

KLASIFIKASI TUMOR OTAK MELALUI CITRA *MAGNETIC RESONANCE IMAGING* BERBASIS ARSITEKTUR *DEEP LEARNING*

Muhammad Rafly Asri
Fakultas Ilmu Komputer
Universitas Sriwijaya
Palembang, Indonesia

Annisa Darmawahyuni
Fakultas Ilmu Komputer
Universitas Sriwijaya
Palembang, Indonesia

Abstrak— Deteksi dini tumor otak memiliki peran penting dalam menentukan penanganan medis yang tepat serta meningkatkan peluang kesembuhan pasien. *Magnetic Resonance Imaging (MRI)* merupakan metode pencitraan medis yang umum digunakan, namun interpretasi hasil secara manual masih memerlukan waktu yang lama dan berpotensi menimbulkan kesalahan diagnostik. Penelitian ini bertujuan untuk mengembangkan model klasifikasi otomatis berbasis *Convolutional Neural Network (CNN)* guna mengidentifikasi jenis tumor otak pada citra MRI. Dataset yang digunakan terdiri atas empat kelas, yaitu glioma, meningioma, pituitary, dan normal. Model dilatih dan diuji menggunakan teknik *deep learning*, kemudian dievaluasi melalui *confusion matrix* serta visualisasi hasil klasifikasi. Hasil penelitian menunjukkan bahwa model CNN yang dikembangkan mampu mengklasifikasikan jenis tumor otak dengan tingkat akurasi yang tinggi. Secara praktis, penelitian ini berpotensi mendukung proses diagnosis medis dengan menyediakan sistem berbasis kecerdasan buatan yang cepat, akurat, dan efisien, sehingga dapat membantu tenaga medis dalam pengambilan keputusan klinis.

Kata kunci— Tumor Otak, *Magnetic Resonance Imaging (MRI)*, *Convolution Neural Network (CNN)*, *Deep learning*, *Klasifikasi Citra*

I. PENDAHULUAN

Data statistik kanker pada 2016 menyebutkan bahwa Tumor otak merupakan factor utama dari mordibitas terkait kanker, dan penunjang angka kematian di seluruh belahan dunia dan dikenal juga sebagai salah satu jenis kanker yang menjangkit anak-anak dan orang dewasa. *Medical image* processing banyak digunakan untuk deteksi dini kanker otak, yang pada akhirnya menghasilkan perancangan perawatan yang lebih efektif dan meningkatkan tingkat kelangsungan hidup kanker. Namun, tumor otak memiliki variasi jenis yang berbeda (misalnya, Meningioma, Pituitari, dan Glioma), yang membuat penentuan jenis yang tepat pada tahap awal menjadi masalah yang sangat menantang, tetapi merupakan tugas yang krusial karena membantu dokter untuk memiliki rencana perawatan yang lebih tepat dan memiliki prediksi yang lebih baik tentang respons pasien terhadap perawatan yang diadopsi. Di sisi lain, klasifikasi jenis tumor dengan inspeksi manusia adalah tugas yang sangat memakan waktu dan rawan kesalahan, yang sangat tergantung pada pengalaman dan keterampilan ahli radiologi [1],[2].

Saat ini, diagnosis dan tindakan dokter dapat didasarkan pada informasi klinis dan radiologis. Pencitraan Resonansi Magnetik (MRI) merupakan andalan untuk melakukan diagnosis awal pada pasien dengan tumor otak, meskipun pencitraan konvensional memiliki keterbatasan yang signifikan dalam mengevaluasi luas tumor, memprediksi derajat tumor, dan cara menilai respons pengobatan. Teknik akuisisi baru sedang dikembangkan untuk meningkatkan karakterisasi lesi, penilaian terapi, dan penatalaksanaan, namun, pendekatan baru untuk analisis citra telah mendapatkan daya tarik berkat kekayaan informasi yang dimiliki oleh citra radiologis [2].

