

Peningkatan Hiperparameter Framework Deep Learning VGG-16 untuk Pendeteksian Tumor Otak pada Teknologi MRI

Ahmad Bagas Aditya Ilham Aulia, Alamsyah*

Program Studi Teknik Informatika, FMIPA, Universitas Negeri Semarang, Indonesia
Gedung D5 Lt.2, Kampus Sekaran Gunungpati, Semarang 50229

E-mail: alamsyah@mail.unnes.ac.id

Diterima 17 Mei 2024

Disetujui 17 Oktober 2024

Abstrak

Deteksi tumor otak manusia melalui citra medis masih memiliki keterbatasan, sehingga diperlukan metode yang akurat. Penelitian ini bertujuan untuk meningkatkan kemampuan model VGG-16 yang dimodifikasi melalui penyesuaian hiperparameter dalam mendeteksi gambar MRI tumor otak manusia. Dataset yang digunakan berasal dari Brain MRI Tumor Dataset di Kaggle, dengan empat kategori tumor otak. Model VGG-16 dilakukan penyesuaian untuk meningkatkan akurasi, menyesuaikan kecerahan dan kontras dalam augmentasi data, serta penambahan layer klasifikasi. Hiperparameter yang diatur meliputi *learning rate*, *batch size*, *epoch*, dan *optimizer*. Hasil penelitian menunjukkan akurasi 95,63%, *precision* 95,69%, *recall* 95,58%, dan *F1 score* 95,57%. Model yang diterapkan menunjukkan potensi dalam meningkatkan akurasi dan efisiensi diagnosis tumor otak menggunakan teknologi MRI. Dengan demikian, pemodifikasian model VGG-16 dalam penelitian ini memberikan peningkatan performa dalam pendeteksian gambar MRI tumor otak dibandingkan penelitian sebelumnya.

Kata kunci: *Deep learning*, *fine-tuning*, MRI, tumor otak, VGG-16

Abstract

Detection of human brain tumors through medical images still has limitations, so an accurate method is needed. This study aims to improve the ability of the modified VGG-16 model through hyperparameter adjustment in detecting human brain tumor MRI images. The dataset used comes from the Brain MRI Tumor Dataset on Kaggle, with four categories of brain tumors. The VGG-16 model was adjusted to improve accuracy, adjust brightness and contrast in data augmentation, and add a classification layer. Hyperparameters set include learning rate, batch size, epoch, and optimizer. The results showed an accuracy of 95.63%, precision 95.69%, recall 95.58%, and F1 score 95.57%. The applied model shows potential in improving the accuracy and efficiency of brain tumor diagnosis using MRI technology. Thus, the modification of the VGG-16 model in this study provides improved performance in brain tumor MRI image detection compared to previous studies.

Keywords: Brain tumor, deep learning, fine-tuning, MRI, VGG-16

How to cite:

Aulia ABAI., Alamsyah. (2024). Peningkatan hiperparameter framework deep learning VGG-16 untuk pendeteksian tumor otak pada teknologi MRI. *Indonesian Journal of Mathematics and Natural Sciences*, 47(2), 99-107.

PENDAHULUAN

Tumor otak merupakan salah satu penyakit yang krusial dan memerlukan penanganan medis segera. Penyakit ini disebabkan oleh pertumbuhan sel-sel abnormal di dalam otak manusia (Sailunaz *et al.*, 2024). Kasus tumor otak merupakan isu kesehatan serius yang dapat menyerang berbagai usia, mulai dari anak-anak hingga lanjut usia (Teoh, 2023). Tingginya angka kasus tumor otak, disertai dengan meningkatnya jumlah kematian di setiap tahunnya, menuntut perhatian serius. Setiap tahun,

terdapat sekitar 11.700 pasien dengan penyakit tumor otak, dan memiliki kelangsungan hidup yang sangat rendah (Teoh, 2023).

Pencitraan medis menjadi salah satu pendekatan yang populer untuk membantu dokter mendeteksi keberadaan tumor di dalam otak manusia (Varghese *et al.*, 2024). Pencitraan medis merupakan metode yang memanfaatkan citra dan visualisasi organ tubuh untuk keperluan klinis dan analisis psikologi (Sailunaz *et al.*, 2024). Teknik pencitraan medis tidak hanya menampilkan gambaran tubuh atau struktur internal organ, tetapi juga digunakan untuk mendiagnosis penyakit. Beberapa alat yang digunakan pencitraan medis saat ini meliputi *magnetic resonance imaging* (MRI), *positron emission tomography* (PET), *computed tomography* (CT), *ultrasound*, dan lain-lain (Sailunaz *et al.*, 2024).

Berdasarkan lokasinya yang berada di dalam otak, terdapat lebih dari 150 jenis tumor otak. Berdasarkan karakteristik selnya, tumor dapat dibedakan menjadi dua kategori yaitu tumor jinak dan ganas. Tumor jinak (*benign*) atau non-kanker tidak memiliki sel aktif dan bentuknya tidak berubah. Sementara tumor ganas (*malignant*) atau kanker memiliki sel aktif dengan bentuk yang seragam (Soomro *et al.*, 2023). Dalam banyak kasus, tumor dapat diangkat melalui prosedur operasi, namun ada kemungkinan tumor dapat tumbuh kembali setelah operasi.

