KLASIFIKASI STROKE PADA CITRA CT OTAK MENGGUNAKAN TRANSFER LEARNING EFFICIENTNET-B0

Rendi , Salamet Nur Himawan*, Robieth Sohiburoyyan dan Vera Wati

Politeknik Negeri Indramayu
Jl. Raya Lohbener Lama No.08, Legok, Kec. Lohbener, Kabupaten Indramayu, Jawa Barat 45252
rendi@polindra.ac.id, snhimawan@polindra.ac.id, robieth.s@polindra.ac.id, vera.w@polindra.ac.id
*Corresponding Author

ABSTRAK

Stroke merupakan salah satu penyebab utama kematian dan kecacatan di dunia. Deteksi dini terhadap jenis stroke penting untuk menentukan terapi yang tepat. Penelitian ini mengusulkan model klasifikasi stroke berbasis citra CT otak menggunakan metode transfer learning dengan arsitektur EfficientNet-B0. Dataset publik digunakan secara simulatif dengan tiga kelas yaitu stroke iskemik, stroke hemoragik dan tanpa stroked. Model dilatih menggunakan optimizer Adam dan dievaluasi menggunakan metrik akurasi, presisi, recall, dan AUC. Hasil menunjukkan akurasi 96,83% menandakan performa klasifikasi sangat baik. Penelitian ini menunjukkan potensi penerapan EfficientNet-B0 dalam sistem Computer-Aided Diagnosis (CAD) untuk membantu radiolog dalam deteksi stroke secara cepat dan akurat.

Kata Kunci: *Stroke, CT Otak, Transfer Learning, EfficientNet-B0, Transfer Learning*

PENDAHULUAN

Stroke merupakan salah satu penyebab utama kematian dan kecacatan di dunia. Menurut laporan World Health Organization (WHO), lebih dari 15 juta orang mengalami stroke setiap tahunnya, dan sekitar sepertiganya meninggal dunia [1]. Deteksi dini terhadap jenis stroke sangat penting agar penanganan medis dapat dilakukan dengan tepat waktu dan sesuai dengan jenisnya, yaitu stroke iskemik dan stroke hemoragik [2]. Salah diagnosis pada tahap awal dapat berakibat fatal karena perbedaan terapi pada kedua jenis stroke tersebut.

Salah satu metode yang umum digunakan dalam diagnosis stroke adalah Computed Tomography (CT) scan otak. Citra CT memiliki kemampuan untuk menampilkan struktur anatomi otak dan mendeteksi adanya perdarahan atau penyumbatan pembuluh darah [2]. Namun, interpretasi citra CT secara manual oleh radiolog dapat memakan waktu dan bersifat subjektif tergantung pada pengalaman serta tingkat kelelahan pengamat [3]. Oleh karena itu, dibutuhkan sistem berbasis kecerdasan buatan (Artificial Intelligence) yang mampu membantu klasifikasi stroke secara otomatis dan akurat menggunakan citra CT otak.

Perkembangan deep learning, khususnya Convolutional Neural Network (CNN), telah menunjukkan performa tinggi dalam pengenalan pola pada citra medis [4]. Salah satu pendekatan yang banyak digunakan untuk meningkatkan efisiensi pelatihan model adalah transfer learning, yaitu pemanfaatan model yang telah dilatih sebelumnya (pre-trained model) pada dataset besar untuk menyelesaikan permasalahan baru dengan jumlah data yang lebih terbatas [5]. Pendekatan ini terbukti mampu mempercepat proses pelatihan serta meningkatkan akurasi model pada domain medis, termasuk klasifikasi penyakit berbasis citra [6].

Salah satu arsitektur CNN modern yang memiliki performa tinggi dengan efisiensi komputasi yang baik adalah EfficientNet, khususnya varian EfficientNet-B0, yang menggabungkan optimasi kedalaman, lebar, dan resolusi jaringan secara seimbang [7]. Penelitian ini bertujuan untuk mengimplementasikan metode transfer learning menggunakan EfficientNet-B0 dalam klasifikasi stroke pada citra CT otak.

