

Development of Deep Learning Model Based on Convolutional Neural Network (CNN) for Brain Tumor Classification Using MRI Images

May Rani Tabitha Sinaga¹, Bungaria Tampubolon², Nurfitri Humayro Daulay³, Dinie Triana⁴,
Aulia Hani⁵, Ferdianto Abangan Simanjuntak⁶, Arnita⁷

^{1,2,3,4,5,6,7}Program Studi Statistika, Univesitas Negeri Medan, Indonesia

Email: mayrani1805@gmail.com; bungariatp@gmail.com; nurfitrihumayro@gmail.com; dinietriana47@gmail.com;
auliaahani11@gmail.com; abangjuntaks18@gmail.com; arnita@unimed.ac.id

ABSTRAK

Klasifikasi tumor otak menggunakan citra MRI menghadirkan tantangan kritis dalam radiologi medis. Studi ini mengembangkan model pembelajaran mendalam berdasarkan Convolutional Neural Network (CNN) untuk mengklasifikasikan citra MRI otak ke dalam empat kategori: Normal, Glioma, Meningioma, dan Pituitari. Kumpulan data yang tersedia untuk umum dari Kaggle yang terdiri dari 20.672 citra digunakan, dengan pra-proses dan penambahan data yang diterapkan. Arsitektur model mencakup lapisan konvolusional, penyatuan, perataan, padat, dan putus sekolah, yang dioptimalkan menggunakan pengoptimal Adam dan fungsi kerugian crossentropy kategoris. Hasil evaluasi menunjukkan bahwa model mencapai akurasi keseluruhan sebesar 96% dengan skor f1 yang tinggi di semua kelas, khususnya untuk kelas Pituitari (0,98). Kontribusi utama dari studi ini terletak pada integrasi berbagai teknik penambahan data dan metode AI yang Dapat Dijelaskan (XAI), yang memungkinkan visualisasi area utama dalam citra MRI yang mendukung keputusan klasifikasi. Model yang diusulkan tidak hanya akurat tetapi juga menunjukkan generalisasi dan interpretabilitas yang kuat, menjadikannya alat yang menjanjikan untuk sistem pendukung keputusan klinis dalam diagnosis tumor otak.

Keyword: Tumor Otak; MRI; Jaringan Syaraf Konvolusional; Klasifikasi Citra

ABSTRACT

Brain tumor classification using MRI images presents a critical challenge in medical radiology. This study develops a deep learning model based on Convolutional Neural Network (CNN) to classify brain MRI images into four categories: Normal, Glioma, Meningioma, and Pituitary. A publicly available dataset from Kaggle consisting of 20,672 images was used, with preprocessing and data augmentation applied. The model architecture includes convolutional, pooling, flatten, dense, and dropout layers, optimized using the Adam optimizer and categorical crossentropy loss function. The evaluation results show that the model achieved an overall accuracy of 96% with high f1-scores across all classes, particularly for the Pituitary class (0.98). The main contribution of this study lies in the integration of diverse data augmentation techniques and Explainable AI (XAI) methods, enabling the visualization of key areas in MRI images that support classification decisions. The proposed model is not only accurate but also demonstrates strong generalization and interpretability, making it a promising tool for clinical decision support systems in brain tumor diagnosis.

Keyword: Brain Tumor; MRI; Convolutional Neural Network; Image Classification

Corresponding Author:

Bungaria Tampubolon,
Univesitas Negeri Medan,
Jl. William Iskandar Ps. V, Kabupaten Deli Serdang, Indonesia
Email: bungariatp@gmail.com



1. INTRODUCTION

Tumor otak merupakan penyakit serius yang memerlukan diagnosis dini dan akurat untuk meningkatkan prognosis pasien. Magnetic Resonance Imaging (MRI) menjadi metode utama dalam mendeteksi tumor otak karena kemampuannya menghasilkan citra detail jaringan otak. Namun, interpretasi

manual citra MRI memerlukan keahlian khusus dan rentan terhadap kesalahan. Oleh karena itu, metode Convolutional Neural Network (CNN) banyak digunakan dalam klasifikasi tumor otak karena kemampuannya mengekstraksi fitur spasial secara otomatis dan efisien dari citra medis yang kompleks (Husen, 2024). CNN dapat mengenali pola-pola penting pada citra tanpa perlu ekstraksi fitur manual yang memakan waktu (Amalia et. al., 2022).