Beberapa alat dapat digunakan untuk pencitraan medis, namun MRI paling populer digunakan untuk pemindaian tumor dalam otak manusia (Majib *et al.*, 2021). MRI menggunakan paparan sinar radiasi yang rendah dengan hasil gambar yang memiliki kontras cukup baik. MRI menggunakan medan magnet dalam menyelaraskan proton-proton dalam molekul air sel otak dan menggunakan sinyal radio pada tingkatan frekuensi tertentu untuk mengganggu proton-proton setelah sejajar.

Meskipun teknologi MRI telah digunakan, penanganan pasien dengan tumor otak masih menghadapi berbagai kendala dan rentan terhadap kesalahan. Ketidakkampuan atau ketidakpahaman dokter dalam menganalisis hasil scan MRI otak menjadi salah satu permasalahan utama (Kuroiwa, 2023). Kesulitan dalam mendeteksi tumor kecil, batasan gambar tumor dalam MRI, variasi dalam interpretasi antar operator, dan kompleksitas struktur otak sering kali menyebabkan ketidakakuratan dan inkonsistensi (Kuroiwa, 2023). Oleh karena itu, ada kebutuhan mendesak untuk mengembangkan teknik otomatis yang dapat membantu radiolog mendeteksi tumor otak dengan lebih akurat dan konsisten.

Saat ini, analisis gambar tumor otak menjadi topik yang populer, dan banyak ilmuwan berusaha berkontribusi dalam bidang ini. Berbagai metode dan sistem otomatis telah dicoba, termasuk *thresholding*, *filtering*, operasi morfologis, serta metode *machine learning* dan *deep learning* untuk mengatasi permasalahan ini (Ramtekkar *et al.*, 2023; Mahum *et al.*, 2023). Beberapa penelitian berfokus pada algoritma metaheuristik, seperti penggunaan algoritma optimasi yang dapat mencapai akurasi hingga 90% (Kale & Shitole, 2024). Selain itu, metode pembelajaran mesin seperti *supervised* dan *unsupervised learning*, termasuk *support vector machine* (SVM), *random forest* (RF), *K-means clustering*, *K-nearest neighbor* (KNN), dan pendekatan hibrid juga banyak digunakan. Penggunaan metode *convolutional neural networks* (CNN) (Nurriski & Alamsyah 2023), *fully convolutional networks*, dan *deep neural networks* (DNN) juga merupakan pendekatan yang dapat diandalkan untuk mencapai performa dan akurasi optimal (Kaur *et al.*, 2023).

Dalam beberapa tahun terakhir, pendekatan *deep learning*, khususnya CNN, menunjukkan potensi besar dalam analisis gambar medis. CNN dengan kemampuannya mengekstraksi dan mempelajari fitur-fitur kompleks dalam data gambar, berhasil diterapkan dalam berbagai tugas pengenalan dan klasifikasi gambar. Keunggulan CNN dalam menangani data gambar beresolusi tinggi serta fleksibilitas struktur jaringan membuatnya ideal untuk aplikasi dalam pencitraan medis (Xu *et al.*, 2023; Anaya-Isaza *et al.*, 2021).

Dalam pembelajaran mesin, terdapat istilah model pra-pelatihan (*pre-trained model*), yaitu jaringan saraf tiruan yang telah dilatih sebelumnya pada dataset yang besar dan representatif, seperti VGG-16, untuk tugas tertentu seperti klasifikasi gambar (Kumaresan *et al.*, 2023). Model-model ini mengakumulasi pengetahuan yang luas dari data latihannya dan dapat digunakan sebagai basis untuk menyelesaikan tugas-tugas serupa atau terkait yang melibatkan pemrosesan gambar. Dengan menggunakan model pra-pelatihan, pengguna dapat memanfaatkan representasi fitur yang terlatih dengan baik, yang sering kali mempercepat proses pelatihan dan meningkatkan performa model pada dataset yang lebih kecil atau khusus.

Arsitektur VGG16 yang diperkenalkan oleh *visual geometry group* (VGG) di University of Oxford, merupakan salah satu model CNN dan model pra-pelatihan yang terkenal. VGG-16 adalah model jaringan saraf konvolusi dengan 16 lapisan, dan setiap lapisan menggunakan filter konvolusi 3x3 dan lapisan *max-pooling* 2x2 untuk memproses gambar input. Ini menghasilkan fungsi keputusan

yang ditingkatkan dan konvergensi yang lebih cepat karena lebih banyak lapisan aktivasi non-linear, serta mengurangi risiko *overfitting* dengan menggunakan filter yang lebih kecil (Al-Khater & Al-Madeed, 2024).

Penelitian terkait tumor otak telah banyak dilakukan. Studi Majib et al. (2021) mengeksplorasi pengembangan dan evaluasi berbagai model pembelajaran mesin tradisional dan hibrida, bersama dengan 16 model transfer *learning* yang berbeda, untuk mengklasifikasikan gambar tumor otak tanpa intervensi manusia. Di antara model-model tersebut, suatu VGG *Stacked Classifier Network* (VGG-SCNets), menunjukkan efektivitas dan potensinya untuk aplikasi klinis dalam diagnosis dini tumor otak.

