

Klasifikasi Tumor Otak Berbasis Data MRI dengan Algoritma *Convolutional Neural Network* (CNN)

Mariano Charlos Patiatma^{a1}, I Wayan Santiyasa^{a2}, I Made Widiartha^{a3}, I Gusti Ngurah Anom Cahyadi Putra^{a4}

Program Studi Informatika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Udayana, Bali, Indonesia

1charlospatiatma106@student.unud.ac.id

2santiyasa@unud.ac.id

3madewidiartha@unud.ac.id

4anom.cp@unud.ac.id

Abstract

Early and accurate detection of brain tumors is crucial for supporting appropriate clinical decision-making, given that this condition is classified as a serious neurological disorder. Magnetic Resonance Imaging (MRI) is one of the modalities widely used for brain examinations due to its ability to display soft tissue structures in detail. This study proposes a brain tumor classification method using a Convolutional Neural Network (CNN) model combined with the Local Binary Pattern (LBP) feature extraction technique to improve texture representation in MRI images. This study used 5,266 MRI images, divided into three groups: glioma, meningioma, and no tumor. Before the training stage, all images underwent resizing, normalization, and feature extraction using the LBP method.. The data was then divided into 3,403 training images, 852 validation images, and 1,011 test images. The designed CNN architecture consists of three convolutional layers, each followed by max pooling, followed by global average pooling, a fully connected layer, dropout, and a classification layer with a softmax function. Test results showed the model achieved a training accuracy of 98.53%, a validation accuracy of 94.24%, and a testing accuracy of 92.28%. These results indicate that the proposed approach is capable of delivering stable classification performance while maintaining generalization ability to MRI data the model has never encountered before.

Keywords: Brain Tumor, Magnetic Resonance Imaging, Convolutional Neural Network, Deep Learning, Image Classification

1. Pendahuluan

Ketepatan dan kecepatan diagnosis menjadi faktor krusial dalam penanganan tumor otak, sebab penyakit ini dapat mengganggu fungsi sistem saraf dan memperbesar risiko komplikasi apabila penanganannya tertunda. MRI banyak dimanfaatkan dalam proses diagnosis karena kemampuannya menampilkan struktur jaringan otak secara detail. Meski begitu, pembacaan citra MRI secara manual masih sangat bergantung pada pengalaman tenaga medis dan membutuhkan waktu yang tidak sedikit, sehingga otomatisasi proses klasifikasi menjadi kebutuhan yang relevan untuk dikembangkan. [1]-[3]

Kehadiran teknologi Deep Learning, membuka peluang baru khususnya CNN dalam menganalisis citra medis dengan akurasi yang cukup menjanjikan. Beberapa studi terdahulu telah membuktikan efektivitas CNN dalam mendeteksi tumor otak, namun sebagian besar mengandalkan arsitektur yang cukup rumit sehingga membutuhkan sumber daya komputasi yang besar [4]-[8]. Kondisi ini mendorong perlunya pendekatan alternatif dengan struktur model yang lebih ringkas tanpa mengorbankan kualitas klasifikasi.

Menariknya, arsitektur yang rumit tidak otomatis menjamin akurasi yang lebih baik, semua tergantung apakah citra yang masuk ke jaringan sudah cukup “matang” secara informasi sebelum diproses. Local Binary Pattern (LBP) berperan di titik inilah: metode ini mengeluarkan pola tekstur dari citra terlebih dulu, sehingga CNN tidak perlu bekerja dari nol untuk menemukan sendiri pola tekstur lewat puluhan lapisan konvolusi. Bertolak dari logika ini muncul dugaan pada penelitian ini, bila LBP sudah

menyumbang informasi tekstur sejak awal, tiga lapisan konvolusi saja diperkirakan cukup untuk mencapai akurasi yang sebanding dengan arsitektur CNN dalam yang selama ini dipakai peneliti lain yang dimana menguji apakah kombinasi CNN ringkas dan LBP sanggup menandingi arsitektur CNN kompleks dalam tugas klasifikasi tumor otak.

Mengacu pada permasalahan tersebut, penelitian ini merancang model klasifikasi tumor otak dari citra MRI dengan memanfaatkan CNN yang dipadukan dengan ekstraksi fitur LBP. Dataset yang dipakai berjumlah 5.266 citra MRI yang dikelompokkan ke dalam tiga kategori, yakni glioma, meningioma, dan no tumor. Kinerja model dinilai menggunakan empat metrik, yaitu accuracy, precision, recall dan F1-score, guna mengetahui sejauh mana model mampu mengklasifikasikan citra MRI secara tepat.