Beberapa penelitian terdahulu menunjukkan kesamaan kasus dalam penggunaan CNN untuk klasifikasi tumor otak dengan dataset MRI yang mencakup kelas glioma, meningioma, pituitary, dan no tumor. Penelitian Husen (2024) menggunakan teknik augmentasi data seperti flipping, scaling, dan rotasi yang terbukti meningkatkan akurasi model hingga 92,97% dan mengurangi risiko overfitting. Penelitian lain menggunakan arsitektur AlexNet melaporkan akurasi sebesar 98,84% pada klasifikasi tumor otak dengan dataset serupa (Amalia et. al., 2022). Selain itu, studi yang mengaplikasikan arsitektur ResNet-50 juga menunjukkan hasil akurasi mencapai 96% (Septipalan, 2024). Studi lain yang menggunakan EfficientNetB3 dan MobileNetV2 menyoroti pentingnya keseimbangan antara efisiensi komputasi dan akurasi dalam klasifikasi tumor otak berbasis CNN (Lizard, 2023).

Inovasi utama dalam penelitian ini terletak pada penerapan teknik augmentasi data yang lebih variatif dan penggunaan Explainable AI (XAI) untuk meningkatkan interpretabilitas hasil klasifikasi. Selain itu, preprocessing yang meliputi konversi citra ke grayscale, resize ke dimensi seragam, dan normalisasi piksel ke rentang 0–1 dilakukan untuk menstandarkan input dan mempercepat pelatihan model. Pendekatan ini berbeda dari penelitian terdahulu yang umumnya hanya fokus pada peningkatan akurasi tanpa penekanan pada interpretabilitas model dan optimasi preprocessing secara menyeluruh (Husen, 2024).

Pemilihan CNN didasarkan pada kemampuannya dalam mengekstraksi fitur kompleks secara otomatis tanpa memerlukan ekstraksi fitur manual yang memakan waktu dan rentan kesalahan. CNN juga terbukti unggul dibandingkan metode machine learning tradisional seperti SVM dan ANN dalam klasifikasi citra medis (Andre, et. al., 2021). Metode preprocessing seperti normalisasi grayscale dan resize sangat penting untuk menstandarkan input citra sehingga model dapat belajar dengan lebih efisien dan menghindari bias intensitas piksel. Teknik augmentasi data juga krusial untuk memperkaya variasi data pelatihan, mengurangi overfitting, dan meningkatkan kemampuan generalisasi model pada data baru (Husen, 2024).

Dengan demikian, penelitian ini tidak hanya mengadopsi kekuatan CNN dalam klasifikasi tumor otak, tetapi juga mengintegrasikan teknik augmentasi dan XAI sebagai pembeda utama dari penelitian sebelumnya, sehingga menghasilkan model yang tidak hanya akurat tetapi juga dapat dipahami dan dipercaya oleh praktisi klinis.

2. RESEARCH METHOD

A. Kerangka Penelitian

Penelitian ini bertujuan untuk melakukan klasifikasi citra MRI otak ke dalam empat kelas, yaitu *Normal*, *Glioma*, *Meningioma*, dan *Pituitary* dengan menggunakan algoritma *Convolutional Neural Network* (CNN). CNN dipilih karena kemampuannya yang tinggi dalam mengenali pola visual kompleks pada citra medis. Dataset yang digunakan bersumber dari repositori publik Kaggle yang diunggah oleh pengguna bernama *guslovesmath*. Penelitian ini difokuskan pada pelatihan model CNN yang akurat dan efisien dalam mendeteksi jenis tumor otak berdasarkan gambar MRI (Anhar, 2023).

B. Tahap Persiapan Data

1) Sumber dan Karakteristik Data

Dataset terdiri atas empat kategori utama: *Normal*, *Glioma*, *Meningioma*, dan *Pituitary*. Seluruh gambar memiliki format .jpg atau .png dengan resolusi yang diseragamkan menjadi 150x150 piksel agar dapat diproses secara konsisten oleh model CNN. Jumlah data dibagi menjadi dua bagian, yaitu:

- Training set: 2.004 gambar otak *Normal*, 4.131 gambar tumor *Glioma*, 4.149 gambar tumor *Meningioma*, dan 3.803 gambar tumor *Pituitary*.
- Testing set: 1.062 gambar otak *Normal*, 2.176 gambar tumor *Glioma*, 2.242 gambar tumor *Meningioma*, dan 2.105 gambar tumor *Pituitary*. Secara keseluruhan, jumlah gambar dalam dataset mencapai 20.672 gambar, memberikan proporsi data yang cukup besar untuk pelatihan model secara optimal.

