

Klasifikasi Stroke pada Citra MRI Otak Menggunakan Arsitektur DenseNet121

Safira Rahmalia Putri¹, I Gede Susrama Mas Diyasa², Andri Fauzan Adziima³

^{1,3}Program Studi Sains Data, Universitas Pembangunan Nasional “Veteran” Jawa Timur

¹22083010073@student.upnjatim.ac.id

³andri.fauzan.fasilkom@upnjatim.ac.id

²Program Studi Sains Data, Universitas Pembangunan Nasional “Veteran” Jawa Timur

Corresponding author email: igsusrama.if@upnjatim.ac.id

ABSTRAK

Abstrak—Stroke merupakan salah satu penyebab utama kematian dan kecacatan di dunia, termasuk di Indonesia. Deteksi dini sangat penting untuk mencegah dampak lebih lanjut, namun interpretasi citra *Magnetic Resonance Imaging (MRI)* masih membutuhkan keahlian radiolog dan berpotensi menimbulkan bias subjektif. Penelitian ini mengembangkan model klasifikasi stroke berbasis citra MRI otak menggunakan arsitektur DenseNet121 sebagai backbone yang berfungsi sebagai *feature extractor* untuk meningkatkan akurasi deteksi otomatis. Tahapan penelitian mencakup *preprocessing* citra berupa *resize*, *grayscale conversion*, *histogram equalization*, *Gaussian blur*, dan normalisasi intensitas piksel, diikuti pembagian dataset menjadi data latih dan validasi (80:20) serta augmentasi citra. Proses pelatihan dilakukan secara bertahap melalui *initial training*, *fine-tuning*, dan *deep fine-tuning* dengan *EarlyStopping* serta *ReduceLROnPlateau*. Hasil menunjukkan bahwa pada tahap *initial training* model mencapai akurasi validasi sebesar 87,62%, meningkat menjadi 94,50% setelah *fine-tuning*, dan mencapai 97,25% pada tahap *deep fine-tuning* dengan validation loss sebesar 0,0786 serta nilai rata-rata *precision*, *recall*, dan *F1-score* sebesar 0,97. Model ini terbukti efektif untuk klasifikasi citra MRI otak dan berpotensi digunakan sebagai sistem bantu diagnosis stroke di fasilitas kesehatan dengan sumber daya terbatas.

Keywords: Citra MRI Otak, Deep Learning, DenseNet121, Klasifikasi Citra, Stroke.

I. PENDAHULUAN

Stroke merupakan kondisi medis akut pada sistem saraf pusat yang terjadi akibat menurunnya atau terhentinya aliran darah menuju jaringan otak, sehingga dapat memicu kerusakan sel saraf secara permanen hingga berujung pada kematian apabila tidak mendapatkan penanganan secara cepat dan tepat. Penyakit ini masih menjadi salah satu penyumbang angka kematian dan kecacatan tertinggi di dunia, termasuk di Indonesia [1], [2]. Tingginya prevalensi stroke menuntut adanya sistem diagnosis yang akurat dan efisien untuk mempercepat proses penanganan pasien serta menekan risiko komplikasi lebih lanjut.

Magnetic Resonance Imaging (MRI) menjadi salah satu modalitas pencitraan yang sangat penting dalam pemeriksaan stroke karena kemampuannya menampilkan struktur jaringan otak secara detail serta sensitivitasnya dalam mendeteksi perubahan lesi iskemik maupun hemoragik, khususnya pada fase akut [3]. Namun demikian, proses interpretasi citra MRI umumnya masih dilakukan secara manual oleh tenaga medis profesional. Pendekatan ini membutuhkan keahlian khusus, waktu analisis yang relatif lama, serta berpotensi menimbulkan variasi penilaian antar-pengamat, terutama pada kasus dengan ukuran lesi kecil atau kontras citra yang rendah [4]. Kondisi ini dapat memengaruhi ketepatan dan konsistensi hasil diagnosis, terutama di fasilitas kesehatan dengan keterbatasan jumlah tenaga ahli.


Perkembangan teknologi kecerdasan buatan, khususnya metode deep learning, membuka peluang untuk mengotomatisasi analisis citra medis sehingga mampu meningkatkan akurasi dan efisiensi proses diagnosis [5]. *Convolutional Neural Network* (CNN) telah banyak diaplikasikan pada bidang pencitraan medis dan menunjukkan performa yang menjanjikan dalam tugas klasifikasi berbagai penyakit berbasis citra. Salah satu arsitektur CNN yang terbukti efektif adalah DenseNet121. Arsitektur ini menerapkan mekanisme konektivitas padat antar-layer yang memungkinkan setiap lapisan menerima fitur dari seluruh lapisan sebelumnya, sehingga mampu menjaga stabilitas aliran gradien, memaksimalkan pemanfaatan fitur, serta meningkatkan efisiensi parameter [6]. Berbagai penelitian menunjukkan bahwa DenseNet unggul untuk tugas klasifikasi citra medis karena menghasilkan performa tinggi dengan jumlah parameter yang relatif efisien [7], [8].

