

ANALISIS KINERJA ARSITEKTUR CNN *ALEXNET* DAN *VGG16* UNTUK KLASIFIKASI TUMOR OTAK

Agustina Diah Kusuma Dewi^{1*}, Efandra Eka Julita², Rizki Wahyu Yulianti³

Universitas Dian Nuswantoro, Semarang, Jawa Tengah, Indonesia¹

Email*: 111202214122@mhs.dinus.ac.id

Universitas Dian Nuswantoro, Semarang, Jawa Tengah, Indonesia²

Email: 111202214220@mhs.dinus.ac.id

Universitas Dian Nuswantoro, Semarang, Jawa Tengah, Indonesia³

Email: 111202214212@mhs.dinus.ac.id

(*) Corresponding Author

ABSTRAK

Deteksi dini tumor otak sangat penting dalam menentukan langkah pengobatan yang tepat dan meningkatkan tingkat kesembuhan pasien. Dalam penelitian ini, dilakukan analisis dan perbandingan kinerja dua arsitektur *Convolutional Neural Network* (CNN), yaitu *Alexnet* dan *VGG16*, dalam mengklasifikasikan citra MRI tumor otak ke dalam tiga kelas: *glioma*, *meningioma*, dan *pituitary*. Dataset yang digunakan telah melalui proses anotasi medis dan dibagi menjadi data pelatihan (80%) dan data pengujian (20%). Setiap citra mengalami *preprocessing* berupa *resize*, *normalisasi*, dan *augmentasi*. Kedua model diinisialisasi dengan bobot *pre-trained* dari *ImageNet* dan dilatih selama 15 epoch menggunakan algoritma Adam. Evaluasi performa dilakukan berdasarkan metrik akurasi, *precision*, *recall*, dan *F1-score*. Hasil penelitian menunjukkan bahwa *Alexnet* memberikan akurasi pengujian sebesar 78.99% dengan *F1-score* tertimbang 0.79, sedangkan *VGG16* memperoleh akurasi sebesar 78.01% dengan *F1-score* tertimbang 0.75. Meskipun *VGG16* memiliki arsitektur yang lebih dalam dan mampu mengenali fitur kompleks, *Alexnet* menunjukkan performa yang lebih stabil dan merata pada seluruh kelas tumor. Temuan ini menunjukkan bahwa *Alexnet* lebih efektif dalam klasifikasi citra MRI tumor otak pada dataset yang digunakan, serta memiliki potensi besar sebagai komponen dalam sistem pendukung keputusan medis berbasis *deep learning*.

Kata Kunci: *Alexnet*, CNN, klasifikasi tumor otak, MRI, *VGG16*

ABSTRACT

Early detection of brain tumors is essential for determining appropriate treatment strategies and increasing patient survival rates. This study analyzes and compares the performance of two *Convolutional Neural Network* (CNN) architectures *Alexnet* and *VGG16* for classifying brain tumor MRI images into three categories: *glioma*, *meningioma*, and *pituitary*. The dataset, annotated by medical experts, was split into 80% for training and 20% for testing. Each image underwent preprocessing steps including resizing, normalization, and data augmentation. Both models were initialized with pre-trained weights from *ImageNet* and trained for 15 epochs using the Adam optimizer. Model performance was evaluated using accuracy, precision, recall, and *F1-score* metrics. The results show that *Alexnet* achieved a testing accuracy of 78.99% with a weighted *F1-score* of 0.79, while *VGG16* obtained an accuracy of 78.01% and a weighted *F1-score* of 0.75. Although *VGG16* has a deeper architecture capable of capturing more

complex features, Alexnet demonstrated more stable and balanced performance across all tumor classes. These findings suggest that Alexnet is more effective for classifying brain tumor MRI images within the evaluated dataset and holds strong potential for integration into medical decision-support systems based on deep learning.