2) Preprocessing

Sebelum digunakan dalam pelatihan, dilakukan beberapa tahap praproses, yaitu (Mandle, 2022):

- Pemeriksaan kelengkapan data untuk memastikan semua gambar memiliki label, tidak rusak, dan distribusi antar kelas seimbang
- Normalisasi citra, yaitu mengubah nilai piksel dari rentang 0–255 menjadi 0–1

- c. Augmentasi data (hanya pada training set), menggunakan teknik rotasi acak, flip horizontal, zoom in/out, dan penyesuaian brightness. Tujuannya adalah untuk memperkaya variasi data dan mencegah overfitting

C. Tahap Pemodelan

1) Arsitektur Model CNN

Model CNN dibangun dalam bentuk model sekuensial dengan beberapa layer sebagai berikut (Diaz-Pernas, et. al., 2021):

- a. Conv2D, untuk mengekstrak fitur-fitur penting seperti tepi dan pola dari citra input.
- b. MaxPooling2D, untuk mengurangi dimensi spasial (downsampling).
- c. Flatten, untuk mengubah output dua dimensi dari hasil konvolusi menjadi vektor satu dimensi.
- d. Dense, sebagai lapisan klasifikasi utama.
- e. Dropout, sebagai teknik regularisasi untuk mencegah overfitting.

Proses arsitektur CNN dirancang agar mampu mendeteksi fitur visual spesifik dari tumor otak dengan efisiensi tinggi.

2) Kompilasi Model

Model dikompilasi menggunakan (Misbullah et. al., 2024):

- a. Optimizer: Adam
- b. Loss Function: Categorical Crossentropy (karena klasifikasi multi-kelas)
- c. Metrik evaluasi: Accuracy

D. Pelatihan dan Validasi Model

Model dilatih selama 20 epoch dengan ukuran batch sebesar 64. Data dibagi menjadi 70% untuk pelatihan, 20% untuk validasi, dan 10% untuk pengujian. Proses pelatihan dilakukan menggunakan GPU (seperti Google Colab T4 GPU) untuk mempercepat komputasi. Teknik Early Stopping diterapkan agar pelatihan dapat dihentikan secara otomatis apabila akurasi validasi tidak meningkat dalam beberapa epoch berturut-turut. (Husen, 2024)

E. Evaluasi Model

1) Metode Evaluasi

Evaluasi model dilakukan dengan menggunakan berbagai metrik berikut (Husen, 2024):

- a. Accuracy: presentase prediksi yang tepat
- b. Precision: ketepatan prediksi pada masing-masing kelas
- c. Recall: seberapa banyak data aktual tiap kelas berhasil dikenali
- d. F1-Score: rata-rata harmonis antara precision dan recall
- e. Macro Average: rata-rata metrik tiap kelas tanpa memperhatikan jumlah data
- f. Weighted Average: rata-rata metrik dengan mempertimbangkan jumlah data tiap kelas
- g. Confusion Matrix: visualisasi klasifikasi benar dan salah pada masing-masing kelas
- h. Learning Curve: grafik akurasi dan loss terhadap epoch untuk memantau overfitting atau underfitting

2) Visualisasi Hasil

Visualisasi hasil klasifikasi dilakukan dalam beberapa bentuk (Husen, 2024):

- a. Grafik akurasi dan loss selama pelatihan
- b. Confusion matrix yang menampilkan jumlah klasifikasi benar dan salah untuk keempat kelas

Prediksi hasil model terhadap contoh citra MRI, yang dibandingkan dengan label sebenarnya (misalnya citra MRI diprediksi sebagai Glioma).