Meskipun beberapa studi telah memanfaatkan DenseNet121 untuk klasifikasi citra medis, sebagian penelitian belum mengkaji secara mendalam pengaruh penerapan strategi *transfer learning* bertahap yang meliputi *initial training*, *fine-tuning*, dan *deep fine-tuning* terhadap peningkatan performa model, khususnya pada klasifikasi citra MRI otak untuk kasus stroke. Selain itu, pemanfaatan dataset publik dengan karakteristik heterogen juga masih memerlukan evaluasi lebih lanjut untuk memastikan kemampuan generalisasi model.

Berdasarkan celah penelitian tersebut, studi ini mengimplementasikan DenseNet121 sebagai backbone tunggal untuk mengklasifikasikan citra MRI otak ke dalam dua kelas, yaitu stroke dan non-stroke menggunakan dataset publik dari Kaggle. Penelitian ini bertujuan menganalisis peningkatan performa model pada setiap tahap pelatihan serta mengevaluasi efektivitas DenseNet121 dalam membangun sistem klasifikasi stroke berbasis citra MRI yang akurat dan efisien.

II. METODOLOGI PENELITIAN

Penelitian ini dilaksanakan melalui beberapa tahapan utama yang meliputi pengumpulan dataset citra MRI otak, proses *preprocessing* dan augmentasi data, pemodelan menggunakan arsitektur DenseNet121 berbasis *transfer learning*, proses pelatihan bertahap, serta evaluasi performa model. Alur tersebut disusun secara sistematis guna memastikan setiap tahapan saling terintegrasi dalam menghasilkan sistem klasifikasi stroke yang optimal.



Gambar 1. Diagram alur metodologi penelitian


II.1.Dataset

Dataset yang digunakan merupakan dataset publik citra MRI otak yang diperoleh dari platform Kaggle. Dataset terdiri dari dua kelas, yaitu citra otak dengan indikasi stroke dan citra otak non-stroke. Seluruh citra memiliki format .jpg dan .png dengan resolusi bervariasi. Dataset ini dipilih karena dapat merepresentasikan variasi kondisi pencitraan medis yang umum ditemukan pada pemeriksaan MRI.

II.2.Preprocessing Citra

Tahap *preprocessing* dilakukan untuk meningkatkan kualitas data masukan serta memastikan kesesuaian dengan spesifikasi model DenseNet121 [9]. Seluruh citra terlebih dahulu diubah ukurannya menjadi 224×224 piksel. Selanjutnya dilakukan konversi ke citra *grayscale* untuk mempermudah pengolahan intensitas serta mengurangi kompleksitas saluran warna.

Proses peningkatan kualitas citra dilakukan menggunakan teknik *histogram equalization* guna memperbaiki kontras citra sehingga struktur area lesi terlihat lebih jelas. Untuk mereduksi gangguan *noise* digunakan *Gaussian blur* dengan kernel kecil. Tahapan terakhir adalah normalisasi intensitas piksel ke rentang 0–1 agar distribusi data sesuai dengan kebutuhan proses pelatihan model.



Gambar 2. Contoh Hasil *Preprocessing* Citra MRI

II.3.Pembagian Dataset dan Augmentasi

Dataset hasil preprocessing dibagi menjadi data latih dan data validasi menggunakan rasio 80%:20%. Untuk meningkatkan variasi data latih dan mengurangi risiko overfitting, diterapkan teknik data augmentation. Proses augmentasi meliputi rotasi citra secara acak, pergeseran horizontal dan vertikal, *zoom in* dan *zoom out*, pembalikan horizontal dan vertikal, serta penyesuaian kecerahan citra.

Augmentasi menghasilkan penambahan variasi citra sintetis yang memiliki karakteristik visual menyerupai data asli sehingga model dapat belajar dari representasi fitur yang lebih luas [10].

II.4.Arsitektur Model DenseNet121

Model klasifikasi dibangun menggunakan arsitektur DenseNet121 yang telah dipretrain pada dataset ImageNet. Lapisan klasifikasi bawaan pada DenseNet121 dihilangkan sehingga model berfungsi sebagai *feature extractor*. *Output backbone* disambungkan dengan lapisan *Global Average Pooling* yang berfungsi merangkum fitur spasial menjadi vektor fitur global.