Keywords: *Alexnet*, brain tumor classification, CNN, MRI, *VGG16*

1. PENDAHULUAN

Tumor otak merupakan salah satu penyakit serius yang dapat mengancam jiwa manusia. Deteksi dini dan klasifikasi yang akurat terhadap jenis tumor otak sangat penting untuk menentukan langkah pengobatan yang tepat dan meningkatkan peluang kesembuhan pasien [1], [2], [3]. Dalam beberapa dekade terakhir, teknologi pengolahan citra medis telah mengalami perkembangan pesat, khususnya dengan kemajuan dalam bidang kecerdasan buatan dan pembelajaran mendalam (*deep learning*) [4].

Convolutional Neural Networks (CNN) merupakan salah satu metode *deep learning* yang telah terbukti efektif dalam berbagai aplikasi pengenalan pola dan klasifikasi citra, termasuk dalam bidang medis [3], [5], [6]. Dua arsitektur CNN yang populer dan masih banyak digunakan hingga saat ini adalah AlexNet dan VGG16. AlexNet dikenal sebagai pelopor arsitektur CNN modern dan menjadi tonggak penting dalam perkembangan *deep learning* setelah memenangkan kompetisi ImageNet pada tahun 2012 [7]. Arsitektur yang lebih dalam dengan penggunaan filter konvolusi berukuran kecil secara konsisten juga ditawarkan oleh model-model terbaru yang mengadopsi prinsip desain serupa dengan VGG16 dalam pengenalan citra berskala besar [8].

Penelitian sebelumnya menunjukkan bahwa *VGG16* mampu mencapai akurasi hingga 95.23% dalam klasifikasi tumor otak, dengan nilai *recall* 93.72%, *precision* 93.27%, dan *F1-score* 94.22% [9]. Sementara itu, *Alexnet* juga menunjukkan performa yang baik sebagai benchmark dalam klasifikasi citra tumor otak [9], [10]. Penggunaan transfer learning dan augmentasi data menjadi strategi penting untuk meningkatkan performa model [11], [12], [13].

Penelitian ini bertujuan untuk menganalisis dan membandingkan kinerja kedua arsitektur CNN tersebut dalam klasifikasi tumor otak berdasarkan citra MRI. Dengan menggunakan dataset tumor otak yang representatif, penelitian ini mengevaluasi akurasi, *precision*, *recall*, dan *F1-score* dari kedua model untuk menentukan arsitektur yang lebih efektif dalam mendukung diagnosis medis.

Melalui analisis ini, diharapkan dapat memberikan kontribusi dalam pengembangan sistem pendukung keputusan medis yang lebih akurat dan efisien, serta membuka peluang untuk penelitian lanjutan dalam pengaplikasian *deep learning* pada bidang kesehatan.


2. METODE

Tahapan Penelitian

Penelitian ini dilakukan melalui beberapa tahapan utama sebagai berikut:

- Pengumpulan Data: Mengumpulkan dataset citra MRI tumor otak yang telah diberi label oleh ahli medis.
- Preprocessing* Data: Melakukan *resize*, *normalisasi*, dan augmentasi data untuk mempersiapkan dataset agar sesuai dengan kebutuhan model CNN.
- Pengembangan Model: Membangun dan menginisialisasi model *Alexnet* dan *VGG16* dengan bobot *pre-trained ImageNet*.


- d. Pelatihan Model: Melatih kedua model menggunakan dataset yang telah diproses dengan parameter pelatihan yang telah ditentukan.
- e. Evaluasi Model: Mengukur performa model menggunakan confusion metrik evaluasi
- f. Analisis Hasil: Membandingkan hasil kinerja kedua model dan mendiskusikan temuan serta potensi perbaikan.



Gambar 1. Diagram alur

Dataset

Dalam penelitian ini, dataset yang digunakan sejumlah 3064 citra MRI tumor otak yang mencakup beberapa kelas tumor utama, yaitu 1426 citra *glioma*, 708 citra *meningioma*, dan 930 citra *pituitary* tumor. Setiap citra dalam dataset telah melalui proses anotasi oleh ahli medis untuk memastikan keakuratan label yang melekat pada masing-masing gambar.




Gambar 2. Dataset citra

Untuk keperluan pelatihan dan pengujian model, dataset ini kemudian dibagi menjadi dua subset, dengan proporsi 80% data digunakan untuk pelatihan dan 20% sisanya digunakan untuk pengujian model [14]. Citra yang digunakan untuk pelatihan model terdiri dari 1140 citra glioma, 566 meningioma, dan 744 citra pituitary. Sedangkan untuk pengujian model digunakan 286 citra glioma, 142 meningioma, dan 186 citra pituitary.