2. Metode Penelitian

Penelitian ini menerapkan pendekatan kuantitatif berbasis data citra MRI. Rangkaian tahapannya mencakup pengumpulan dataset, preprocessing citra, ekstraksi fitur tekstur menggunakan LBP, pelatihan model CNN, hingga evaluasi performa akhir. Keseluruhan proses ini diarahkan untuk menghasilkan model yang mampu mengelompokkan citra MRI ke dalam tiga kategori, yaitu glioma, meningioma, dan no tumor.

2.1 Dataset


Data yang dipakai bersumber dari Brain Tumor MRI Dataset yang tersedia secara publik di Kaggle, terdiri dari 5.266 citra MRI otak ke dalam tiga kategori: glioma, meningioma, dan no tumor. Guna keperluan pelatihan dan evaluasi, dataset dibagi menjadi 3.403 citra untuk pelatihan, 852 citra untuk validasi, dan 1.011 citra untuk pengujian, sebagaimana ditampilkan pada Tabel 1.

Tabel 1. Distribusi Dataset

Kelas	Training	Validation	Testing	Total
Glioma	1.056	265	300	1.621
Meningioma	1.071	268	306	1.645
No Tumor	1.276	319	405	2.000
Total	3.403	852	1.011	5.266

2.2. Alur Penelitian

Proses penelitian diawali dengan pengumpulan citra MRI, dilanjutkan dengan prerprocessing untuk menyeragamkan ukuran dan mempersiapkan data sebelum masuk tahap penelitian. Citra kemudian diolah dengan metode LBP untuk memperoleh representasi tekstur yang lebih kaya informasi. Hasil ekstraksi fitur tersebut menjadi masukan bagi model CNN pada tahap pelatihan dan klasifikasi. Setelah pelatihan selesai, performa model diuji menggunakan data validasi dan pengujian. Alur lengkap penelitian dilihat pada Gambar 1.



Gambar 1. Flowchart Penelitian

2.3. Preprocessing dan Ekstraksi Fitur

Setiap citra terlebih dahulu diseragamkan menjadi 224 x 224 piksel, kemudian dinormalisasi nilai piksel agar konsisten. Selanjutnya, metode LBP diterapkan untuk menangkap karakteristik tekstur pada citra MRI. Informasi tekstur hasil ekstraksi ini kemudian dijadikan input bagi model CNN sehingga proses klasifikasi dapat memanfaatkan pola visual yang lebih kaya.

2.4. Arsitektur CNN

Model dibangun dengan tiga blok konvolusi, dimana setiap blok diikuti oleh lapisan max pooling untuk menekan dimensi fitur. Fitur yang dihasilkan selanjutnya diringkas melalui Global Average Pooling sebelum diteruskan ke dense layer dan dropout layer, lalu diklasifikasikan menggunakan fungsi softmax. Rancangan ini bertujuan menjaga model tetap ringan namun tetap efektif membedakan ketiga kelas citra MRI.

2.5. Parameter Pelatihan

Proses training memakai optimizer Adam dan fungsi loss categorical crossentropy. Learning rate ditetapkan sebesar 0,001, dengan batch size-nya 32 dan maksimum 50 epoch. Pemilihan learning rate ini didasarkan pada hasil uji coba awal yang menunjukkan performa validasi terbaik dibanding scenario lain. Rincian parameter tercantum pada tabel 2.

Tabel 2. Hyperparameter Model

Parameter	Nilai
Epoch	50
Batch Size	32
Optimizer	Adam
Learning Rate	0.001
Loss Function	Categorical Crossentropy

2.6. Evaluasi Model

Kemampuan klasifikasi model diuji terhadap data pengujian yang tidak dilibatkan dalam proses pelatihan. Penilaian dilakukan melalui metrik accuracy, precision, recall dan F1-score, dilengkapi confusion matrix untuk melihat pola prediksi yang tepat maupun kekeliruan yang masih muncul pada tiap kelas.

3. Hasil dan Pembahasan


3.1. Pengujian Learning Rate

Pengujian ini bertujuan mengetahui nilai learning rate yang memberi hasil pelatihan CNN paling optimal, dengan lima scenario yang di uji: 0,001; 0,003; 0,005; 0,007; dan 0,009. Hasilnya dilihat pada Tabel 3.