Pada penelitian Bairagi et al. (2023) memperkenalkan algoritma pemrosesan gambar berbasis CNN untuk mengklasifikasikan gambar tumor otak menjadi normal dan abnormal, menggunakan augmentasi data untuk mengatasi keragaman lokasi dan struktur tumor. Algoritma tersebut telah diuji dengan dataset BRATs 2013, BRATs 2015, dan gambar Open-I. Hasil simulasi mengindikasikan akurasi sebesar 90,67% menggunakan jaringan VGG-16-TL dengan fungsi pelatihan ADAM, 88,00% dengan VGG-16 dan fungsi pelatihan rmsprop, serta 89,33% dengan VGG-16 dan fungsi pelatihan SGDM. Pada penelitian Srinivasan et al. (2024) mengusulkan metode multi-klasifikasi untuk deteksi dini tumor otak menggunakan model CNN dengan hiperparameter yang dioptimalkan otomatis via *grid search*.

Penelitian ini bertujuan untuk mengembangkan metode deteksi otomatis tumor otak dengan memanfaatkan model VGG16 yang telah dimodifikasi untuk menganalisis gambar MRI. Modifikasi ini diharapkan dapat meningkatkan akurasi dan konsistensi dalam mendeteksi tumor otak, sehingga dapat membantu radiolog dalam diagnosa yang lebih efektif dan efisien.

METODE

Studi ini memanfaatkan teknologi transfer *learning* yang dimiliki oleh arsitek VGG-16 dalam mendeteksi 4 kategori tumor otak. Studi dimulai dari pemuatan dataset MRI pada Kaggle, pemrosesan data, pengaturan model dan hiperparameter, pelatihan, dan yang terakhir adalah pengujian.

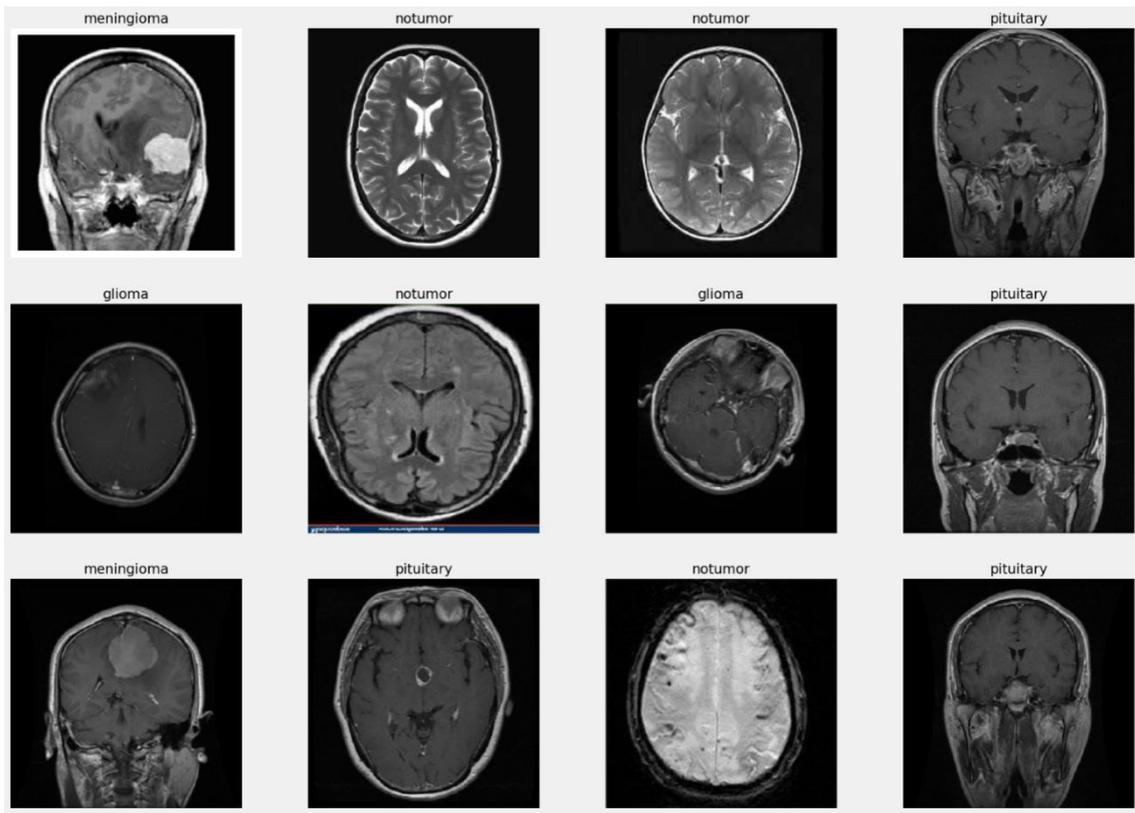
Dataset

Dataset yang digunakan dalam artikel jurnal ini adalah dataset publik yang berasal dari *brain MRI tumor dataset* yang tersedia di Kaggle. Dataset ini mencakup 7.023 gambar hasil scan MRI otak manusia, yang diklasifikasikan ke dalam empat kategori yaitu glioma, meningioma, pituitary, dan no tumor (Nickparvar, 2024). Visualisasi gambar MRI tumor otak dari keempat kategori tersebut dapat dilihat pada Gambar 1.