Pada tahap klasifikasi, digunakan dua lapisan *fully connected* dengan aktivasi ReLU serta lapisan *dropout* bertingkat untuk mengurangi *overfitting*. Lapisan terakhir menggunakan fungsi aktivasi *softmax* dengan dua neuron untuk membedakan kategori stroke dan non-stroke.

II.5. Proses Pelatihan Model

Pelatihan dilakukan secara bertahap melalui tiga fase utama. Tahap pertama adalah *initial training*, di mana seluruh parameter *backbone* DenseNet121 dibekukan sehingga pelatihan hanya dilakukan pada lapisan klasifikasi tambahan. Tahap kedua adalah *fine-tuning*, dengan membuka sebagian layer DenseNet121 agar mampu beradaptasi terhadap fitur spesifik citra MRI. Tahap ketiga adalah *deep fine-tuning* dengan

membuka lebih banyak layer *backbone* untuk memungkinkan optimalisasi parameter secara menyeluruh.

Optimizer Adam digunakan dengan *learning rate* bertingkat sesuai tahapan pelatihan. Untuk menjaga kestabilan proses pelatihan dan menghindari *overfitting*, diterapkan *callback EarlyStopping* dan *ReduceLROnPlateau*.

II.6. Evaluasi Model

Evaluasi model dilakukan untuk mengukur kinerja klasifikasi DenseNet121 terhadap data validasi. Beberapa metrik digunakan sebagai tolok ukur performa, yaitu *accuracy*, *precision*, *recall*, dan *F1-score*. *Accuracy* menggambarkan persentase prediksi yang benar terhadap seluruh data uji. *Precision* mengukur ketepatan model dalam mengklasifikasikan citra ke kelas tertentu, sedangkan *recall* menunjukkan kemampuan model dalam mendeteksi seluruh data positif, terutama kasus stroke. *F1-score* digunakan sebagai metrik gabungan untuk menilai keseimbangan antara *precision* dan *recall*.

Selain perhitungan metrik kuantitatif, dilakukan pula analisis confusion matrix untuk mengidentifikasi tipe kesalahan prediksi yang terjadi pada masing-masing kelas. *Confusion matrix* memberikan gambaran jumlah data yang diklasifikasikan secara benar dan salah, sehingga dapat diketahui kecenderungan model dalam melakukan kesalahan klasifikasi.

Evaluasi tambahan dilakukan melalui observasi terhadap kurva *training* dan *validation accuracy* serta *loss* selama proses pelatihan. Analisis kurva ini bertujuan untuk mendeteksi potensi *overfitting* maupun *underfitting*. Model dianggap memiliki performa optimal apabila terjadi peningkatan yang konsisten pada nilai *accuracy* dan penurunan *loss*, tanpa terdapat kesenjangan besar antara data latih dan validasi.

III. HASIL DAN ANALISIS

III.1 Hasil Pelatihan Model

Pelatihan model dilakukan melalui tiga tahap utama, yaitu *initial training*, *fine-tuning*, dan *deep fine-tuning*. Setiap tahap menunjukkan peningkatan performa yang konsisten baik dari sisi akurasi maupun penurunan nilai *loss*. Pada tahap *initial training*, lapisan *backbone* DenseNet121 dibekukan dan hanya lapisan klasifikasi yang dilatih untuk beradaptasi terhadap dataset citra MRI otak. Parameter pelatihan disesuaikan menggunakan optimizer Adam dan fungsi *Binary Crossentropy*.

Hasil tahap awal menunjukkan bahwa model mampu mencapai akurasi validasi sebesar 87,62% dengan nilai *validation loss* sebesar 0,3138, menandakan bahwa fitur dasar yang diekstraksi sudah cukup representatif untuk membedakan kelas stroke dan non-stroke.

Tahap pelatihan dilanjutkan dengan *fine-tuning*, dimana beberapa lapisan akhir DenseNet121 mulai diaktifkan untuk mempelajari representasi fitur yang lebih spesifik. Tahap ini menghasilkan peningkatan akurasi yang cukup signifikan hingga mencapai 94,50% dengan nilai *validation loss* turun menjadi 0,1416.

Pada fase terakhir, yaitu *deep fine-tuning*, dilakukan pembukaan lapisan *backbone* yang lebih luas disertai penurunan *learning rate* menjadi 5×10^{-6} guna menjaga stabilitas perubahan bobot. Tahap ini berhasil menghasilkan kinerja tertinggi dengan akurasi validasi sebesar 97,25% dan nilai *validation loss* terendah yaitu 0,0786.