3. RESULTS AND DISCUSSION

Data melalui proses Normalisasi menggunakan Metode Grayscale. Metode normalisasi grayscale adalah proses penskalaan nilai intensitas piksel pada gambar abu-abu (grayscale) agar berada dalam rentang tertentu, umumnya $[0, 1]$ atau $[0, 255]$, dengan tujuan untuk menstandarkan data input dan meningkatkan kinerja model dalam pengolahan citra. Gambar grayscale hanya memiliki satu kanal (channel), di mana setiap piksel merepresentasikan tingkat kecerahan, dari 0 (hitam) hingga 255 (putih).


Normalisasi ini biasanya dilakukan dengan membagi nilai piksel dengan 255, atau menggunakan metode lain seperti standardisasi z-score, tergantung kebutuhan. Normalisasi penting untuk mempercepat pelatihan model machine learning atau deep learning, menghindari dominasi nilai piksel besar, serta meningkatkan akurasi dan efisiensi pemrosesan citra.

Dari hasil normalisasi menggunakan metode Grayscale diperoleh hasil seperti di gambar :



Gambar 1. MRI Otak

Gambar MRI otak pada Gambar 1 menggambarkan adanya perubahan ukurannya menjadi 150x150 piksel. Gambar kemudian dikonversi ke array NumPy berdimensi (150, 150, 3) dan ditambahkan dimensi batch menjadi (1, 150, 150, 3), yang sesuai dengan format input untuk model deep learning. Selanjutnya, gambar dinormalisasi dengan membagi semua nilai piksel dengan nilai maksimum agar berada dalam rentang [0, 1]. Setelah itu, gambar dikonversi kembali ke format gambar untuk ditampilkan. Hasil visualisasi menunjukkan sebuah gambar MRI kepala berukuran kecil yang telah diproses dan siap digunakan untuk keperluan analisis atau pelatihan model, seperti klasifikasi medis.



Gambar 2. Pra-pemrosesan

Gambar tersebut menunjukkan tahapan pra-pemrosesan citra MRI otak yang terdiri dari empat langkah utama, dimulai dari citra asli berukuran 224x224 piksel dengan 3 kanal warna (RGB) dan nilai piksel 0–255. Selanjutnya, citra dikonversi menjadi grayscale dengan ukuran yang sama, menghilangkan informasi warna dan menyisakan satu kanal intensitas abu-abu. Setelah itu, citra di-resize menjadi 150x150 piksel untuk menyesuaikan dimensi input model yang lebih efisien, dengan sedikit perubahan nilai piksel akibat interpolasi. Tahap terakhir adalah normalisasi, yaitu mengubah nilai piksel menjadi skala 0–1 agar data lebih seragam dan mempercepat proses pembelajaran mesin. Keempat tahap ini bertujuan menyiapkan citra medis secara optimal untuk keperluan analisis atau pelatihan model deep learning.

Model Convolutional Neural Network (CNN) dilatih menggunakan dataset citra MRI otak yang terbagi menjadi beberapa kelas jenis tumor yaitu : Normal, Meningioma, Glioma, dan Pituitary.

```

Training Counts
{'Normal': 2004, 'Meningioma': 4149, 'Glioma': 4131, 'Pitui
tary': 3803}


Testing Counts
{'Normal': 1062, 'Meningioma': 2242, 'Glioma': 2176, 'Pitui
tary': 2105}
  
```

Gambar 3. Hasil Pengolahan

Pada data Training terdapat 2004 Gambar otak normal, 4149 Gambar tumor Meningioma, 4131 Gambar tumor Glioma, dan 3803 Gambar tumor Pituitary. Namun pada pengujian data terdapat 1062 Gambar otak normal, 2242 Gambar tumor Meningioma, 2176 Gambar tumor Glioma, dan 2105 Gambar tumor Pituitary.

A. Visualisasi Arsitektur Model

Gambar di bawah ini menunjukkan visualisasi arsitektur model Convolutional Neural Network (CNN) yang digunakan dalam penelitian ini.



Gambar 4. Visualisasi Arsitektur Model


Model terdiri atas beberapa blok utama, yaitu:

- Lapisan konvolusi (Conv2D) yang berfungsi mengekstraksi fitur spasial penting dari citra MRI, seperti tepi, tekstur, dan pola khas tumor.
- Lapisan pooling (MaxPooling2D) yang bertugas mereduksi dimensi fitur sekaligus mempertahankan informasi penting, sehingga mempercepat proses pelatihan dan mengurangi risiko overfitting.
- Lapisan flatten, yang mengubah hasil ekstraksi fitur dua dimensi menjadi vektor satu dimensi agar dapat diproses oleh lapisan fully connected.
- Lapisan dense (fully connected) yang mengolah fitur hasil ekstraksi untuk menghasilkan keputusan klasifikasi.
- Lapisan dropout yang secara acak menonaktifkan sejumlah neuron selama pelatihan guna meningkatkan generalisasi model dan mencegah overfitting.