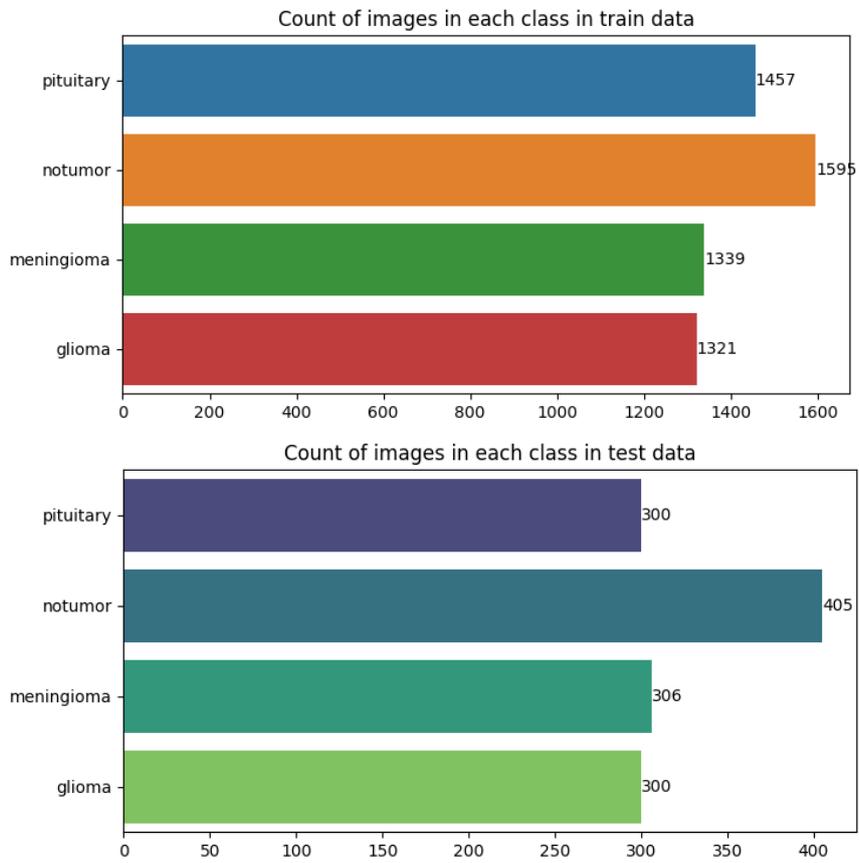
Dataset ini dibagi menjadi dua bagian, terdiri dari data pelatihan dan data pengujian, yang masing-masing mencakup keempat kategori tumor otak tersebut. Jumlah dari masing-masing gambar dapat dilihat pada Gambar 2. Pemilik dataset memberikan catatan bahwa gambar-gambar dalam dataset memiliki ukuran yang bervariasi. Oleh karena itu, disarankan untuk melakukan pemrosesan tambahan dengan mengatur ukuran gambar yang seragam dan menghapus margin yang tidak diinginkan sebelum digunakan dalam pelatihan model. Hal ini bertujuan untuk memungkinkan pelatihan model yang lebih efektif dan evaluasi yang akurat terhadap kemampuan model dalam mendeteksi berbagai jenis tumor otak (Nickparvar, 2024).

Preprocessing

Dataset yang telah dimuat dari Kaggle terdiri dari data training dan test (Nickparvar, 2024). Data latihan kemudian dilakukan pembagian menjadi dua untuk data validasi dengan perbandingan antara data latih dan validasi adalah 70:30. Augmentasi data dilakukan untuk meningkatkan keragaman data dan mencegah terjadinya *overfitting*. Teknik augmentasi yang dilakukan diantaranya adalah melakukan penyesuaian kecerahan dan penyesuaian kontras. Penyesuaian kecerahan dan kontras sama-sama diatur dengan tingkat kecerahan yang dipilih secara acak antara 0,8 hingga 1,5. Penyesuaian lain dilakukan dengan mengubah ukuran gambar menjadi 224x224 piksel agar sesuai dengan input model.



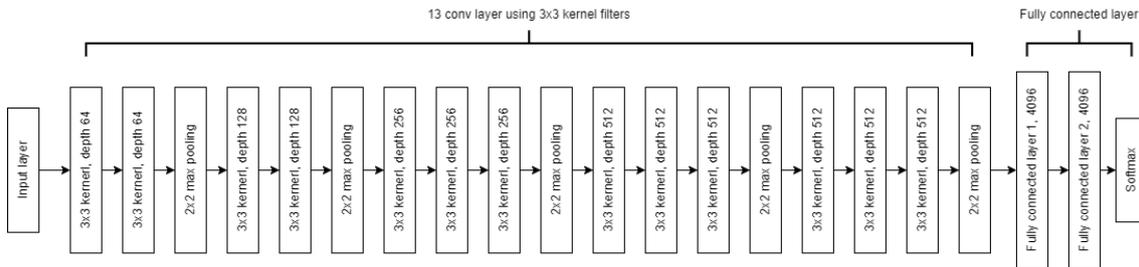
Gambar 1. Sampel gambar MRI 4 kategori tumor otak