Pemanfaatan *Deep learning* dalam dunia medis, khususnya pada pengklasifikasian tumor otak, menunjukkan perkembangan yang signifikan baik dari sisi metodologi maupun aplikasi klinis [4] menegaskan bahwa arsitektur *deep learning*, terutama *convolutional neural networks (CNNs)*, mampu mengekstraksi representasi fitur hierarkis dari citra medis dengan tingkat akurasi yang melebihi pengaplikasian tradisional yang berbasis rekayasa fitur [6]. Pendekatan ini kemudian diadopsi dalam kegiatan spesifik seperti pengolahan citra otak, para ahli menunjukkan bahwa pengembangan sistem klasifikasi dan deteksi tumor otak berbasis *deep learning* dengan performa yang kuat mampu untuk melakukan pengelompokan jenis-jenis tumor melalui analisis otomatis citra MRI [5].

Relevansi metodologi penggunaan arsitektur *deep learning* ini diperkuat dengan penekanan efektivitas CNN tunggal dalam menyelesaikan permasalahan klasifikasi citra kompleks, yang dalam konteks medis dapat diterjemahkan ke dalam klasifikasi tumor dengan efisiensi komputasional yang lebih tinggi. Secara keseluruhan, integrasi *deep learning* dalam diagnosis dan klasifikasi tumor otak tidak hanya meningkatkan kecepatan serta akurasi interpretasi untuk citra medis, namun juga memungkinkannya untuk membuka jalan menuju sistem pendukung keputusan klinis yang lebih andal dan skalabel [3].

Penelitian ini ditujukan untuk mengembangkan model klasifikasi citra *Magnetic Resonance Imaging (MRI)* dalam mendeteksi tumor otak yang memiliki 4 yang dibagi menjadi 2 bagian yaitu meningioma, pituitary, glioma dan no tumor sebagai contoh netral. Dataset yang digunakan diperoleh dari platform Kaggle, yang terdiri dari 7023 hasil MRI otak. Proses pra-pemrosesan melibatkan penyesuaian ukuran citra menjadi 224x224 piksel, melakukan augmentasi citra menjadi rotasi horizontal, dan melakukan normalisasi ukuran untuk tahap selanjutnya.

Arsitektur *deep learning* yang digunakan dalam pengujian pada penelitian ini adalah SimpleCNN. Model dilatih selama 10 epoch dengan menggunakan optimasi Adam dan fungsi yang menjelaskan terhadap kehilangan pada saat pelatihan yaitu CrossEntropyLoss dengan tidak memakai bobot awalan. Hasil pelatihan pada penelitian ini menunjukkan bahwa arsitektur yang digunakan terbukti efektif dengan hasil tingkat akurasi yang tertinggi diangka 93,67%.

Penulis berharap bahwa penelitian ini dapat memberikan rekomendasi bawasannya dengan menggunakan arsitektur *deep learning CNN* untuk melakukan diagnosis dini pada penyakit tumor otak dapat menjadi referensi dalam melakukan pengembangan sistem diagnosis tumor otak yang lebih tepat, cepat dan efisien, terkhususnya dapat digunakan di semua tempat yang memiliki keterbatasan tenaga medis maupun, keterbatasan alat medis.

II. KAJIAN PUSTAKA

Klasifikasi tumor otak berbasis *Convolutional Neural Networks (CNN)* telah menjadi paradigma utama dalam melakukan analisis citra medis, khususnya citra Magnetic Resonance Imaging (MRI). CNN terbukti lebih mutakhir dari pada metode *machine learning* konvensional. Berbagai penelitian mutakhir telah membuktikan keunggulan CNN dalam meningkatkan akurasi klasifikasi tumor otak. [10],[11],[16].

Model arsitektur *SimpleCNN* diposisikan sebagai pendekatan efisien yang mampu memberikan kinerja optimal dalam pelatihan dataset dengan kompleksitas yang relatif lebih rendah dibandingkan model *deep CNN* seperti *VGG*, *Resnet*, dan lain lain [12]. Dalam konteks klasifikasi citra medis, pendekatan *SimpleCNN* memanfaatkan lapisan konvolusi yang lebih sedikit namun tetap efektif dalam mengekstraksi fitur dengan lebih relevan [9].