Susunan arsitektur ini mencerminkan alur umum CNN dalam tugas klasifikasi citra medis, di mana proses ekstraksi fitur dilakukan secara bertahap sebelum pengambilan keputusan klasifikasi akhir.

B. Hasil Pelatihan Model

Untuk mengevaluasi performa model CNN dalam proses pelatihan, dilakukan visualisasi terhadap metrik akurasi dan nilai loss terhadap jumlah epoch. Gambar menunjukkan perbandingan akurasi dan loss antara data pelatihan dan data validasi selama 20 epoch pelatihan.



Gambar 5. Grafik Akurasi dan Loss

Pada grafik sebelah kiri, terlihat bahwa akurasi model meningkat tajam pada beberapa epoch pertama dan kemudian mengalami kenaikan yang lebih stabil. Akurasi data pelatihan mencapai lebih dari 99%, sementara akurasi validasi stabil di atas 95% setelah epoch ke-10. Hal ini menunjukkan bahwa model mampu mempelajari fitur penting dari data secara efektif dan memiliki kemampuan generalisasi yang baik terhadap data yang belum pernah dilihat. Sementara itu, grafik sebelah kanan menunjukkan penurunan nilai loss yang signifikan pada awal pelatihan, kemudian melambat dan stabil pada nilai rendah.

Meskipun terjadi sedikit fluktuasi pada loss validasi di beberapa epoch akhir, tren keseluruhan tetap menunjukkan perbaikan performa. Tidak tampak indikasi overfitting yang parah karena selisih antara loss pelatihan dan validasi relatif kecil.

Secara keseluruhan, grafik ini menunjukkan bahwa arsitektur CNN yang digunakan berhasil dilatih dengan baik dan menghasilkan model yang akurat dan stabil dalam klasifikasi tumor otak berbasis citra MRI.

C. Evaluasi Kinerja Model

Untuk menilai performa model CNN secara lebih menyeluruh, dilakukan evaluasi menggunakan metrik klasifikasi berupa precision, recall, dan f1-score terhadap masing-masing kelas.

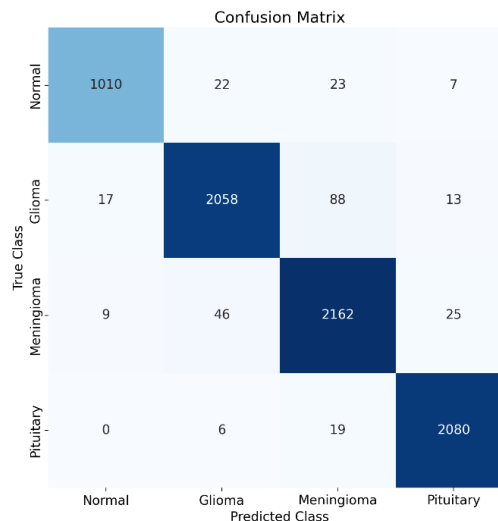
Tabel 1. Hasil evaluasi klasifikasi model CNN pada data uji berdasarkan masing-masing kelas tumor otak

Kelas	Precision	Recall	F1-Score	Jumlah Data (Support)
Normal	0.97	0.95	0.96	1,062
Glioma	0.97	0.95	0.96	2,176
Meningioma	0.94	0.96	0.95	2,242
Pituitary	0.98	0.99	0.98	2,105
Rata-rata Makro	0.97	0.96	0.96	7,585
Rata-rata Tertimbang	0.96	0.96	0.96	7,585
Akurasi Keseluruhan			0.96	