Gambar 2. Jumlah gambar dalam setiap kelas dalam data latih dan data tes

VGG-16

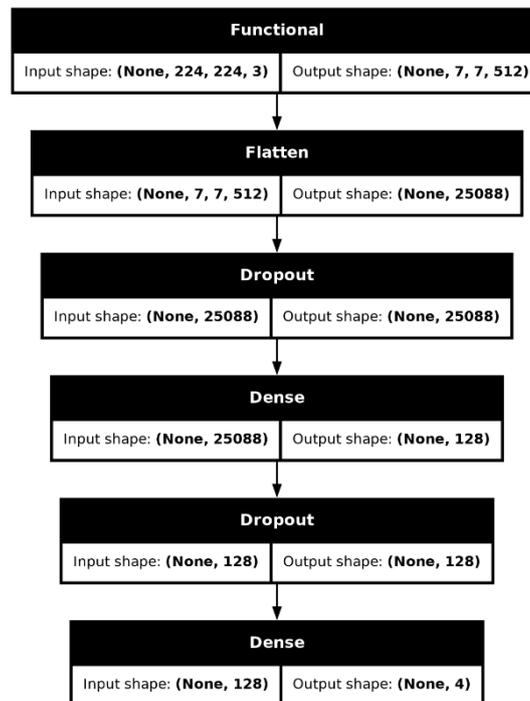
Penelitian ini memanfaatkan model VGG16 yang telah dilatih sebelumnya (*pre-trained*) untuk melakukan klasifikasi gambar 4 kelas gambar MRI tumor otak dengan TensorFlow dan Keras. Model ini sebelumnya telah dilakukan pelatihan menggunakan dataset ImageNet. Untuk menyesuaikan model dengan dataset MRI tumor otak, maka perlu dilakukan pembekuan layer konvolusi dari model agar tidak dilatih ulang. Gambar 3 menunjukkan basis dari arsitektur model VGG16 (Rismi & Luthfiarta, 2021).



Gambar 3. Arsitektur VGG-16

Semua lapisan dari model dasar yang ditunjukkan pada Gambar 3 diatur menjadi tidak dapat dilatih (*non-trainable*) untuk mempertahankan bobot yang telah dipelajari sebelumnya. Namun, tiga lapisan terakhir dari blok VGG diatur kembali menjadi dapat dilatih (*trainable*) untuk memungkinkan penyesuaian lebih lanjut selama pelatihan.

Model *sequential* dibuat dan diinisialisasi dengan lapisan masukan yang sesuai dengan ukuran gambar. Model VGG16 yang telah dimodifikasi kemudian ditambahkan sebagai basis. Lapisan Flatten digunakan untuk meratakan output dari model dasar, diikuti oleh lapisan *dropout* dengan tingkat *dropout* 0.3 untuk mengurangi *overfitting*. Lapisan *dense* dengan 128 unit dan aktivasi ReLU ditambahkan untuk melakukan pemrosesan lebih lanjut, diikuti oleh lapisan *dropout* lain dengan tingkat *dropout* 0.2. Akhirnya, lapisan *dense* terakhir dengan jumlah unit yang sesuai dengan jumlah label unik dan aktivasi softmax ditambahkan untuk menghasilkan probabilitas klasifikasi. Selanjutnya, ringkasan model ditampilkan untuk memberikan gambaran tentang arsitektur dan parameter seperti ditunjukkan pada Gambar 4.



Gambar 4. Model arsitektur dan parameter

Akhirnya, model dilatih dengan menggunakan data generator untuk 40 epoch, dengan data validasi juga dimasukkan untuk evaluasi, dan pengacakan data diatur ke "False" agar konsisten. Untuk melihat lebih lengkap pengaturan hiperparameter dapat dilihat pada Tabel 1.

Tabel 1. Pengaturan hiperparameter

Hyperparameter	Nilai
Epoch	40
Learning Rate	0,001
Batch Size	32
Optimizer	Adamax
Loss	Sparse Categorical Crossentropy
Metrics	Sparse Categorical Accuracy

Evaluasi Model

Accuracy adalah proporsi dari semua prediksi yang benar (baik positif maupun negatif) terhadap keseluruhan prediksi. Ini adalah ukuran seberapa sering model membuat prediksi yang benar. Formulasi matematika yang digunakan terdapat pada Persamaan (1).

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

Dimana:

TP (True Positive): jumlah kasus di mana model memprediksi positif dan benar (prediksi dan realitas sama-sama positif).

TN (True Negative): jumlah kasus di mana model memprediksi negatif dan benar (prediksi dan realitas sama-sama negatif).

FP (False Positive): jumlah kasus di mana model memprediksi positif tetapi salah (prediksi positif, tetapi kenyataannya negatif).

FN (False Negative): jumlah kasus di mana model memprediksi negatif tetapi salah (prediksi negatif, tetapi kenyataannya positif).

Precision adalah proporsi prediksi positif yang benar terhadap semua prediksi positif. Ini mengukur seberapa tepat model dalam memprediksi kelas positif. Presisi tinggi berarti bahwa ketika model memprediksi kelas positif, maka kemungkinan besar prediksi tersebut benar. Formulasi matematika yang digunakan terdapat pada Persamaan (2).

