

Penerapan Deep Learning pada Sistem Klasifikasi Tumor Otak Berbasis Citra CT Scan

Bela Agustina¹, Auliya Rahman Isnain²

bela_agustina@teknokrat.ac.id, auliyarahman@teknokrat.ac.id

Universitas Teknokrat Indonesia

Informasi Artikel

Diterima : 9 Mei 2024

Direview : 14 Mei 2024

Disetujui : 15 Jun 2024

Kata Kunci

Brain Tumor,
Classification,
Convolutional Neural
Network, CT Image, Deep
Learning

Abstrak

Deteksi dan klasifikasi tumor otak merupakan tantangan penting dalam bidang medis yang membutuhkan solusi yang cepat dan akurat. Dalam penelitian ini, kami mengusulkan penerapan Deep Learning pada sistem klasifikasi tumor otak berbasis citra CT scan. Kami menggunakan DenseNet sebagai model dasar dan melatihnya menggunakan dataset citra CT scan untuk membedakan antara kelas positif (tumor otak) dan kelas negatif (tanpa tumor otak). Selain itu, kami melakukan serangkaian eksperimen dengan variasi jumlah epoch untuk memahami perkembangan kinerja model selama proses pelatihan. Hasil evaluasi menunjukkan bahwa model kami mencapai akurasi tertinggi sebesar 0.92 pada epoch 100, dengan presisi, recall, dan F1 score yang stabil pada nilai yang tinggi. Meskipun terdapat fluktuasi dalam kinerja pada beberapa tahap pelatihan, model tetap menunjukkan performa yang stabil secara keseluruhan. Temuan ini menunjukkan bahwa penerapan Deep Learning dapat menjadi alat yang efektif dalam mendukung diagnosa penyakit otak yang kompleks.

Keywords

Brain Tumor, Classification,
CT Image, Convolutional
Neural Network, Deep
Learning

Abstract

Brain tumor detection and classification is an important challenge in the medical field that requires a fast and accurate solution. In this study, we propose the application of Deep Learning to a CT scan image-based brain tumor classification system. We use DenseNet as the base model and train it using CT scan image dataset to distinguish between positive class (brain tumor) and negative class (no brain tumor). In addition, we conducted a series of experiments with varying number of epochs to understand the development of the model's performance during the training process. The evaluation results show that our model achieved the highest accuracy of 0.92 at epoch 100, with precision, recall, and F1 score stabilizing at high values. Although there are fluctuations in performance at some stages of training, the model still shows stable performance overall. These findings suggest that the application of Deep Learning can be an effective tool in supporting the diagnosis of complex brain diseases.

A. Pendahuluan

Penyakit tumor otak, yang mencakup berbagai jenis dan tingkat keganasan, merupakan salah satu masalah kesehatan global yang mendesak. Keberadaan tumor otak dapat mengakibatkan dampak serius pada fungsi otak dan kualitas hidup penderitanya [1]. Menanggulangi penyakit ini memerlukan pendekatan holistik yang melibatkan diagnosis dini, pengobatan yang tepat, dan pemantauan berkelanjutan [2].

Dalam era teknologi informasi dan kedokteran yang semakin berkembang, citra medis, khususnya Citra Tomografi Komputer (*CT Scan*), telah menjadi landasan penting dalam proses diagnosa penyakit otak. Citra *CT Scan* memberikan gambaran detail dan struktural tentang otak, memungkinkan para profesional medis untuk mengidentifikasi kelainan atau perubahan yang terjadi. Namun, pengolahan manual citra *CT Scan* memerlukan keahlian tinggi dan memakan waktu, sehingga meningkatkan risiko kesalahan dan menghambat respons cepat terhadap kondisi pasien [3].

Di tengah kebutuhan mendesak untuk solusi yang lebih efisien dalam diagnosis tumor otak, terutama dalam hal identifikasi jenis tumor dengan cepat dan akurat, teknologi *Deep Learning* muncul sebagai kandidat yang menjanjikan. Melalui penerapan algoritma yang mampu belajar secara mandiri dari data, *Deep Learning* memiliki potensi untuk mengoptimalkan proses klasifikasi berbasis citra *CT Scan* [4]. Beberapa literatur menyebutkan bahwa penerapan teknologi ini telah memberikan kontribusi signifikan dalam peningkatan akurasi dan efisiensi diagnosa penyakit otak, namun terdapat juga tantangan-tantangan baru yang muncul seiring dengan evolusi teknologi.