Berdasarkan Tabel 1, model CNN menunjukkan performa klasifikasi yang sangat baik untuk keempat kelas, dengan akurasi keseluruhan mencapai 96%. Kelas Pituitary tumor memiliki nilai f1-score tertinggi yaitu 0.98, menunjukkan bahwa model sangat andal dalam mengenali jenis tumor ini. Sementara itu, Meningioma memiliki f1-score sedikit lebih rendah (0.95), namun tetap menunjukkan kinerja yang kuat. Nilai precision dan recall yang seimbang di seluruh kelas mengindikasikan bahwa model tidak hanya mampu meminimalkan kesalahan prediksi positif palsu, tetapi juga mampu mendeteksi sebagian besar kasus yang benar (true positives). Rata-rata makro dan tertimbang (macro avg dan weighted avg) yang juga tinggi menunjukkan bahwa model tidak bias terhadap kelas dengan jumlah data yang lebih besar. Dengan demikian, model ini cukup handal untuk digunakan dalam klasifikasi tumor otak secara otomatis berbasis citra MRI.

D. Confusion matrix

Sebagai pelengkap analisis metrik klasifikasi, Figure 4 menyajikan confusion matrix model CNN pada seluruh data uji. Diagram ini memetakan distribusi prediksi (sumbu X) terhadap label sebenarnya (sumbu Y) untuk setiap kelas tumor otak, sehingga pola kesalahan model dapat diamati secara intuitif sebelum diinterpretasikan lebih lanjut pada uraian berikut.



Gambar 6. Grafik Akurasi dan Loss

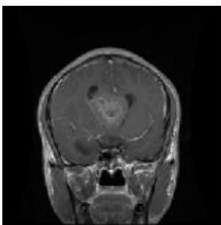
Gambar menampilkan confusion matrix yang menunjukkan performa model CNN dalam mengklasifikasikan citra MRI otak ke dalam empat kategori: Normal, Glioma, Meningioma, dan Pituitary. Model berhasil mengklasifikasikan 1.010 gambar Normal, 2.058 gambar Glioma, 2.162 gambar Meningioma, dan 2.080 gambar Pituitary dengan benar, ditunjukkan oleh warna biru paling gelap pada diagonal utama. Beberapa kesalahan klasifikasi juga terjadi, seperti 22 gambar Normal diklasifikasikan sebagai Glioma, 88 gambar Glioma sebagai Meningioma, dan 46 gambar Meningioma sebagai Glioma. Kesalahan terbesar terjadi antara kelas yang mirip secara visual, yaitu Glioma dan Meningioma. Secara umum, model menunjukkan performa klasifikasi yang sangat baik, terutama pada kelas Pituitary yang memiliki tingkat kesalahan paling rendah.

E. Hasil Prediksi Model

Untuk menguji kemampuan model dalam melakukan prediksi terhadap data baru, dilakukan pengujian menggunakan salah satu citra MRI otak yang belum pernah dilihat model sebelumnya. Citra ini diproses terlebih dahulu dengan mengubah ukuran (*reshape*) agar sesuai dengan dimensi input model, yaitu 150×150 piksel dan 1 channel (*grayscale*).

```
x reshaped: (1, 150, 150, 1)
Class name of the first image: Glioma

Out[27]:
```



Gambar 7. Hasil Prediksi Model

Model berhasil mengidentifikasi bahwa gambar MRI tersebut termasuk dalam kelas Glioma. Hal ini menunjukkan bahwa model mampu mengenali karakteristik visual khas dari tumor Glioma, seperti bentuk dan letaknya di dalam struktur otak. Prediksi ini menunjukkan bahwa model memiliki kemampuan generalisasi yang baik terhadap data baru, mendukung hasil evaluasi sebelumnya yang menunjukkan akurasi tinggi pada data validasi.

4. CONCLUSION

Penelitian ini berhasil mengembangkan model klasifikasi tumor otak berbasis citra MRI menggunakan algoritma Convolutional Neural Network (CNN) dengan akurasi yang tinggi sebesar 96%. Arsitektur model yang terdiri atas lapisan konvolusi, pooling, dan dense telah menunjukkan performa yang andal dalam membedakan empat jenis kategori tumor otak. Teknik augmentasi data dan penerapan Explainable AI (XAI) turut memperkuat kemampuan generalisasi model sekaligus meningkatkan interpretabilitas hasil klasifikasi. Dengan hasil evaluasi yang konsisten dan visualisasi prediksi yang jelas, model ini memberikan kontribusi signifikan sebagai solusi pendukung diagnosis dini dan akurat tumor otak, serta memiliki potensi untuk diterapkan dalam sistem klinis berbasis kecerdasan buatan.