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

Recall atau sensitivitas, adalah proporsi prediksi positif yang benar terhadap semua sampel yang sebenarnya positif. Ini mengukur kemampuan model untuk mendeteksi semua contoh positif. *Recall* tinggi berarti bahwa model jarang melewatkan prediksi kelas positif yang benar. Formulasi matematika yang digunakan terdapat pada Persamaan (3).

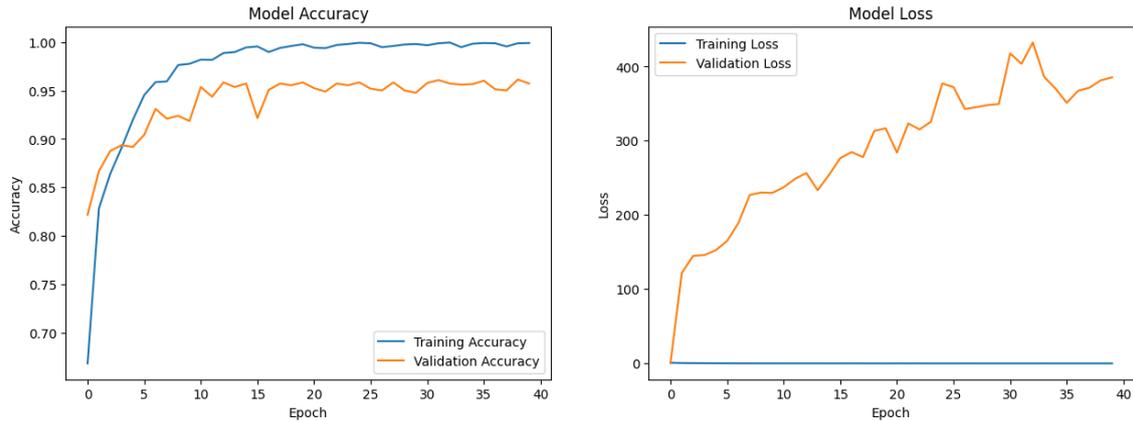
$$recall = \frac{TP}{TP+FN} \quad (3)$$

F1 Score adalah rata-rata harmonis dari *precision* dan *recall*, dan memberikan keseimbangan antara keduanya. Ini berguna ketika kita ingin mempertimbangkan keduanya secara bersamaan, terutama dalam kasus dataset yang tidak seimbang. Formulasi matematika yang digunakan terdapat pada Persamaan (4).

$$F1\ score = 2 \times \frac{precision \times recall}{precision + recall} \quad (4)$$

HASIL DAN PEMBAHASAN

Hasil pengujian model yang digambarkan dalam Gambar 5 memvisualisasikan perubahan nilai akurasi dan loss selama pengujian model. Pengujian dan validasi model dilaksanakan selama 40 epoch, yang memberikan gambaran menyeluruh tentang kinerja model dari awal hingga akhir proses pelatihan.



Gamba 5. Grafik hasil pengujian model

Tabel 2 menyajikan *classification report* yang menunjukkan perbandingan antara kelas hasil prediksi dan kelas sebenarnya. Model VGG-16 yang diusulkan dievaluasi berdasarkan metrik-metrik utama seperti precision, recall, dan F1-score untuk setiap kelas. Laporan ini memberikan gambaran mendalam tentang kinerja model dalam mengklasifikasikan berbagai kelas, dan membantu dalam penilaian kualitas prediksi model.