Preprocessing Data

Sebelum dilakukan pelatihan model, seluruh citra dalam dataset diolah terlebih dahulu melalui beberapa tahap *preprocessing*. Pertama, setiap citra diubah ukurannya menjadi 224x224 piksel agar sesuai dengan ukuran input yang dibutuhkan oleh model *Alexnet* dan *VGG16*. Selanjutnya, nilai piksel pada citra dinormalisasi ke rentang 0 hingga 1 untuk mempercepat proses pelatihan dan meningkatkan stabilitas model. Untuk menambah variasi pada data training tanpa benar-benar menambah data baru, dilakukan augmentasi pada data training. Dilakukan rotasi hingga 45 derajat secara acak dan flipping (pembalikan) pada citra secara horizontal. Selain itu, ditambahkan variasi zoom hingga 30 persen dari citra asli serta pergeseran (translasi) citra secara horizontal dan vertikal masing-masing hingga 20 persen dari ukuran gambar. Citra juga mengalami transformasi geser (shear) hingga 0.4 untuk menambahkan distorsi bentuk secara acak. Nilai piksel pada citra dinormalisasi ke dalam rentang [0,1] dengan cara membagi nilai piksel dengan 255. Area kosong yang muncul akibat transformasi diisi menggunakan metode interpolasi 'nearest'. Sebanyak 20 persen dari data training digunakan sebagai data validasi. Langkah augmentasi bertujuan untuk mengurangi risiko overfitting sehingga model dapat belajar dari data yang lebih beragam dan menghasilkan performa yang lebih baik [15], [16], [17].

Pengembangan Model



Gambar 3. Arsitektur CNN

Dalam penelitian ini, dua arsitektur *Convolutional Neural Networks* (CNN) digunakan, yaitu *Alexnet* dan *VGG16*. *Alexnet* terdiri dari lima lapisan konvolusi dan tiga lapisan fully connected, dengan fungsi aktivasi ReLU yang digunakan pada setiap lapisan [18]. Untuk mengurangi risiko overfitting, teknik dropout juga diterapkan selama pelatihan. Sementara itu, *VGG16* memiliki arsitektur yang lebih dalam dengan 13 lapisan konvolusi yang menggunakan filter berukuran 3x3 secara konsisten, serta tiga lapisan *preprocessing*. Kedua model ini diinisialisasi dengan bobot *pre-trained* yang diperoleh dari dataset *ImageNet* untuk memanfaatkan teknik transfer learning, kemudian dilakukan fine-tuning pada dataset tumor otak agar model dapat beradaptasi dengan karakteristik data yang spesifik [19].

Pelatihan Model

Pelatihan model dilakukan menggunakan algoritma optimasi Adam dengan learning rate awal sebesar 0,0001. Dataset dibagi menjadi dua bagian, yaitu 80% data digunakan untuk pelatihan dan 20% sisanya untuk pengujian. Proses pelatihan berlangsung selama 15 epoch dengan *batch size* sebesar 32. Selama pelatihan, validasi silang diterapkan untuk memantau performa model secara berkala dan mencegah

terjadinya overfitting, sehingga model dapat menghasilkan generalisasi yang baik pada data baru.

Evaluasi Model

Kinerja kedua model dievaluasi menggunakan beberapa metrik utama, yaitu akurasi, *precision*, *recall* (sensitivitas), dan *F1-score*. Metrik-metrik ini memberikan gambaran menyeluruh mengenai kemampuan model dalam mengklasifikasikan tumor otak dengan benar, baik dari segi ketepatan prediksi maupun kemampuan mendeteksi kelas positif secara akurat.