Berbagai penelitian menganggap bahwa tahap *preprocessing* pada citra MRI otak memegang peranan krusial dalam memastikan bahwa model deep learning mampu beroperasi dengan tingkat akurasi optimal. Variasi pada dataset sering kali mengganggu proses ekstraksi fitur jika tidak ditangani sejak awal. Teknik *preprocessing* seperti normalisasi intensitas, augmentasi citra, serta segmentasi area otak yang relevan terbukti meningkatkan kualitas representasi fitur yang diekstrak oleh model arsitektur *SimpleCNN* [7],[8],[14].

Pemilihan model arsitektur *SimpleCNN* dalam klasifikasi tumor otak ini didasari pada efektivitasnya dalam mengekstraksi fitur penting meski dengan arsitektur yang relatif sederhana. Berbeda dengan model kompleks seperti *VGG* atau *ResNet* yang memiliki jumlah parameter sangat besar dan memerlukan sumber daya komputasi tinggi, *SimpleCNN* mampu mencapai performa kompetitif dengan kebutuhan komputasi yang jauh lebih rendah. Pada dataset medis dengan ukuran terbatas seperti citra MRI otak, penggunaan model yang terlalu kompleks berisiko menimbulkan *overfitting* karena jumlah parameter yang tidak sebanding dengan variasi data. Selain itu, *SimpleCNN* memberikan kemudahan dalam proses pelatihan dan interpretasi hasil, yang penting dalam konteks diagnostik medis di mana transparansi model menjadi faktor krusial. Oleh karena itu, pemilihan *SimpleCNN* dianggap sebagai kompromi ideal antara akurasi, efisiensi komputasi, dan reliabilitas diagnostik, tanpa mengorbankan kemampuan model dalam mengenali pola patologis yang relevan [12][13][15].

Citra MRI otak sebagai input menyediakan informasi anatomi dan tekstural detail yang menjadi dasar akurasi klasifikasi tumor. [17]. Citra-citra MRI banyak digunakan untuk melakukan tahap penyaringan terhadap gejala *meningioma*, *pituitari*, dan *glioma* [11].

Singkatnya, efisiensi keberhasilan klasifikasi berbasis arsitektur model *SimpleCNN* terdiri dari beberapa faktor gabungan antara pemilihan arsitektur, tahap *preprocessing*, dan juga kesesuaian karakteristik informasi dataset terhadap model [11],[12],[13],[15],[17].

III. METODOLOGI PENELITIAN

A. DATASET

Data yang digunakan dalam penelitian ini diperoleh dari platform Kaggle yang terdiri dari empat kategori utama: *meningioma*, *glioma*, *pituitary tumor* serta satu kategori untuk *no tumor*. Dataset terdiri dari 7.023 gambar MRI yang telah diberi label oleh ahli radiologi. Dikarenakan terdapat variasi dalam ukuran citra, maka proses normalisasi ukuran dilakukan [21].

B. PRA-PEMROSESAN DATA

Tahap *preprocessing* merupakan langkah fundamental dalam penelitian berbasis *deep learning* karena kualitas data yang dioalah model akan sangat mendongkrak performa akhir klasifikasi. Dalam konteks penelitian ini, yang terkhusus pada citra *MRI* otak, tahap pertama ialah melakukan *resize* dan normalisasi terlebih dahulu karena,

kualitas citra berpengaruh besar terhadap akurasi *system* deteksi yang berbasis citra medis. [7],[14],[16]

Selanjutnya, ukuran citra *MRI* perlu diseragamkan agar kompatibel dengan arsitektur *CNN* yang digunakan, sekaligus menjaga efisiensi komputasi. Pemilihan resolusi 224×224 piksel merupakan standar yang sering digunakan dalam arsitektur *CNN* modern, karena ukuran ini dianggap cukup besar untuk mempertahankan detail spasial citra medis, namun tidak terlalu besar. [9]. *Resize* ke ukuran seragam juga mencegah inkonsistensi dimensi antar citra yang dapat menyebabkan kegagalan pelatihan atau menurunkan akurasi model [15].