Beberapa penelitian telah menyoroti keberhasilan *Deep Learning* dalam menganalisis citra medis salah satunya penelitian yang menunjukkan diagnosis COVID-19 menggunakan model *Convolutional Neural Network* (CNN) yang dilatih pada dataset citra sinar-X dada. Model ini dilatih secara bertahap dengan dataset yang berbeda untuk mencapai akurasi dan performa maksimum. Teknik *preprocessing* data, termasuk keseimbangan dataset, analisis manual citra sinar-X, dan augmentasi data, digunakan untuk meningkatkan performa model. Model CNN menunjukkan hasil yang menjanjikan dalam kedua skenario pengujian, menunjukkan potensinya dalam diagnosis COVID-19. Hasil dari penelitian ini adalah pengembangan model CNN yang efisien dan efektif dalam mendeteksi penyakit COVID-19 dari citra sinar-X dada dengan akurasi mode sebesar 99.5% [5].

Penelitian lain bertujuan untuk mengembangkan model klasifikasi biner menggunakan algoritma CNN untuk membedakan gambar histologi kanker payudara berkualitas baik dan buruk. Metode ini melibatkan analisis ROI, pelatihan model CNN, evaluasi, dan analisis. Hasil penelitian menunjukkan bahwa model yang dikembangkan memiliki kinerja yang lebih baik dibandingkan dengan model-model terkini, dengan akurasi sekitar 80% [6].


Melalui tinjauan literatur ini, penelitian ini bertujuan untuk memperdalam pemahaman terhadap kontribusi positif dan tantangan yang terkait dengan penerapan *Deep Learning* pada sistem klasifikasi tumor otak berbasis citra *CT Scan*. Dengan demikian, penelitian ini diharapkan dapat memberikan kontribusi berarti dalam pengembangan solusi yang lebih holistik dan efektif dalam mendukung diagnosa dan penanganan penyakit tumor otak.

B. Metode Penelitian

Metode penelitian untuk penerapan *Deep Learning* pada sistem klasifikasi tumor otak berbasis citra CT Scan dapat dibagi menjadi beberapa tahapan utama, yang mencakup pengumpulan data, pra-pemrosesan data, pembangunan model *Deep Learning* dan evaluasi model.

Dataset

Dataset yang digunakan berasal dari "*Brain MRI Images for Brain Tumor Detection*" yang tersedia di platform Kaggle dengan tautan <https://www.kaggle.com/datasets/navoneel/brain-mri-images-for-brain-tumor-detection>, yang dibuat oleh Navoneel Chakrabarty. Dataset ini terdiri dari 253 file citra CT scan otak yang terbagi menjadi dua kelas: "no" dan "yes". Kelas "no" mencakup citra CT scan dari pasien yang tidak memiliki tumor otak, sedangkan kelas "yes" mencakup citra CT scan dari pasien yang memiliki tumor otak. Jumlah citra dalam kelas "no" adalah 98, sedangkan jumlah citra dalam kelas "yes" adalah 155. Adanya label yang tepat untuk setiap citra memungkinkan untuk pelatihan dan evaluasi model klasifikasi tumor otak dengan *Deep Learning* secara akurat. Sampel dataset dapat dilihat pada Gambar 1.



Gambar 1. Sampel Citra CT Scan Tumor Otak

Pra-pemrosesan Data

Pra-Pemrosesan Data merupakan tahap awal dalam persiapan citra CT Scan sebelum dilibatkan dalam model *Deep Learning*. Langkah pra-pemrosesan data dilakukan untuk memastikan kualitas dan relevansi informasi dalam citra sebelum dimasukkan ke dalam model *Deep Learning* [7].

Perancangan Model

Dalam penelitian ini, arsitektur model *Deep Learning* yang diadopsi adalah DenseNet (*Densely Connected Convolutional Networks*), sebuah jenis arsitektur CNN yang telah terbukti efektif dalam berbagai tugas pemrosesan citra. Struktur koneksi yang padat pada DenseNet memungkinkan informasi untuk beredar lebih efisien melalui jaringan, mengurangi masalah hilangnya informasi yang sering terjadi dalam jaringan yang lebih dalam [8]. DenseNet memiliki keunggulan dalam memanfaatkan kembali fitur-fitur yang diekstraksi melalui koneksi langsung antara lapisan-lapisan. Ini dapat meningkatkan kinerja model dengan memungkinkan informasi untuk tetap terjaga dan digunakan kembali dalam proses klasifikasi [9].