3. HASIL DAN PEMBAHASAN

Penelitian ini membandingkan dua arsitektur *Convolutional Neural Network* (CNN) yang populer, yaitu *Alexnet* dan *VGG16*, dalam tugas klasifikasi tiga jenis tumor otak berdasarkan citra MRI: *glioma*, *meningioma*, dan *pituitary*. Evaluasi dilakukan berdasarkan metrik akurasi, *precision*, *recall*, dan *F1-score*, yang mencerminkan kemampuan model dalam mengenali dan membedakan karakteristik masing-masing jenis tumor secara efektif. Hasil eksperimen menunjukkan perbedaan yang menarik antara kedua model, baik dari sisi akurasi maupun dari ketepatan klasifikasi per kelas.

Model Arsitektur *Alexnet*

Model *Alexnet* yang dilatih menggunakan bobot awal *pre-trained* dari *ImageNet* dan kemudian dilakukan *fine-tuning* pada dataset tumor otak, menunjukkan performa yang cukup kuat dan stabil sepanjang proses pelatihan. Pada akhir pelatihan selama 15 *epoch*, *Alexnet* berhasil mencapai akurasi pengujian sebesar 78.99%.

Dari hasil evaluasi lebih lanjut, diketahui bahwa *Alexnet* memiliki kinerja klasifikasi yang sangat baik terhadap kelas *pituitary* dan *glioma*, dengan nilai *F1-score* yang masing-masing mencapai 0.90 dan 0.80. Namun demikian, kinerja pada kelas *meningioma* menunjukkan kelemahan, khususnya pada metrik *precision* yang hanya mencapai 0.57, meskipun nilai *recall*-nya relatif tinggi yaitu 0.75. Hal ini mengindikasikan bahwa model sering mengklasifikasikan kelas lain sebagai *meningioma*, menyebabkan *false positive* yang cukup tinggi.

Secara keseluruhan, nilai rata-rata *F1-score* makro sebesar 0.78 dan *F1-score* tertimbang sebesar 0.79 menunjukkan bahwa *Alexnet* mampu melakukan klasifikasi dengan cukup merata di semua kelas, meskipun ada ketidakseimbangan yang perlu diperhatikan pada kelas *meningioma*.

Model Arsitektur *VGG16*

Model *VGG16*, yang memiliki arsitektur lebih dalam dengan 13 layer konvolusi, juga menunjukkan performa yang kompetitif dalam klasifikasi tumor otak. Dengan jumlah parameter yang lebih besar dan kedalaman arsitektur yang tinggi, model ini diharapkan dapat mengekstraksi fitur yang lebih kompleks dari citra MRI.

Setelah proses pelatihan selama 15 *epoch*, *VGG16* mencatatkan akurasi pengujian sebesar 78.01%, sedikit lebih rendah dibandingkan *Alexnet*. Analisis *classification report* mengungkap bahwa model ini sangat kuat dalam mengenali tumor jenis *glioma* dan *pituitary*, dengan *F1-score* masing-masing 0.83 dan 0.86. Namun, kinerja pada kelas *meningioma* cukup rendah, khususnya pada nilai *recall* yang hanya sebesar 0.32, yang mengindikasikan bahwa banyak gambar *meningioma* tidak terdeteksi atau diklasifikasikan ke kelas lain. Meskipun *precision*-nya sebesar 0.75 cukup tinggi, nilai

recall yang rendah menyebabkan *F1-score* kelas *meningioma* turun drastis menjadi hanya 0.45.

Secara umum, *F1-score* makro untuk *VGG16* adalah 0.72 dan *F1-score* tertimbang sebesar 0.75, sedikit lebih rendah dari *Alexnet*. Performa ini menandakan bahwa meskipun *VGG16* memiliki keunggulan dalam kedalaman arsitektur, hal ini tidak serta merta menjamin peningkatan performa, terutama ketika berhadapan dengan distribusi data yang tidak seimbang antar kelas.

Perbandingan dan Analisis

Perbandingan langsung antara kedua model dapat dilihat pada tabel berikut: Secara umum, *Alexnet* menunjukkan performa yang sangat baik dalam tugas klasifikasi citra tumor otak, dengan hasil evaluasi yang konsisten pada seluruh metrik utama seperti akurasi, *precision*, dan *F1-score*. Arsitektur *Alexnet* yang efisien dan ringan memungkinkan proses pelatihan yang cepat dan stabil, serta menghasilkan generalisasi yang baik pada data uji. Model ini secara khusus menunjukkan kemampuan klasifikasi yang kuat pada kelas *glioma* dan *pituitary*, dengan nilai evaluasi yang tinggi dan prediksi yang akurat.