METODE PENELITIAN

Penelitian ini dilakukan secara simulatif menggunakan dataset publik citra CT otak yang terdiri dari tiga kelas, yaitu stroke iskemik, stroke hemoragik dan tanpa stroke (Absent). Secara umum, alur penelitian dapat dijelaskan melalui beberapa tahapan, yaitu (1) pengumpulan dan praproses data, (2) pembagian dataset, (3) implementasi model transfer learning EfficientNet-B0, (4) pelatihan dan validasi model, serta (5) evaluasi kinerja model.

Pengumpulan dan Praproses Data

Data yang digunakan dalam penelitian ini berasal dari dataset publik citra CT otak [8]. Setiap citra diklasifikasikan berdasarkan diagnosis medis menjadi dua kategori utama: stroke iskemik dan stroke hemoragik. Proses praproses data dilakukan untuk meningkatkan kualitas citra dan menyesuaikannya dengan kebutuhan model deep learning, meliputi resize, normalisasi piksel, dan augmentasi data seperti rotasi, flipping, serta kontras adaptif [9].

Augmentasi data berfungsi untuk memperbanyak variasi citra pelatihan sehingga model menjadi lebih robust terhadap perbedaan orientasi dan intensitas pencahayaan [10]. Seluruh citra diubah ke ukuran 224×224 piksel agar sesuai dengan arsitektur input model EfficientNet-B0 [7].

Pembagian Dataset

Dataset dibagi menjadi tiga subset, yaitu data latih (70%), data validasi (10%), dan data uji (20%). Pembagian ini bertujuan agar model dapat dievaluasi secara objektif tanpa overfitting terhadap data pelatihan [11]. Setiap subset dipilih secara acak namun tetap mempertahankan proporsi kelas (stratified sampling).

Implementasi Model Transfer Learning EfficientNet-B0

Model EfficientNet-B0 digunakan sebagai arsitektur dasar dengan bobot awal dari ImageNet [12]. Lapisan akhir (fully connected layer) diganti dengan lapisan Dense baru berukuran 3 neuron dengan fungsi aktivasi Softmax untuk menghasilkan tiga kelas output, yaitu iskemik, hemoragik dan tanpa stroke. Beberapa lapisan awal model dibekukan (frozen layers) selama tahap awal pelatihan untuk mempertahankan fitur dasar dari pre-trained model [5].

Pelatihan dan Validasi Model

Proses pelatihan dilakukan menggunakan optimizer Adam dengan learning rate awal sebesar 0.0001 dan batch size sebesar 32. Fungsi loss yang digunakan adalah categorical cross-entropy karena tugas klasifikasi bersifat multi-class [13]. Pelatihan dilakukan selama 50 epoch dengan early stopping untuk mencegah overfitting apabila akurasi validasi tidak meningkat setelah 10 epoch berturut-turut.

Untuk memantau performa model selama pelatihan, dilakukan evaluasi pada data validasi menggunakan metrik accuracy, precision, recall, dan F1-score [14]. Setelah proses pelatihan selesai, model terbaik disimpan dan diuji menggunakan data uji untuk menilai performa generalisasi. Evaluasi dilakukan menggunakan confusion matrix.

HASIL DAN PEMBAHASAN

Hasil Pelatihan Model

Pelatihan model dilakukan menggunakan 70% data latih dengan 10% data validasi dan 20% data testing, selama 50 epoch menggunakan optimizer Adam dan learning rate 0.0001. Hasil pelatihan menunjukkan bahwa akurasi model pada data validasi meningkat secara signifikan pada 15 epoch pertama, kemudian stabil setelah epoch ke-35.

Kurva akurasi dan loss ditunjukkan pada Gambar 1, di mana nilai training accuracy mencapai 99,92%, sedangkan validation accuracy mencapai 96,42%.