Rekapitulasi performa tiap tahap pelatihan disajikan pada Tabel 1.

Tabel 1. Perbandingan Performa DenseNet121 pada Setiap Tahap *Training*

Tahap Pelatihan	Epoch	Akurasi Validasi (%)	Validation Loss
-----------------	-------	----------------------	-----------------

<i>Initial Training</i>	8	87,62	0,3138
<i>Fine-Tuning</i>	20	94,50	0,1416
<i>Deep Fine-Tuning</i>	15	97,25	0,0786

III.2 Analisis Kurva Pelatihan



Gambar 3. Kurva *Training Accuracy* – *Validation Accuracy* dan *Training Loss* – *Validation Loss* model DenseNet121 pada tahap *deep fine-tuning*.

Berdasarkan kurva akurasi pada Gambar 3, terlihat bahwa nilai *training accuracy* meningkat secara konsisten dari *epoch* awal hingga akhir, sejalan dengan peningkatan nilai *validation accuracy* yang mencapai lebih dari 97% pada *epoch* terakhir. Tidak terlihat perbedaan yang ekstrem antara kedua kurva, menunjukkan bahwa model mampu melakukan generalisasi dengan baik terhadap data validasi.

Pada kurva *loss*, baik *training* maupun *validation loss* memperlihatkan tren penurunan stabil sepanjang proses pelatihan. Nilai *validation loss* menurun dari sekitar 0,16 menjadi 0,078, sedangkan *training loss* turun dari sekitar 0,30 menjadi 0,17. Pola ini memperlihatkan bahwa proses optimasi berjalan efektif dan tidak menunjukkan gejala *overfitting* yang signifikan.

Konsistensi antara kenaikan nilai akurasi dan penurunan nilai *loss* membuktikan bahwa strategi pelatihan bertahap yang digunakan, disertai penyesuaian *learning rate* serta penerapan *early stopping* dan *ReduceLROnPlateau*, berhasil meningkatkan performa DenseNet121 secara optimal.

III.3 Evaluasi Klasifikasi

Evaluasi kinerja model dilakukan menggunakan data validasi sebesar 509 citra MRI yang terdiri atas dua kelas, yaitu stroke dan non-stroke. Metode evaluasi mencakup perhitungan *precision*, *recall*, dan *F1-score* untuk masing-masing kelas serta nilai akurasi keseluruhan. Hasil perhitungan metrik evaluasi disajikan pada Tabel 2.

Tabel 2. Hasil Evaluasi Klasifikasi DenseNet121

Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Support</i>
Non-Stroke	0,98	0,97	0,97	252
Stroke	0,97	0,98	0,97	257
Akurasi	0,97			509

III.4 Pembahasan

Berdasarkan seluruh hasil yang diperoleh, arsitektur DenseNet121 terbukti memiliki kapabilitas tinggi dalam menangani permasalahan klasifikasi citra MRI otak. Penerapan transfer learning memungkinkan model memanfaatkan fitur visual umum yang telah dipelajari pada dataset berskala besar (*ImageNet*) dan kemudian menyesuaikannya dengan domain medis melalui skema fine-tuning bertahap.

Analisis kurva pelatihan memperlihatkan proses pembelajaran yang stabil dan terkontrol, tanpa indikasi overfitting yang signifikan. Hasil evaluasi pun menunjukkan konsistensi tinggi antara *precision*, *recall*, dan *F1-score* dengan nilai rata-rata 0,97. Dengan demikian, model ini memiliki potensi besar untuk digunakan sebagai sistem pendukung diagnosis stroke yang bersifat objektif serta dapat membantu proses interpretasi citra MRI, khususnya di lingkungan layanan kesehatan dengan keterbatasan tenaga ahli.

IV. KESIMPULAN (10 PT)

Penelitian ini berhasil menerapkan arsitektur DenseNet121 untuk klasifikasi stroke pada citra MRI otak secara otomatis dengan performa yang sangat baik. Tahapan penelitian meliputi *preprocessing* citra, pembagian dataset menjadi data latih dan validasi (80:20), augmentasi data, serta pelatihan model secara bertahap yang terdiri atas *initial training*, *fine-tuning*, dan *deep fine-tuning*.

Pada tahap *initial training*, model mencapai akurasi validasi sebesar 87,62%, yang menunjukkan bahwa DenseNet121 telah mampu mengenali pola dasar citra MRI. Setelah dilakukan *fine-tuning* dengan membuka sebagian layer dan menyesuaikan parameter pembelajaran, performa meningkat signifikan dengan akurasi validasi sebesar 94,50%. Tahap akhir berupa *deep fine-tuning* menghasilkan performa terbaik dengan akurasi validasi mencapai 97,25% dan nilai validation loss sebesar 0,0786.