Tahapan berikutnya ialah augmentasi, pada tahap ini citra di rotasikan hingga berposisi horizontal. Teknik ini menambah variasi spasial dari citra *MRI* tanpa mengubah informasi anatomi yang relevan, sehingga memperkaya distribusi data yang digunakan dalam pelatihan [10], [11]. Rotasi membantu *CNN* mengenali pola tumor otak dari berbagai orientasi [16].

Tahap terakhir ialah tahap pembagian dataset menjadi tiga sub-bagian, yaitu : *training* 80%, *validation* 10%, dan *testing* 10%. Pemilihan opsi ini bertujuan untuk memberikan jumlah data maksimal yang dapat digunakan dalam proses pelatihan dengan tetap menyediakan cukup data untuk mengatur keseimbangan performa model [17],[21].

C. ARSITEKTUR CNN

Pada studi penelitian ini, penulis melakukan adopsi arsitektur *deep learning* berbasis *Convolutional Neural Network (CNN)*, yang Dimana arsitektur yang digunakan terbukti efektif dalam menganalisis citra medis, terkhususnya citra *MRI*.

Dalam implementasinya, penelitian ini secara khusus menggunakan arsitektur *SimpleCNN*, yakni sebuah varian *CNN* yang di desain lebih ringan dan sederhana dibandingkan arsitektur *deep CNN* lainnya. *SimpleCNN* umumnya terdiri dari beberapa lapisan konvolusi dan pooling yang berfokus pada ekstraksi fitur fundamental tanpa adanya penambahan jaringan secara berlebihan [3].

Model ini dipilih karena dapat memberikan keseimbangan yang optimal antara efisiensi komputasi, kemudahan dalam melakukan pelatihan, serta kemampuan mengklasifikasi, terutama dalam penelitian ini tidak melakukan dataset yang terlalu besar, yang umumnya dijumpai pada data *MRI* medis [12],[15].

SimpleCNN mampu mencapai performa yang kompetitif dengan resiko yang rendah pada bagian *overfitting*, serta interpretasi yang lebih baik. Oleh karena itu, penelitian ini pengangkat model arsitektur *SimpleCNN* merupakan strategi metodologis yang menekankan pada stabilitas, efisiensi dan relevansi diagnosa dalam kasus klasifikasi tumor otak [6],[14].

IV. PELATIHAN MODEL DAN EVALUASI

A. PELATIHAN MODEL

Arsitektur yang digunakan adalah *SimpleCNN* dengan tiga lapisan konvolusi yaitu, *max-pooling*, dan dua *fully connected layer*. Pemilihan arsitektur ini didasarkan pada efisiensi komputasi, kemudahan optimisasi, serta minimnya risiko terhadap kemungkinan *overfitting* [3],[12].

Untuk meningkatkan penyamarataan, dilakukan tahap augmentasi data berupa rotasi acak dan *flip* horizontal, yang terbukti efektif mengurangi praduga tujuan serta memperkaya variasi citra tumor [7]. Dataset dibagi menjadi 80% pelatihan, 10% validasi, dan 10% pengujian, sehingga evaluasi performa dapat dilakukan secara obyektif tanpa adanya kebocoran data [9].

Model dilatih selama 10 *epoch* dengan *batch size* 16 dengan menggunakan *optimizer* Adam dan *CrossEntropyLoss*, serta dilengkapi fitur *Dropout* untuk mencegah terjadinya *overfitting*. Bobot terbaik disimpan berdasarkan akurasi validasi tertinggi pada tiap epoch [4],[6].

Proses pelatihan data dilakukan di media Google Colab menggunakan GPU Tesla K80, dengan estimasi waktu sekitar 3 jam 10 menit. Hasil pelatihan menunjukkan bahwa arsitektur SimpleCNN yang sederhana mampu memberikan kinerja yang efisien pada perangkat keras yang bersifat terbatas [1],[16].