Tabel 1. Perbandingan model

Metrik Evaluasi	<i>Alexnet</i>	<i>VGG16</i>
Akurasi Uji	78.99%	78.01%
<i>F1-score</i> (Macro)	0.78	0.72
<i>F1-score</i> (Weighted)	0.79	0.75
Kelas Terkuat	<i>Pituitary</i> (F1=0.90)	<i>Pituitary</i> (F1=0.86)
Kelas Terlemah	<i>Meningioma</i> (<i>Precision</i>)	<i>Meningioma</i> (<i>Recall</i>)

Sementara itu, *VGG16* juga menunjukkan kinerja yang kompetitif dengan hasil akurasi yang mendekati *Alexnet*, disertai dengan keunggulan dalam mengenali pola-pola visual yang lebih kompleks. Dengan kedalaman arsitekturnya yang tinggi, *VGG16* mampu mengekstraksi fitur yang lebih dalam dari citra MRI, menghasilkan nilai *precision* dan recall yang tinggi pada kelas tertentu. Keunggulan ini menunjukkan bahwa *VGG16* memiliki potensi besar dalam menangani klasifikasi citra medis yang kompleks dan beragam.

Kedua model secara keseluruhan telah menunjukkan performa yang menjanjikan dan layak dipertimbangkan sebagai pendekatan berbasis *deep learning* untuk membantu proses identifikasi dan klasifikasi tumor otak secara otomatis, cepat, dan akurat.


Confusion Matrix

Confusion Matrix pada model *Alexnet* menunjukkan kinerja klasifikasi yang sangat baik terhadap ketiga jenis tumor otak, yaitu *glioma*, *meningioma*, dan *pituitary*. Pada kelas *glioma*, model berhasil mengklasifikasikan 201 data secara tepat, dengan hanya sedikit kesalahan klasifikasi ke kelas *meningioma* dan *pituitary*. Hal ini menunjukkan bahwa model memiliki sensitivitas yang tinggi terhadap pola visual khas *glioma*.

Kinerja model pada kelas *meningioma* juga tergolong baik, dengan 107 data berhasil dikenali secara akurat. Meskipun terdapat beberapa prediksi ke kelas lain, jumlah klasifikasi yang benar tetap mendominasi, mencerminkan kemampuan model dalam mengenali ciri khas tumor *meningioma*.


Sementara itu, pada kelas *pituitary*, model menunjukkan performa yang sangat unggul, dengan 177 data terklasifikasi dengan benar dan hanya sebagian kecil yang salah.

Ini menandakan bahwa *Alexnet* memiliki akurasi yang sangat tinggi dalam mengenali citra tumor jenis ini.



Gambar 4 *Confusion matrix alexnet*

Secara keseluruhan, distribusi data pada *Confusion Matrix* yang terpusat di diagonal utama menunjukkan bahwa *Alexnet* mampu mengenali dan membedakan ketiga jenis tumor dengan baik. Hasil ini memperkuat efektivitas arsitektur *Alexnet* dalam tugas klasifikasi citra medis, serta memperlihatkan potensi besar model ini untuk diterapkan dalam sistem pendukung diagnosis berbasis *deep learning*.



Gambar 5 *Confusion matrix VGG16*

baik terhadap tiga jenis tumor otak: *glioma*, *meningioma*, dan *pituitary*. Pada kelas *glioma*, model berhasil mengklasifikasikan 250 data dengan benar, menunjukkan ketepatan yang tinggi dalam mengenali pola visual khas *glioma*. Hanya sejumlah kecil data yang diprediksi sebagai *meningioma* 27 dan *pituitary* 9, yang menandakan bahwa model memiliki sensitivitas yang kuat terhadap kelas ini.