Tabel 3. Hasil Pengujian Learning Rate

Learning Rate	Validation Accuracy
0,001	95,60%
0,003	95,10%
0,005	94,70%
0,007	92,90%
0,009	94,40%


Learning rate 0,001 terbukti memberikan validation accuracy tertinggi, yakni 95,60. Kenaikan learning rate melewati angka tersebut justru cenderung menurunkan performa, karena pembaruan bobot model menjadi kurang stabil. Karena itu, nilai 0,001 dipilih sebagai parameter pada tahap pelatihan berikutnya.



Gambar 2. Grafik Learning Rate Terhadap Accuracy


3.2. Hasil Pelatihan Model

Model dilatih menggunakan 3.403 citra pelatihan dan 852 citra validasi selama maksimum 50 epoch. Perkembangan performa model diamati melalui grafik accuracy dan loss pada setiap epoch.



Gambar 3. Grafik Training Akurasi dan Validation Akurasi

Training akurasi bertahap meningkat sampai menyentuh 98,53%, sementara validation akurasi berada pada 94,24% di akhir pelatihan. Selisih kedua angka yang relatif kecil ini mengindikasikan model belajar dengan baik tanpa gejala overfitting yang signifikan.




Gambar 4. Grafik Training Loss dan Validation Loss

Sejalan dengan itu, kurva pelatihan loss dan validasi loss sama-sama menurun sepanjang pelatihan, menandakan model semakin baik dalam menekan kesalahan prediksi hingga mencapai kestabilan menjelang akhir proses.

3.3. Evaluasi Model

Evaluasi dilakukan menggunakan 1.011 citra pengujian yang tidak digunakan selama proses pelatihan. Tahap ini bertujuan agar mengukur kemampuan model dalam mengklasifikasikan citra MRI ke dalam tiga kelas yang telah ditentukan.



Gambar 5. Confusion Matrix Testing

Confusion matrix memperlihatkan bahwa mayoritas citra terklarifikasi dengan tepat. Kekeliruan masih muncul pada sebagian citra glioma dan meningioma karena kemiripan karakteristik visual keduanya, sedangkan kelas no tumor justru menunjukkan hasil klasifikasi paling konsisten.

Tabel 4. Classification Report Testing


Kelas	Precision	Recall	F1-score
Glioma	0,9655	0,8400	0,8984
Meningioma	0,8497	0,9052	0,8766
No Tumor	0,9528	0,9975	0,9747
Macro Average	0,9227	0,9142	0,9165
Weighted Average	0,9232	0,9228	0,9223


Angka recall di Tabel 4 memperkuat gambaran dari confusion matrix tadi, glioma berada di posisi terendah (0.8400), jauh di bawah meningioma (0,9052) dan no tumor (0,9975) artinya dari seluruh citra glioma yang diuji, proporsi yang berhasil dikenali benar justru paling kecil dibanding dua kelas lain. Dugaan penyebabnya bisa ditelusuri dari dua arah. Dari sisi tampilan citra, glioma dan meningioma punya kemiripan mendasar, keduanya sama-sama muncul sebagai massa dengan sinyal yang lebih terang dibanding jaringan otak sekitarnya, dan pada citra yang kontrasnya kurang tajam, batas kedua massa ini bisa jadi susah dibedakan mata maupun model. Ditambah lagi, glioma punya sifat tumbuh dan menyusup ke jaringan sekitar dengan tepi yang kabur, pola LBP maupun pola yang ditangkap CNN jadi tumpang tindih untuk dua kelas ini.

Faktor kedua datang dari komposisi datanya sendiri, citra latih glioma cuma berjumlah (1.056), sedikit di bawah meningioma (1,071) dan cukup jauh di bawah no tumor (1.276), selisih ini bisa saja membuat model kurang banyak melihat variasi bentuk glioma selama proses belajarnya. Bandingkan dengan kelas no tumor yang sama sekali tidak punya massa abnormal untuk dikenali bentuk maupun batasannya, sehingga citranya jauh lebih seragam dan gampang dipisahkan dari dua kelas tumor, itulah kenapa recall dan F1-score no tumor jauh melampaui dua kelas lainnya. Meski begitu, testing accuracy 92,28% yang diraih model secara keseluruhan tetap terbilang baik. Untuk penelitian lanjutan, dua celah di atas bisa jadi titik perbaikan, menambah variasi data glioma lewat augmentasi, atau mencari metode ekstraksi tekstur yang lebih peka menangkap batas lesi yang kabur seperti pada kasus glioma.