Tabel 2. Hasil *classification report*

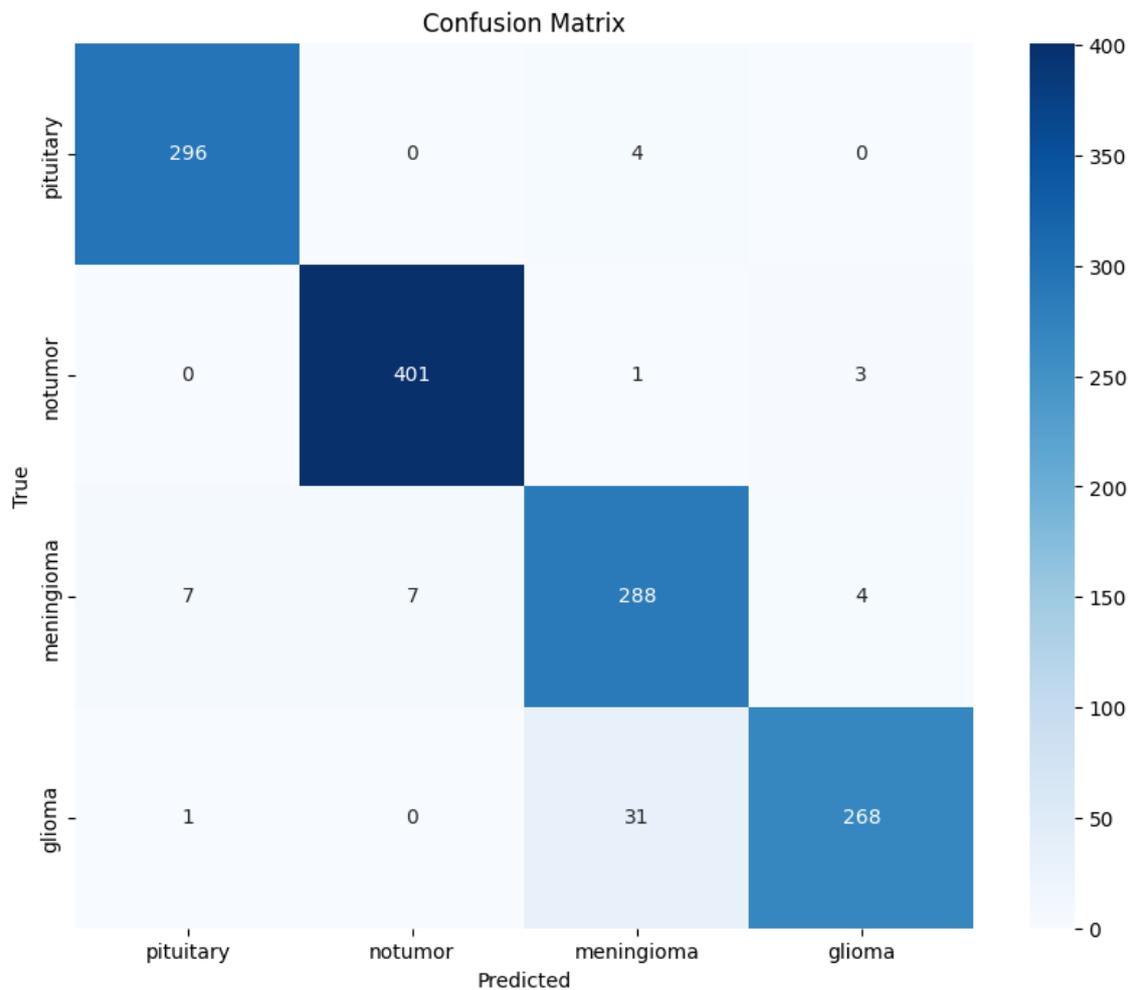
Kelas	Precision	Recall	F1-Score
Pituitary	0,97	0,99	0,98
Notumor	0,98	0,99	0,99
Meningioma	0,89	0,94	0,91
Glioma	0,97	0,89	0,93

Uji coba model VGG-16 yang telah dimodifikasi pada penelitian ini menghasilkan confusion matrix seperti yang ditampilkan pada Gambar 6. Confusion matrix ini menunjukkan perbandingan antara kelas asli yang terdapat pada sumbu Y dengan kelas prediksi pada sumbu X. Model diuji pada empat kelas berbeda, yaitu glioma, meningioma, notumor, dan pituitary, untuk menilai kinerjanya dalam membedakan dan mengklasifikasikan setiap kelas secara akurat.

Dilihat dari akurasi, model yang diusulkan memiliki nilai akurasi yang lebih tinggi dibandingkan dengan penelitian sebelumnya (Pathak *et al.*, 2019). Perbandingan kekuatan model dalam hal akurasi dapat dilihat pada Tabel 3.

Tabel 3. Perbandingan metode

Penelitian	Metode	Akurasi
Model Diusulkan	Modifikasi VGG16	95,63%
Pathak et al. (2019)	CNN	86,20%



Gambar 6. Hasil *confusion matrix*

SIMPULAN

Penelitian ini berhasil mengimplementasikan dan memodifikasi model jaringan saraf convolutional VGG16 untuk deteksi tumor otak pada gambar MRI. Melalui pemrosesan data dengan augmentasi gambar untuk meningkatkan keragaman dan mencegah overfitting, model VGG16 yang dimodifikasi menunjukkan performa yang sangat baik. Model dasar VGG16 diinisialisasi dengan bobot awal dari ImageNet, dan beberapa lapisan terakhir dibuat dapat dilatih untuk menyesuaikan dengan dataset MRI, ditambah lapisan Dense dan Dropout untuk meningkatkan kemampuan klasifikasi. Dengan optimizer Adamax dan fungsi loss sparse categorical crossentropy, model dilatih selama 40 epoch dengan batch size 32. Hasil evaluasi menunjukkan akurasi pengujian sebesar 95,63%, *precision* 95,69%, *recall* 95,58%, dan F1 score 95,57%, menunjukkan bahwa model ini sangat akurat dan seimbang dalam mendeteksi serta mengklasifikasikan tumor otak. Kesuksesan ini menegaskan potensi penggunaan model deep learning dalam meningkatkan diagnosis medis melalui analisis gambar, memberikan rekomendasi dan perawatan yang lebih tepat waktu kepada pasien.