Pelatihan Model

Model *deep learning* akan dilatih menggunakan framework TensorFlow. Proses pelatihan melibatkan pembagian data penelitian menjadi tiga set: *training*, *validation*, dan *testing*. Dataset *training* digunakan untuk melatih model, *validation* untuk mencegah *overfitting*, dan *testing* untuk evaluasi akhir [10].

Evaluasi Model

Untuk mengetahui performanya, model *deep learning* dievaluasi pada dataset validasi dan testing menggunakan *Confusion matrix*. *Confusion matrix* adalah tabel menggambarkan hasil klasifikasi berdasarkan empat kemungkinan [11], seperti yang ditampilkan pada Tabel 1.

Tabel 1. Metrik Evaluasi Model

<i>Confusion Matrix</i>	Prediksi Positif	Prediksi Negatif
Aktual Positif	True Positive (TP)	False Negative (FN)
Aktual Negatif	False Positive (FP)	True Negative (TN)

Berdasarkan parameter TP, FP, FN, dan TN, nilai presisi, recall, dan akurasi dapat ditentukan. *Precision* mengacu pada tingkat ketepatan deteksi yang dihasilkan oleh suatu sistem. *Recall* mengacu pada tingkat keberhasilan dalam melakukan deteksi. Akurasi adalah metrik yang digunakan untuk mencari keseimbangan antara *precision* dan *recall* [12]. Nilai *precision*, *recall*, dan akurasi dapat diperoleh dengan perhitungan sebagai berikut.

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \quad (1)$$

$$Precision = \frac{TP}{TP + FP} \quad (2)$$


$$Recall = \frac{TP}{TP + FN} \quad (3)$$

$$F1\ Score = 2 \frac{(recall * precision)}{(recall + precision)} \quad (4)$$

C. Hasil dan Pembahasan


Hasil Pemrosesan Data

Hasil pra-pemrosesan ini melibatkan serangkaian teknik mulai dari konversi format citra hingga penghapusan operasi morfologi dan identifikasi area otak yang relevan. Alur tahapan pra-pemrosesan dapat dilihat pada Gambar 2.



Gambar 2. Tahap Pra-pemrosesan Data

Berdasarkan Gambar 2, proses ini dimulai dengan konversi citra ke format skala abu-abu untuk memudahkan analisis selanjutnya [13]. Kemudian, dilakukan pengaburan Gaussian untuk mengurangi noise dan memperhalus citra [14]. Citra hasilnya ditreshold untuk membentuk citra biner, di mana hanya piksel dengan intensitas tertentu yang dipertahankan. Operasi morfologi, seperti erosi dan dilasi, diterapkan untuk menghilangkan noise dan meningkatkan kualitas citra biner. Kontur dalam citra biner diidentifikasi untuk mengisolasi area otak, dan area ini dipilih sebagai *Region of Interest* (ROI) dengan mengambil kontur terbesar yang diasumsikan sebagai bagian otak. Selanjutnya, bounding box dibuat di sekitar ROI untuk membatasi area otak. Citra asli kemudian dipotong menggunakan *bounding box* untuk mempertahankan hanya bagian yang relevan. Intensitas citra dinormalisasi untuk menjaga konsistensi antara citra. Akhirnya, citra yang dipotong diresize ke ukuran yang diinginkan untuk persiapan analisis lebih lanjut. Visualisasi hasil dari pra-pemrosesan dapat dilihat pada Gambar 3.



Gambar 3. Visualisasi Pra-pemrosesan Data

Hasil Perancangan Model


Dalam implementasi ini, DenseNet yang telah dilatih pada dataset ImageNet digunakan sebagai model dasar, tanpa melibatkan lapisan teratas seperti yang dirangkum pada Tabel 2. Pilihan ini didasarkan pada kemampuan DenseNet dalam mengekstraksi fitur yang kuat dari citra, serta fleksibilitasnya untuk disesuaikan dengan tugas klasifikasi spesifik. Setelah ekstraksi fitur, lapisan-lapisan klasifikasi tambahan diperkenalkan. Pertama, *Global Average Pooling* diterapkan untuk mereduksi dimensi spasial citra menjadi vektor fitur 1D. Selanjutnya, lapisan *Dense* dengan 128 neuron dan fungsi aktivasi ReLU ditambahkan untuk memungkinkan pembelajaran representasi yang lebih kompleks. Dalam rangka mengatasi masalah overfitting, dropout dengan tingkat 0.5 diterapkan setelah lapisan *Dense*. Akhirnya, lapisan output dengan aktivasi sigmoid digunakan untuk menghasilkan prediksi klasifikasi tumor otak berdasarkan citra CT scan. Pengoptimalan model dilakukan dengan mengompilasi menggunakan *binary crossentropy* sebagai fungsi kerugian dan metode *optimizer* Adam dengan laju pembelajaran $1e-5$.