Untuk kelas *meningioma*, *VGG16* berhasil mengenali 72 sampel dengan akurat, sementara sisanya terbagi ke dalam prediksi *glioma* dan *pituitary*. Jumlah prediksi benar yang cukup signifikan menunjukkan bahwa model mampu menangkap karakteristik penting dari *meningioma* dengan cukup baik.

energi sangat baik juga ditunjukkan pada kelas *pituitary*, dengan 168 data diklasifikasikan secara tepat. Kesalahan klasifikasi relatif sedikit, yaitu 15 data ke *glioma* dan 3 ke *meningioma*, yang memperlihatkan *precision* tinggi dalam mengenali tumor jenis ini.

Secara keseluruhan, distribusi klasifikasi pada *Confusion Matrix* ini mencerminkan kemampuan generalisasi *VGG16* yang solid dan akurat. Model ini mampu

mengidentifikasi ketiga jenis tumor dengan baik, dan menunjukkan potensi kuat sebagai alat bantu dalam sistem klasifikasi citra medis berbasis *deep learning*.

4. KESIMPULAN

Penelitian ini telah berhasil mengimplementasikan dan membandingkan dua arsitektur *Convolutional Neural Network*, yaitu *Alexnet* dan *VGG16*, dalam tugas klasifikasi citra MRI tumor otak menjadi tiga kelas: *glioma*, *meningioma*, dan *pituitary*. Berdasarkan hasil evaluasi, *Alexnet* menunjukkan performa yang lebih unggul secara umum, dengan akurasi pengujian sebesar 78.99% dan nilai *F1-score* yang lebih tinggi dibandingkan *VGG16*. Arsitektur *Alexnet* yang efisien mampu memberikan hasil klasifikasi yang akurat dan stabil, terutama pada kelas *glioma* dan *pituitary*.

Sementara itu, *VGG16* juga menunjukkan kinerja yang kompetitif, dengan akurasi yang mendekati *Alexnet* serta hasil klasifikasi yang sangat baik pada kelas *glioma*. Keunggulan *VGG16* terlihat dari kemampuannya dalam mengekstraksi fitur yang lebih kompleks berkat kedalaman arsitekturnya. Hasil visualisasi berupa *Confusion Matrix* menunjukkan bahwa kedua model memiliki distribusi prediksi yang dominan pada label yang tepat, sehingga keduanya layak dipertimbangkan sebagai solusi dalam sistem klasifikasi citra medis berbasis *deep learning*.

DAFTAR PUSTAKA

- [1] A. Chinga, W. Bendezu, and A. Angulo, 'Comparative Study of CNN Architectures for Brain Tumor Classification Using MRI: Exploring GradCAM for Visualizing CNN Focus', *Engineering Proceedings*, vol. 83, no. 1, Art. no. 1, 2025, doi: 10.3390/engproc2025083022.
- [2] S. Suganyadevi, V. Seethalakshmi, and K. Balasamy, 'A review on deep learning in medical image analysis', *Int J Multimed Info Retr*, vol. 11, no. 1, pp. 19–38, Mar. 2022, doi: 10.1007/s13735-021-00218-1.
- [3] C. Chen, N. A. Mat Isa, and X. Liu, 'A review of convolutional neural network based methods for medical image classification', *Computers in Biology and Medicine*, vol. 185, p. 109507, Feb. 2025, doi: 10.1016/j.compbiomed.2024.109507.
- [4] S. Srinivasan, D. Francis, S. K. Mathivanan, H. Rajadurai, B. D. Shivahare, and M. A. Shah, 'A hybrid deep CNN model for brain tumor image multi-classification', *BMC Med Imaging*, vol. 24, no. 1, p. 21, Jan. 2024, doi: 10.1186/s12880-024-01195-7.
- [5] S. S. Kshatri and D. Singh, 'Convolutional Neural Network in Medical Image Analysis: A Review', *Arch Computat Methods Eng*, vol. 30, no. 4, pp. 2793–2810, May 2023, doi: 10.1007/s11831-023-09898-w.
- [6] S. Kollem *et al.*, 'AlexNet-NDTL: Classification of MRI brain tumor images using modified AlexNet with deep transfer learning and Lipschitz-based data augmentation', *International Journal of Imaging Systems and Technology*, vol. 33, no. 4, pp. 1306–1322, 2023, doi: 10.1002/ima.22870.
- [7] M. A. E. Muhammed, A. A. Ahmed, and T. A. Khalid, 'Benchmark analysis of popular ImageNet classification deep CNN architectures', in *2017 International Conference On Smart Technologies For Smart Nation (SmartTechCon)*, Bangalore: IEEE, Aug. 2017, pp. 902–907. doi: 10.1109/smarttechcon.2017.8358502.
- [8] S. Montaha *et al.*, 'BreastNet18: A High Accuracy Fine-Tuned VGG16 Model Evaluated Using Ablation Study for Diagnosing Breast Cancer from Enhanced