Evaluasi klasifikasi pada tahap akhir menunjukkan nilai rata-rata *precision*, *recall*, dan *F1-score* sebesar 0,97 untuk kedua kelas, yaitu stroke dan non-stroke, dengan distribusi data yang seimbang. Tingginya nilai *recall* pada kelas stroke mengindikasikan kemampuan model dalam mengidentifikasi kasus stroke secara efektif dengan tingkat kesalahan diagnosis yang rendah. Selain itu, kesesuaian antara nilai akurasi pelatihan dan validasi menunjukkan bahwa model mampu melakukan generalisasi dengan baik tanpa mengalami *overfitting* yang signifikan.

Berdasarkan seluruh hasil tersebut, dapat disimpulkan bahwa penggunaan arsitektur DenseNet121 sangat efektif untuk melakukan klasifikasi citra MRI otak, sehingga berpotensi besar digunakan sebagai sistem pendukung diagnosis stroke yang objektif dan efisien, khususnya pada fasilitas layanan kesehatan dengan keterbatasan tenaga ahli.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada panitia penyelenggara Seminar Nasional DISCOVER 2025 atas kesempatan yang diberikan untuk mempresentasikan dan mempublikasikan hasil penelitian ini. Ucapan terima kasih juga disampaikan kepada dosen pembimbing serta sivitas akademika Program Studi Sains Data Universitas Pembangunan Nasional “Veteran” Jawa Timur atas bimbingan, arahan, dan dukungan selama pelaksanaan penelitian.

REFERENSI

- [1] V. L. Feigin *et al.*, “World Stroke Organization: Global Stroke Fact Sheet 2025,” *International Journal of Stroke*, vol. 20, no. 2, pp. 132–144, Feb. 2025, doi: 10.1177/17474930241308142.
- [2] B. Kebijakan Pembangunan, K. Kementerian, and K. Ri, “DALAM ANGKA TIM PENYUSUN SKI 2023 DALAM ANGKA KEMENTERIAN KESEHATAN REPUBLIK INDONESIA,” 2023.
- [3] M. G. Lansberg, G. W. Albers, C. Beaulieu, and M. P. Marks, “Comparison of diffusion-weighted MRI and CT in acute stroke,” *Neurology*, vol. 54, no. 8, pp. 1557–1561, Apr. 2000, doi: 10.1212/WNL.54.8.1557.
- [4] E. H. Tedyanto, K. Tini, and N. A. K. Pramana, “Magnetic Resonance Imaging in Acute Ischemic Stroke,” *Cureus*, Jul. 2022, doi: 10.7759/cureus.27224.
- [5] J. A. Bojsen *et al.*, “Artificial intelligence for MRI stroke detection: a systematic review and meta-analysis,” *Insights Imaging*, vol. 15, no. 1, p. 160, Jun. 2024, doi: 10.1186/s13244-024-01723-7.
- [6] G. Huang, Z. Liu, L. van der Maaten, and K. Q. Weinberger, “Densely Connected Convolutional Networks,” Jan. 2018, [Online]. Available: <http://arxiv.org/abs/1608.06993>
- [7] R. S. A, B. Sathish Babu, and S. Hiremath, “International Journal of INTELLIGENT SYSTEMS AND APPLICATIONS IN ENGINEERING Predicting Knee Osteoarthritis Progression Using DenseNet121 with Channel and Spatial Attention.” [Online]. Available: www.ijisae.org
- [8] K. Wang, P. Jiang, D. Kong, B. Sun, and T. Shen, “Improving Accuracy of Pneumonia Classification Using Modified DenseNet,” Aug. 01, 2023, *Institute for Ionics*. doi: 10.1007/s10278-023-00841-w.
- [9] I. M. O. Widyantara, A. T. A. P. Kusuma, and N. M. A. E. D. Wirastuti, “PREPROCESSING PADA SEGMENTASI CITRA PARU-PARU DAN JANTUNG MENGGUNAKAN ANISOTROPIC DIFFUSION FILTER,” *Majalah Ilmiah Teknologi Elektro*, vol. 14, no. 2, p. 6, Dec. 2015, doi: 10.24843/mite.2015.v14i02p02.
- [10] Dede Husen, “EVALUASI TEKNIK AUGMENTASI DATA UNTUK KLASIFIKASI TUMOR OTAK MENGGUNAKAN CNN PADA CITRA MRI,” *TEKNIMEDIA: Teknologi Informasi dan Multimedia*, vol. 5, no. 2, Dec. 2024, doi: 10.46764/teknimedia.v5i2.220.