B. EVALUASI MODEL

Evaluasi terhadap model klasifikasi dilakukan demi memberi penilaian terhadap kinerja dan ketepatan prediksi dari struktur model CNN yang digunakan. Penilaian terhadap model klasifikasi ini memiliki peranan penting dalam melakukan klasifikasi citra medis yang mana semua kekurangan dapat berpengaruh besar untuk memberikan keputusan terhadap diagnosis. Oleh sebab itu, penelitian ini memiliki beberapa poin penilaian dalam mengevaluasi kinerja model yang berfokus pada arsitektur *deep learning* ini.

1) CONFUSION MATRIX

Confusion matrix merupakan sebuah tabel yang digunakan untuk mengevaluasi kinerja model klasifikasi dengan membandingkan label aktual dan prediksi. Matriks ini menampilkan distribusi *True Positive (TP)*, *True Negative (TN)*, *False Positive (FP)*, dan *False Negative (FN)* yang menunjukkan pola kesalahan model [6],[13].

Pada kasus multi-kelas seperti klasifikasi empat jenis penyakit mata, matriks berbentuk $N \times N$ dan menjadi dasar perhitungan metrik evaluasi seperti akurasi, presisi, dan sensitivitas [16].

2) EVALUATION MATRIX

Berdasarkan hasil pelatihan model, metrik evaluasi digunakan untuk menilai performa dari model.

• Akurasi

Akurasi menilai proporsi prediksi benar terhadap keseluruhan prediksi, dan merupakan metrik dasar dalam evaluasi kinerja model klasifikasi [4].

$$Akurasi = \frac{TP+TN}{TP+TN+FP+FN}$$

• Prediksi

Prediksi pada CNN merupakan proses menghasilkan keputusan klasifikasi berdasarkan representasi fitur hierarkis yang diekstraksi secara otomatis dari citra, sehingga mampu memberikan hasil diagnostik yang andal pada analisis medis [4].

$$\text{Prediksi} = y^{\wedge} = \arg c \in C \max P(y=c|x;\theta)$$

dengan keterangan:

- Y = kelas hasil prediksi,
- C = himpunan semua kelas,
- x = citra masukan,
- θ = parameter model CNN,
- $P(y=c|x;\theta)$ = probabilitas bahwa citra x termasuk ke dalam kelas c yang dihitung melalui softmax pada lapisan output.

• Presisi

Presisi mengukur seberapa baik model dapat memprediksi kelas positif. Dari semua data yang dianggap positif, seberapa banyak yang benar-benar positif. Presisi sangat penting terutama dalam bidang data medis, untuk mengurangi kesalahan positif palsu. [7].

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

• Sensitivitas

Sensitivitas mengukur seberapa baik model dalam mendeteksi seluruh data yang seharusnya diklasifikasikan sebagai positif. Sensitivitas penting untuk memastikan bahwa kasus penyakit tidak terlewat [4].

$$Sensitivitas = \frac{TP}{TP+FN}$$

• Spesifitas

Spesifitas mengukur kemampuan model dalam mengidentifikasi data negatif secara benar. Dalam klasifikasi medis, spesifitas penting untuk menghindari kesalahan diagnosis pada individu sehat [4].

$$Spesifitas = \frac{TN}{TN+FP}$$

• F1-Score

F1-score adalah rata-rata antara presisi dan sensitivitas, yang memberikan keseimbangan antara kedua metrik tersebut. *F1-score* berguna ketika distribusi kelas tidak seimbang atau saat kesalahan klasifikasi memiliki risiko tinggi [4].


$$F1 - Score = 2 \times \frac{Presisi \times Sensitivitas}{Presisi + Sensitivitas}$$

V. HASIL PENELITIAN

A. HASIL PELATIHAN MODEL

Pelatihan model dilakukan selama 10 epoch dengan dataset citra *MRI* yang telah dilakukan tahap *preprocessing*, augmentasi data, dan pembagian dataset. Arsitektur yang digunakan untuk melakukan pengujian ialah *SimpleCNN*.