3.4. Implementasi Sistem

Model CNN yang telah melalui proses pelatihan kemudian diintegrasikan ke dalam aplikasi berbasis web untuk memudahkan proses klasifikasi citra MRI. Pengguna hanya perlu mengunggah citra MRI melalui antarmuka sistem, kemudian model akan memberikan hasil klasifikasi beserta tingkat keyakinan (*confidence score*) untuk setiap prediksi. Implementasi ini menunjukkan bahwa model tidak hanya memberikan performa yang baik pada tahap pengujian, tetapi juga dapat diterapkan sebagai pendukung proses identifikasi tumor otak secara otomatis





Hasil implementasi menunjukkan bahwa sistem mampu melakukan klasifikasi citra MRI ke dalam tiga kelas yaitu *glioma*, *meningioma* dan *no tumor* dengan menampilkan tingkat keyakinan prediksi untuk setiap citra yang di uji.

4. Kesimpulan

Penelitian ini berhasil merancang model klasifikasi tumor otak berbasis citra MRI dengan menggabungkan CNN dan ekstraksi fitur LBP. Model yang dibangun mampu mengelompokkan gambar ke dalam tiga kategori yang dimana terdapat meningioma, glioma, dan no tumor – dengan capaian training akurasi 98,53%, validation akurasi 94,24% dan testing akurasi 92,28%

Hasil evaluasi memperlihatkan kemampuan generalisasi model yang cukup baik terhadap data baru yang belum pernah dipelajari sebelumnya. Meski arsitekturnya relatif sederhana, model ini tetap menunjukkan performa klasifikasi yang kompetitif, sehingga berpotensi dikembangkan lebih lanjut sebagai alat bantu identifikasi awal tumor otak berdasarkan citra MRI.

References

- [1] J. Ferlay et al., "Cancer statistics for the year 2020: An overview," *Int. J. Cancer*, vol. 149, no. 4, pp. 778–789, 2021, doi: 10.1002/ijc.33588.
- [2] S. Saeedi, S. Rezayi, H. Keshavarz, and S. R. Niakan Kalhori, "MRI-based brain tumor detection using convolutional deep learning methods and chosen machine learning techniques," *BMC Med. Inform. Decis. Mak.*, vol. 23, no. 1, pp. 1–17, 2023, doi: 10.1186/s12911-023-02114-6.
- [3] H. Alquran, M. Alslatie, A. Rababah, and W. A. Mustafa, "Improved Brain Tumor Segmentation in MR Images with a Modified U-Net," 2024. doi: 10.3390/app14156504.
- [4] V. B. Gianzurriell, F. Husnal, F. A. Wijaya, F. Fauzi, I. Paryudi, and I. Veritawati, "Analisis Gambar MRI Otak Untuk Mendeteksi Tumor Otak Menggunakan Algoritma CNN," *J. Informatics Adv. Comput.*, vol. 4, no. 2, pp. 14–18, 2023.
- [5] M. N. M. Hakim, A. B. Nugroho, and A. E. Minarno, "Prediksi Tumor Otak Menggunakan Metode Convolutional Neural Network," *Inform. Mulawarman J. Ilm. Ilmu Komput.*, vol. 17, no. 1, p. 48, 2023, doi: 10.30872/jim.v17i1.5246.
- [6] A. A. Asiri et al., "Brain Tumor Detection and Classification Using Fine-Tuned CNN with ResNet50 and U-Net Model: A Study on TCGA-LGG and TCIA Dataset for MRI Applications," *Life*, vol. 13, no. 7, 2023, doi: 10.3390/life13071449.
- [7] J. Miah, D. M. Cao, A. Sayed, S. Taluckder, and S. Haque, "Advancing Brain Tumor Detection : A Thorough Investigation of CNNs , Clustering , and SoftMax Classification in the Analysis of MRI Images," vol. 8, no. December, 2024.
- [8] M. M. Zahoor et al., "Brain Tumor MRI Classification Using a Novel Deep Residual and Regional CNN," *Biomedicines*, vol. 12, no. 7, pp. 1–19, 2024, doi: 10.3390/biomedicines12071395.

- [9] P. Paul, M. N. Islam, F. Rafsani, P. Khorasani, and S. B. Soumma, "Efficient Feature Extraction and Classification Architecture for MRI-Based Brain Tumor Detection," pp. 1–6, 2024, [Online]. Available: <http://arxiv.org/abs/2410.22619>
- [10] D. Gusman, "Politik Hukum Pergeseran Kekuasaan Kehakiman di Indonesia Pra Amandemen dan Pasca Amandemen Konstitusi," *Unes J. Swara Justisia*, vol. 8, no. 2, pp. 404–416, 2024, doi: 10.31933/jfz4ct23.