DAFTAR PUSTAKA

- Al-Khater, W., & Al-Madeed, S. (2024). Using 3D-VGG-16 and 3D-Resnet-18 deep learning models and FABEMD techniques in the detection of malware. *Alexandria Engineering Journal*, *89*, 39-52. <https://doi.org/10.1016/j.aej.2023.12.061>
- Anaya-Isaza, A., Mera-Jiménez, L., & Zequera-Diaz, M. (2021). An overview of deep learning in medical imaging. *Informatics in Medicine Unlocked*, *26*, 100723. <https://doi.org/https://doi.org/10.1016/j.imu.2021.100723>

- Bairagi, V. K., Gumaste, P. P., Rajput, S. H., & Chethan, K. S. (2023). Automatic brain tumor detection using CNN transfer learning approach. *Medical and Biological Engineering and Computing*, 61(7), 1821-1836. <https://doi.org/10.1007/s11517-023-02820-3>
- Kale, R. S., & Shitole, S. (2024). Novel optimizer madam for efficient fruit grading and quality assessment using CNN-LSTM. *Journal of The Institution of Engineers (India): Series B*. <https://doi.org/10.1007/s40031-024-01048-5>
- Kaur, S., Kumar, Y., Koul, A., & Kamboj, S. K. (2023). A systematic review on metaheuristic optimization techniques for feature selections in disease diagnosis: open issues and challenges. *Archives of Computational Methods in Engineering*, 30(1), 1863-1895. <https://doi.org/10.1007/s11831-022-09853-1>
- Kumaresan, S., Aultrin, K. S. J., Kumar, S. S., & Anand, M. D. (2023). Deep learning-based weld defect classification using VGG16 transfer learning adaptive fine-tuning. *International Journal on Interactive Design and Manufacturing*, 17(6), 2999-3010. <https://doi.org/10.1007/s12008-023-01327-3>
- Kuroiwa, T. (2023). Brain Tumor. In T. Ishizawa (Ed.), *Fluorescence-Guided Surgery: From Lab to Operation Room*, 117-125. Springer Nature Singapore. https://doi.org/10.1007/978-981-19-7372-7_17
- Mahum, R., Sharaf, M., Hassan, H., Liang, L., & Huang, B. (2023). A robust brain tumor detector using BiLSTM and mayfly optimization and multi-level thresholding. *Biomedicines*, 11(6), 1715. <https://doi.org/10.3390/biomedicines11061715>
- Majib, M. S., Rahman, M. D. M., Sazzad, T. M. S., Khan, N. I., & Dey, S. K. (2021). VGG-SCNet: a VGG net-based deep learning framework for brain tumor detection on MRI images. *IEEE Access*, 9, 116942-116952. <https://doi.org/10.1109/ACCESS.2021.3105874>
- Nickparvar, M. (2024). *Brain Tumor MRI Dataset*. <https://www.kaggle.com/datasets/masoudnickparvar/brain-tumor-mri-dataset>. Akses 26 April 2024
- Nurriski, Y. J. & Alamsyah. (2023). Optimasi deep convolutional neural network (Deep CNN) untuk deteksi aritmia melalui sinyal EKG menggunakan arsitektur Conv1D. *Indonesian Journal of Mathematics and Natural Sciences*, 46(2), 10-20. <https://doi.org/10.15294/ijmns.v46i1.46176>
- Pathak, K., Pavthawala, M., Patel, N., Malek, D., Shah, V., & Vaidya, B. (2019). Classification of brain tumor using convolutional neural network. *2019 3rd International Conference on Electronics, Communication and Aerospace Technology (ICECA)*, 128-132. <https://doi.org/10.1109/ICECA.2019.8821931>
- Ramtekkar, P. K., Pandey, A., & Pawar, M. K. (2023). Accurate detection of brain tumor using optimized feature selection based on deep learning techniques. *Multimedia Tools and Applications*, 82(29), 44623-44653. <https://doi.org/10.1007/s11042-023-15239-7>
- Rismi, R., & Luthfiarta, A. (2021). VGG16 transfer learning architecture for salak fruit quality classification. *Telematika*, 18(1), 37-48. <https://doi.org/10.31315/telematika.v18i1.4025>
- Sailunaz, K., Alhaji, S., Özyer, T., Rokne, J., & Alhaji, R. (2024). A survey on brain tumor image analysis. *Medical and Biological Engineering and Computing*, 62(1), 1-45. <https://doi.org/10.1007/s11517-023-02873-4>
- Soomro, T. A., Zheng, L., Afifi, A. J., Ali, A., Soomro, S., Yin, M., & Gao, J. (2023). Image segmentation for MR brain tumor detection using machine learning: a review. *IEEE Reviews in Biomedical Engineering*, 16, 70-90. <https://doi.org/10.1109/RBME.2022.3185292>
- Srinivasan, S., Francis, D., Mathivanan, S. K., Rajadurai, H., Shivahare, B. D., & Shah, M. A. (2024). A hybrid deep CNN model for brain tumor image multi-classification. *BMC Medical Imaging*, 24(1). <https://doi.org/10.1186/s12880-024-01195-7>
- Teoh, T. T. (2023). CNN for brain tumor classification. Chapter in: *Convolutional Neural Networks for Medical Applications*, 19-34. Springer Link. https://doi.org/10.1007/978-981-19-8814-1_2
- Varghese, M., Varghese, S., & Preethi, S. (2024). Revolutionizing medical imaging: a comprehensive review of optical coherence tomography (OCT). *Journal of Optics*. <https://doi.org/10.1007/s12596-024-01765-6>
- Xu, M., Ouyang, Y., & Yuan, Z. (2023). Deep learning aided neuroimaging and brain regulation. *Sensors*, 23, 4993. <https://doi.org/10.3390/s23114993>