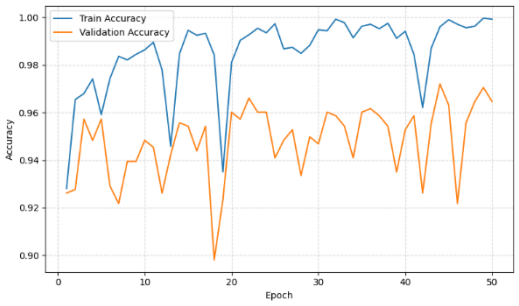

Gambar 1. *Akuraisi Training dan Validation*

Hasil Pengujian Model

Pengujian dilakukan menggunakan data uji sebanyak 20% dari total dataset. Hasil pengujian menunjukkan bahwa model EfficientNet-B0 mampu mengklasifikasikan citra stroke dengan performa yang sangat baik. Nilai metrik evaluasi ditunjukkan pada Tabel 1.

Tabel 1. *Hasil Evaluasi Model*

Metrik	Nilai (%)
Akurasi	96.83
Presisi	95.98
Recall	94.97
F1-Score	95.43
AUC	99.68

Berdasarkan hasil tersebut, model menunjukkan kemampuan klasifikasi yang konsisten antara presisi dan recall. Nilai AUC (Area Under Curve) mendekati 1, yang menandakan performa klasifikasi yang sangat baik.

Confusion matrix pada Tabel 2 menunjukkan bahwa sebagian besar citra berhasil diklasifikasikan dengan benar, dengan hanya sedikit kesalahan klasifikasi antara kelas iskemik dan hemoragik.

Tabel 2. *Confusion Matrix*

	Hemoragik	Absent	Iskemik
Hemoragik	198	12	7
Absent	2	902	11
Iskemik	2	9	213

Dari Tabel 1 terlihat bahwa model memiliki akurasi tinggi sekitar 96,83%, namun dari Tabel 2 masih terdapat kesalahan klasifikasi antar kelas yang penting untuk diperhatikan. Beberapa kasus *Hemoragik* salah dikenali sebagai *Absent* dan *Iskemik*, kemungkinan akibat pola intensitas yang mirip atau ukuran perdarahan yang kecil. Demikian pula, beberapa citra *Iskemik* diklasifikasikan sebagai *Absent* karena lesi iskemik awal sering tampak samar pada CT scan. Sementara itu, kelas *Absent* memiliki akurasi tertinggi tetapi cenderung mendominasi prediksi, menunjukkan adanya bias model terhadap kelas normal. Kesalahan ini mengindikasikan perlunya penyeimbangan data, peningkatan variasi citra melalui augmentasi.

Berikut hasil visualisi pengujian pada setiap kelas Absent, Hemoragik dan Iskemik.

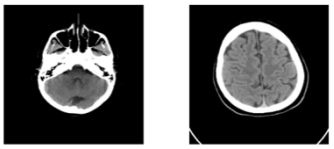

Gambar 2. *Visualisasi Kelas Absent*

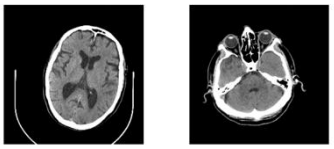

Gambar 3. *Visualisasi Kelas Iskemik*

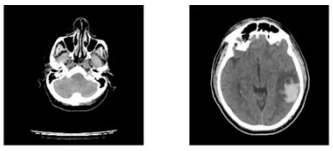

Gambar 4. *Visualisasi Kelas Hemoragik*

PENUTUP

Penelitian ini berhasil mengimplementasikan metode transfer learning menggunakan arsitektur EfficientNet-B0 untuk klasifikasi citra CT otak pada kasus stroke iskemik dan stroke hemoragik. Hasil pengujian menunjukkan bahwa model mampu mencapai akurasi 96,83%, presisi 95,98%, dan AUC 99.68, yang menandakan performa klasifikasi sangat baik.

Model yang dikembangkan berpotensi diintegrasikan ke dalam sistem Computer-Aided Diagnosis (CAD) guna membantu radiolog dalam proses deteksi dini dan

klasifikasi jenis stroke secara cepat, akurat, dan konsisten.

