pelatihan model EfficientNetB4 untuk klasifikasi pneumonia bakterial dan viral. Berlawanan dengan ekspektasi, hasil eksperimen secara konsisten menunjukkan bahwa strategi pelatihan konvensional menggunakan ukuran citra tetap (384x384 piksel) memberikan hasil yang lebih unggul, dengan akurasi akhir sebesar 87,14% dan ROC AUC 0,9431. Temuan ini mengimplikasikan bahwa, untuk tugas klasifikasi citra medis yang sangat bergantung pada fitur visual halus seperti ini, melatih model secara langsung pada resolusi target yang optimal mungkin merupakan pendekatan yang lebih efektif. Hal ini memungkinkan jaringan untuk fokus mempelajari detail-detail diagnostik yang paling relevan tanpa terpengaruh oleh representasi yang dipelajari dari resolusi yang lebih rendah.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Kermany, Zhang, dan Goldbaum atas penyediaan dataset "Chest X-Ray Images (Pneumonia)" melalui Mendeley Data, dan kepada Kaggle yang telah memfasilitasi akses terhadap data tersebut untuk komunitas riset.

DAFTAR PUSTAKA

- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M. A., Al-Amidie, M., & Farhan, L. (2021). Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, 8(1), 1–74. <https://doi.org/10.1186/s40537-021-00444-8>
- Bhatt, A., Ganatra, A., & Kotecha, K. (2021). COVID-19 pulmonary consolidations detection in chest X-ray using progressive resizing and transfer learning techniques. *Heliyon*, 7(6), e07211. <https://doi.org/10.1016/j.heliyon.2021.e07211>
- Celeghin, A., Borriero, A., Orsenigo, D., Diano, M., Méndez Guerrero, C. A., Perotti, A.,

- Petri, G., & Tamietto, M. (2023). Convolutional neural networks for vision neuroscience: Significance, developments, and outstanding issues. *Frontiers in Computational Neuroscience*, 17, 1153572. <https://doi.org/10.3389/fncom.2023.1153572>
- Devasia, J., Goswami, H., Lakshminarayanan, S., Rajaram, M., & Adithan, S. (2023). Deep learning classification of active tuberculosis lung zones wise manifestations using chest X-rays: a multi label approach. *Scientific Reports*, 13(1), 887. <https://doi.org/10.1038/s41598-023-28079-0>
- Li, L., Tan, Z., & Han, X. (2022). An Improved EfficientNet Model and its Applications in Pneumonia Image Classification. *Journal of Engineering Science and Technology Review*, 15(6), 49–54. <https://doi.org/10.25103/jestr.156.07>
- Mienye, I. D., Swart, T. G., Obaido, G., Jordan, M., & Ilono, P. (2025). Deep Convolutional Neural Networks in Medical Image Analysis: A Review. *Information*, 16(3), 195. <https://doi.org/10.3390/info16030195>
- Subiakto, R. B. R., Hendradi, R., Werdiningsih, I., & Lung, C.-W. (2023). Pneumonia detection in children chest X-ray images using convolutional neural networks. *AIP Conference Proceedings*, 2554(1), 040001. <https://doi.org/10.1063/5.0119905>
- Taye, M. M. (2023). Theoretical Understanding of Convolutional Neural Network: Concepts, Architectures, Applications, Future Directions. *Computation*, 11(3), 52. <https://doi.org/10.3390/computation11030052>
- Wijaya, A. E., Swastika, W., & Kelana, O. H. (2021). Implementasi Transfer Learning Pada Convolutional Neural Network Untuk Diagnosis Covid-19 Dan Pneumonia Pada Citra X-Ray. *SAINSBERTEK Jurnal Ilmiah Sains & Teknologi*, 2(1), 1-14.



© 2025 by authors. Content on this article is licensed under a Creative Commons Attribution 4.0 International license. (<http://creativecommons.org/licenses/by/4.0/>).