- Mammography Images’, *Biology*, vol. 10, no. 12, Art. no. 12, Dec. 2021, doi: 10.3390/biology10121347.
- [9] A. Sharma and S. Arora, ‘Brain Tumor Detection using CNN and VGG-16 Model’, *International Journal of Intelligent Systems and Applications in Engineering*, vol. 12, no. 3, Art. no. 3, Jun. 2024.
- [10] C. Srinivas *et al.*, ‘Deep Transfer Learning Approaches in Performance Analysis of Brain Tumor Classification Using MRI Images’, *Journal of Healthcare Engineering*, vol. 2022, no. 1, p. 3264367, 2022, doi: 10.1155/2022/3264367.
- [11] A. Nag *et al.*, ‘TumorGANet: A Transfer Learning and Generative Adversarial Network- Based Data Augmentation Model for Brain Tumor Classification’, *IEEE Access*, vol. 12, pp. 103060–103081, 2024, doi: 10.1109/access.2024.3429633.
- [12] J. Su, X. Yu, X. Wang, Z. Wang, and G. Chao, ‘Enhanced transfer learning with data augmentation’, *Engineering Applications of Artificial Intelligence*, vol. 129, p. 107602, 2024.
- [13] Y. Deng *et al.*, ‘Deep transfer learning and data augmentation improve glucose levels prediction in type 2 diabetes patients’, *NPJ Digital Medicine*, vol. 4, no. 1, p. 109, 2021.
- [14] M. S. Ullah, M. A. Khan, A. Masood, O. Mzoughi, O. Saidani, and N. Alturki, ‘Brain tumor classification from MRI scans: a framework of hybrid deep learning model with Bayesian optimization and quantum theory-based marine predator algorithm’, *Front Oncol*, vol. 14, p. 1335740, Feb. 2024, doi: 10.3389/fonc.2024.1335740.
- [15] N. E. Khalifa, M. Loey, and S. Mirjalili, ‘A comprehensive survey of recent trends in deep learning for digital images augmentation’, *Artif Intell Rev*, vol. 55, no. 3, pp. 2351–2377, Mar. 2022, doi: 10.1007/s10462-021-10066-4.
- [16] E. Goceri, ‘Medical image data augmentation: techniques, comparisons and interpretations’, *Artif Intell Rev*, vol. 56, no. 11, pp. 12561–12605, Nov. 2023, doi: 10.1007/s10462-023-10453-z.
- [17] A. Anaya-Isaza and L. Mera-Jiménez, ‘Data augmentation and transfer learning for brain tumor detection in magnetic resonance imaging’, *IEEE access*, vol. 10, pp. 23217–23233, 2022.
- [18] Y. N. Fu’adah, I. Wijayanto, N. K. C. Pratiwi, F. F. Taliningsih, S. Rizal, and M. A. Pramudito, ‘Automated Classification of Alzheimer’s Disease Based on MRI Image Processing using Convolutional Neural Network (CNN) with AlexNet Architecture’, *J. Phys.: Conf. Ser.*, vol. 1844, no. 1, p. 012020, Mar. 2021, doi: 10.1088/1742-6596/1844/1/012020.
- [19] D. Nurani, I. L. Yanuar, and A. D. Putra, ‘Klasifikasi Jenis Penyakit Pada Citra Daun Padi Menggunakan Algoritma Convolution Neural Network’, *Jurnal Teknologi Informasi dan Komputer*, vol. 8, no. 3, Oct. 2022, doi: 10.36002/jutik.v8i3.2074.