Tabel 2. Hasil Perancangan Model

Layer	Configuration
input	Shape: (224, 224, 3)
DenseNet Base Model	Weights: 'imagenet' Include Top: False Input Shape: (128, 128, 3) Trainable: False
GlobalAvgPooling2D	
Dense	Units: 128 Activation: ReLU Regularizer: L2 (0.001)
Dropout	Rate: 0.5
Dense	Units: 1 Activation: Sigmoid
Model Compilation	Loss: Binary Crossentropy Optimizer: Adam (Learning Rate: $1e-5$) Metrics: Accuracy

Hasil Evaluasi Model

Dalam evaluasinya, penelitian ini bereksperimen menggunakan variasi jumlah epoch di antaranya 50, 100, 150, 200, 250, dan 300. Pemilihan rentang *epoch* ini bertujuan untuk memperoleh pemahaman yang komprehensif tentang perkembangan kinerja model seiring berjalannya proses pelatihan [15]. Pada setiap tahap pelatihan, model dievaluasi terhadap sejumlah metrik performa yang meliputi akurasi, presisi, recall, dan F1 score. Hasil visualisasi evaluasi model dapat dilihat pada Gambar 3 dan dirangkum pada Tabel 3.



Gambar 4. Visualisasi Hasil Evaluasi Model

Tabel 3. Hasil Evaluasi Model

Epochs	Accuracy	Precision	Recall	F1 Score
50	0.84	0.857143	0.857143	0.857143
100	0.92	0.928571	0.928571	0.928571
150	0.92	0.928571	0.928571	0.928571
200	0.88	0.866667	0.928571	0.896552
250	0.92	0.928571	0.928571	0.928571
300	0.88	0.866667	0.928571	0.896552

Dalam evaluasi epoch-epoch yang dilakukan, kami mengamati perkembangan kinerja model CNN dalam klasifikasi tumor otak berdasarkan citra CT *scan*. Pada tahap awal, pada *epoch* 50, model menunjukkan kemampuan yang baik dengan akurasi 0.84 dan presisi, *recall*, serta F1 *score* yang stabil pada nilai 0.857143. Peningkatan yang signifikan terjadi pada *epoch* 100, di mana akurasi meningkat menjadi 0.92, disertai dengan kenaikan yang seimbang dalam presisi, *recall*, dan F1 *score*, masing-masing mencapai 0.928571. Kinerja model tetap stabil pada *epoch* 150, dengan nilai evaluasi yang tetap tinggi. Namun, pada epoch 200, terjadi sedikit penurunan dalam akurasi menjadi 0.88, serta penurunan dalam presisi dan F1 *score*, menunjukkan adanya kesulitan dalam membedakan kelas positif dan negatif. Pada epoch 250, kinerja model kembali stabil dengan akurasi yang meningkat kembali menjadi 0.92, dan nilai evaluasi lainnya yang kembali tinggi. Namun, tahap akhir pada epoch 300 menghadirkan penurunan kinerja kembali, dengan akurasi turun menjadi 0.88 dan presisi serta F1 *score* yang mengalami penurunan. Dari analisis ini, terlihat bahwa model menunjukkan performa yang stabil dan baik pada sebagian besar tahap pelatihan, meskipun terdapat fluktuasi dan penurunan kinerja pada beberapa tahap tertentu.

D. Simpulan

Penelitian ini menghasilkan model *Convolutional Neural Network* (CNN) yang efektif dalam mengklasifikasikan tumor otak berdasarkan citra CT *scan*. Penggunaan DenseNet sebagai model dasar dengan penambahan lapisan-lapisan klasifikasi tambahan telah memberikan hasil yang memuaskan dalam peningkatan akurasi dan performa model. Meskipun terdapat tantangan seperti fluktuasi dan penurunan kinerja pada beberapa tahap pelatihan, hasil evaluasi secara

keseluruhan menunjukkan bahwa model kami memiliki potensi untuk digunakan dalam aplikasi praktis untuk deteksi tumor otak.