Penelitian ini masih bersifat simulatif dengan keterbatasan pada ukuran dataset dan variasi citra CT. Untuk penelitian lanjutan, disarankan penggunaan dataset klinis yang lebih besar dan beragam guna meningkatkan kemampuan generalisasi model. Selain itu, perlu dilakukan fine-tuning adaptif pada berbagai arsitektur EfficientNet (B1–B7) untuk membandingkan efisiensi dan akurasi, serta pengembangan sistem CAD berbasis web atau cloud agar dapat digunakan langsung oleh tenaga medis.

UCAPAN TERIMA KASIH

Penelitian ini didanai oleh Pusat Penelitian dan Pengabdian Kepada Masyarakat (P3M), Politeknik Negeri Indramayu melalui Kegiatan PUKTI 2025.

DAFTAR PUSTAKA

[1] World Health Organization, "The top 10 causes of death," WHO, 2024.

[2] Shafaat O, Sotoudeh H. Stroke Imaging. [Updated 2023 May 1]. In: StatPearls [Internet]. Treasure Island (FL): StatPearls Publishing; 2025 Jan-. Available from: https://www.ncbi.nlm.nih.gov/books/NBK546635/

[3] Grotta JC, Chiu D, Lu M, Patel S, Levine SR, Tilley BC, Brott TG, Haley EC Jr, Lyden PD, Kothari R, Frankel M, Lewandowski CA, Libman R, Kwiatkowski T, Broderick JP, Marler JR, Corrigan J, Huff S, Mitsias P, Talati S, Tanne D. Agreement and variability in the interpretation of early CT changes in stroke patients qualifying for intravenous rtPA therapy. Stroke. 1999 Aug;30(8):1528-33. doi: 10.1161/01.str.30.8.1528. PMID: 10436095.

[4] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," Nature, vol. 521, pp. 436–444, 2015.

[5] S. J. Pan and Q. Yang, "A survey on transfer learning," IEEE Trans. on Knowledge and Data Engineering, vol. 22, no. 10, pp. 1345–1359, 2010.

[6] J. M. Lundervold and A. Lundervold, "An overview of deep learning in medical imaging," Computers in Medicine and Biology, vol. 107, pp. 185–201, 2019.

[7] M. Tan and Q. V. Le, "EfficientNet: Rethinking model scaling for convolutional neural networks," Proc. ICML, 2019.

[8] Koç U, Akçapınar Sezer E, Özkaya YA, Yarbay Y, Taydaş O, Ayyıldız VA, Kızıloğlu HA, Kesimal U, Çankaya İ, Beşler MS, Karakaş E, Karademir F, Sebik NB, Bahadır M, Sezer Ö, Yeşilyurt B, Varlı S, Akdoğan E, Ülgü MM, Birinci Ş. Artificial Intelligence in Healthcare Competition (TEKNOFEST-2021): Stroke Data Set. Eurasian J Med. 2022 Oct;54(3):248-258. doi: 10.5152/eurasianjmed.2022.22096. PMID: 35943079; PMCID: PMC9797774.

[9] O. Ronneberger, P. Fischer, and T. Brox, "U-Net: Convolutional networks for biomedical image segmentation," MICCAI, 2015.

[10] C. Shorten and T. M. Khoshgoftaar, "A survey on image data augmentation for deep learning," J. Big Data, vol. 6, 2019.

[11] G. James et al., An Introduction to Statistical Learning, Springer, 2021.

[12] Deng, Jia & Dong, Wei & Socher, Richard & Li, Li-Jia & Li, Kai & Li, Fei-Fei. ImageNet: a Large-Scale Hierarchical Image Database. IEEE Conference on Computer Vision and Pattern Recognition. 248-255. 2009. 10.1109/CVPR.2009.5206848.

[13] D. P. Kingma and J. Ba, "Adam: A method for stochastic optimization," arXiv preprint arXiv:1412.6980, 2015.

[14] S. Powers, "Evaluation: From precision, recall and F-measure to ROC, informedness, markedness and correlation," J. Mach. Learn. Tech., vol. 2, no. 1, 2011.

Halaman ini sengaja dikosongkan.