REFERENCES

- Amalia, K., Magdalena, R., & Saidah, S. (2022). Klasifikasi penyakit tumor otak pada citra MRI menggunakan metode CNN. *e-Proceeding Engineering*, 8(6), 3247–3254.
- Andre, R., Wahyu, B., & Purbaningtyas, R. (2021). Klasifikasi tumor otak menggunakan convolutional neural network dengan arsitektur EfficientNet-B3. *Jurnal JUST IT*, 11(3), 55–59. <https://jurnal.umj.ac.id/index.php/just-it/index>
- Anhar, A., & Putra, R. A. (2023). Perancangan dan implementasi self-checkout system pada toko ritel menggunakan convolutional neural network (CNN). *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, 11(2), 466. <https://doi.org/10.26760/elkomika.v11i2.466>
- Díaz-Pernas, F. J., Martínez-Zarzuela, M., González-Ortega, D., & Antón-Rodríguez, M. (2021). A deep learning approach for brain tumor classification and segmentation using a multiscale convolutional neural network. *Healthcare*, 9(2). <https://doi.org/10.3390/healthcare9020153>
- Fadlia, N., & Kosasih, R. (2019). Klasifikasi jenis kendaraan menggunakan metode convolutional neural network (CNN). *Jurnal Ilmiah Teknologi dan Rekayasa*, 24(3), 207–215. <https://doi.org/10.35760/tr.2019.v24i3.2397>
- Harahap, F. A. A., Nafisa, A. N., Purba, E. N. D. B., & Putri, N. A. (2023). Implementasi algoritma convolutional neural network arsitektur model MobileNetV2 dalam klasifikasi penyakit tumor otak Glioma, Pituitary dan Meningioma. *Jurnal Teknologi Informasi, Komputer, dan Aplikasi (JTika)*, 5(1), 53–61. <https://doi.org/10.29303/jtika.v5i1.234>
- Husen, D. (2024). Klasifikasi citra MRI tumor otak menggunakan metode convolutional neural network. *bit-Tech*, 7(1), 143–152. <https://doi.org/10.32877/bt.v7i1.1576>
- Lizard, D., Dimara, S., Putri, S. W., & Amelia, R. (2023). Penerapan convolutional neural network (CNN) dalam klasifikasi citra MRI untuk deteksi tumor otak manusia. *Jurnal Kernel*, 4(2), 70–77. <https://doi.org/10.31284/j.kernel.2023.v4i2.6960>
- Mandle, A. K., Sahu, S. P., & Gupta, G. P. (2022). CNN-based deep learning technique for the brain tumor identification and classification in MRI images. *International Journal of Software Science and Computational Intelligence*, 14(1), 1–20. <https://doi.org/10.4018/ijssci.304438>
- Misbullah, A., Mursyida, W., Farsiah, L., & Sukiakhy, K. M. (2024). Analisis performa segmentasi citra MRI tumor otak dengan arsitektur U-Net., 2(2), 83–95.

- Noor Santi, C. (2011). Mengubah citra berwarna menjadi grayscale dan citra biner Rina. *Teknologi Informasi DINAMIK*, 16(1), 14–19.
- Safrizal, M., & Harjoko, A. (2014). Perbandingan pewarnaan citra grayscale menggunakan metode K-Means Clustering dan Agglomerative Hierarchical Clustering. *Berita MIPA*, 23, 255–263. <https://media.neliti.com/media/publications/242368-perbandingan-pewarnaan-citra-grayscale-m-bee66374.pdf>
- Septipalan, M. L., Hibrizi, M. S., Latifah, N., Lina, R., & Bimantoro, F. (2024). Klasifikasi tumor otak menggunakan CNN dengan arsitektur ResNet50. *Seminar Nasional Teknologi dan Sains*, 3(1), 103–108. <https://doi.org/10.29407/stains.v3i1.4357>
- Supiyani, I., & Arifin, N. (2022). Identifikasi nomor rumah pada citra digital menggunakan neural network. *Methodika: Jurnal Teknik Informatika dan Sistem Informasi*, 8(1), 18–21. <https://doi.org/10.46880/mtk.v8i1.921>