Hasil evaluasi menunjukkan bahwa model mencapai akurasi tertinggi sebesar 0.92 pada epoch 100, dengan presisi, recall, dan F1 score yang stabil pada nilai yang tinggi. Meskipun terdapat fluktuasi pada beberapa tahap pelatihan, model tetap menunjukkan performa yang stabil dan baik secara keseluruhan.

E. Referensi

- [1] A. Dutz *et al.*, "Neurocognitive function and quality of life after proton beam therapy for brain tumour patients," *Radiotherapy and Oncology*, vol. 143, pp. 108–116, Feb. 2020, doi: 10.1016/j.radonc.2019.12.024.
- [2] P. Jain and S. Santhanalakshmi, "Early Detection of Brain Tumor and Survival Prediction Using Deep Learning and An Ensemble Learning from Radiomics Images," in *2022 IEEE 3rd Global Conference for Advancement in Technology, GCAT 2022*, Institute of Electrical and Electronics Engineers Inc., 2022. doi: 10.1109/GCAT55367.2022.9971932.
- [3] B. Venkataramanaiah, K. Sambath Kumar, and K. Giridhar Reddy, "Brain Disorders Identification by Machine Learning Classifiers," in *Journal of Physics: Conference Series*, Institute of Physics, 2023. doi: 10.1088/1742-6596/2466/1/012036.
- [4] Y. Hou and M. Navarro-Cía, "A computationally-inexpensive strategy in CT image data augmentation for robust deep learning classification in the early stages of an outbreak," *Biomed Phys Eng Express*, vol. 9, no. 5, Sep. 2023, doi: 10.1088/2057-1976/ace4cf.
- [5] A. A. Reshi *et al.*, "An Efficient CNN Model for COVID-19 Disease Detection Based on X-Ray Image Classification," *Complexity*, vol. 2021, 2021, doi: 10.1155/2021/6621607.
- [6] L. H. Al Fryan, M. I. Shomo, and M. B. Alazzam, "Application of Deep Learning System Technology in Identification of Women's Breast Cancer," *Medicina (Lithuania)*, vol. 59, no. 3, Mar. 2023, doi: 10.3390/medicina59030487.
- [7] P. Gong, Y. Ma, C. Li, X. Ma, and S. H. Noh, "Understand Data Preprocessing for Effective End-to-End Training of Deep Neural Networks," Apr. 2023, [Online]. Available: <http://arxiv.org/abs/2304.08925>
- [8] G. Huang, Z. Liu, G. Pleiss, L. Van Der Maaten, and K. Q. Weinberger, "Convolutional Networks with Dense Connectivity," *IEEE Trans Pattern Anal Mach Intell*, vol. 44, no. 12, pp. 8704–8716, Dec. 2022, doi: 10.1109/TPAMI.2019.2918284.
- [9] B. Qi, H. Sun, X. Gao, H. Zhang, Z. Li, and X. Liu, "Reusing Deep Neural Network Models through Model Re-engineering," Apr. 2023, [Online]. Available: <http://arxiv.org/abs/2304.00245>
- [10] K. M. Kahloot and P. Ekler, "Algorithmic Splitting: A Method for Dataset Preparation," *IEEE Access*, vol. 9, pp. 125229–125237, 2021, doi: 10.1109/ACCESS.2021.3110745.
- [11] K. Riehl, M. Neunteufel, and M. Hemberg, "Hierarchical confusion matrix for classification performance evaluation," Jun. 2023, doi: 10.1093/jrsssc/qlad057.

-
- [12] I. Susmitha, R. J. Femila, and V. Sivasamy, "Detection of forest fire using support vector machine in comparison with random forest to measure accuracy, precision and recall," in *International Conference on Cyber Resilience, ICCR 2022*, Institute of Electrical and Electronics Engineers Inc., 2022. doi: 10.1109/ICCR56254.2022.9995895.
 - [13] Z. N. Khudhair *et al.*, "Color to Grayscale Image Conversion Based on Singular Value Decomposition," *IEEE Access*, vol. 11, pp. 54629–54638, 2023, doi: 10.1109/ACCESS.2023.3279734.
 - [14] M. K. Chung, "Gaussian kernel smoothing," Jul. 2020, [Online]. Available: <http://arxiv.org/abs/2007.09539>
 - [15] A. Zinchenko, E. Neznakhina, S. Sorokin, D. Kornilov, and D. Lapaev, "Comprehensive model of corporate training development system," in *E3S Web of Conferences*, EDP Sciences, Apr. 2023. doi: 10.1051/e3sconf/202338001039.