Berikut merupakan plot hasil pelatihan yang menampilkan *loss* dan akurasi validasi selama proses pelatihan dilakukan.



Gambar 1. Training Plot

B. EVALUASI HASIL KLASIFIKASI

Hasil dari kinerja model klasifikasi memperoleh *Confusion Matrix* untuk arsitektur model *SimpleCNN* yang digunakan.



Gambar 2. *Confusion Matrix*

Evaluasi hasil klasifikasi pada penelitian ini dilakukan dengan memanfaatkan confusion matrix serta beberapa metrik turunan seperti akurasi, presisi, sensitivitas (recall), spesifisitas, dan F1-score yang diperoleh dari model CNN. Berdasarkan hasil pengujian pada data uji, confusion matrix menunjukkan bahwa model memiliki kemampuan klasifikasi yang baik pada keempat kelas, yaitu glioma, meningioma, pituitary, dan notumor. Melalui confusion matrix tersebut, dapat terlihat distribusi prediksi antara kelas tumor otak dan non-tumor, sehingga memudahkan identifikasi pola kesalahan prediksi, baik dalam bentuk false positive maupun false negative.

Secara umum, model menunjukkan performa yang tinggi dengan tingkat akurasi keseluruhan mencapai sekitar 95%. Nilai ini menunjukkan bahwa sebagian besar citra MRI otak berhasil diklasifikasikan dengan benar oleh model CNN. Hasil ini memperkuat efektivitas CNN dalam mengenali pola visual kompleks pada citra medis, terutama pola tekstur dan struktur jaringan otak.

1. Kelas Glioma

Model berhasil mengklasifikasikan 281 citra dengan benar sebagai glioma. Kesalahan klasifikasi terjadi pada sebagian kecil data, yaitu 14 sampel yang salah dikenali sebagai meningioma dan 4 sampel sebagai pituitary. Kesalahan ini dapat disebabkan oleh kemiripan karakteristik visual antara glioma dan meningioma, terutama pada bagian citra dengan batas tumor yang kurang tegas. Meskipun demikian, nilai presisi dan sensitivitas pada kelas ini tetap tinggi, yang menandakan model cukup andal dalam mengenali glioma.

2. Kelas Meningioma

Sebanyak 274 citra berhasil diklasifikasikan dengan benar sebagai meningioma, sementara 12 citra salah dikenali sebagai notumor dan 9 lainnya sebagai pituitary. Hal ini menunjukkan bahwa model masih menghadapi tantangan dalam membedakan meningioma dari kelas lain, terutama ketika intensitas dan tekstur citra menyerupai jaringan otak normal. Namun secara keseluruhan, tingkat deteksi meningioma masih tergolong baik, sehingga model dapat diandalkan dalam mendeteksi tumor jenis ini.

3. Kelas Notumor (Otak Normal)

Model menunjukkan performa terbaik pada kelas notumor dengan 395 citra berhasil diklasifikasikan secara benar, dan hanya sedikit kesalahan prediksi. Hal ini menunjukkan spesifisitas tinggi, di mana model mampu mengenali otak normal secara akurat dan menghindari kesalahan diagnosis pada pasien sehat. Dalam konteks medis, hal ini sangat penting karena mengurangi risiko diagnosis positif palsu (false positive), yang dapat menyebabkan tindakan medis yang tidak diperlukan.

4. Kelas Pituitary

Sebanyak 279 citra pituitary terklasifikasi dengan benar, sementara kesalahan prediksi hanya terjadi pada 6 citra (2 salah ke glioma dan 4 ke meningioma). Hasil ini menunjukkan bahwa model mampu mengenali ciri morfologi khas pituitary tumor dengan baik. Akurasi tinggi pada kelas ini menandakan bahwa fitur-fitur yang diekstraksi CNN cukup efektif untuk membedakan tumor pituitary dari jenis tumor lainnya.

Secara keseluruhan, nilai akurasi, presisi, sensitivitas, dan F1-score yang diperoleh menunjukkan bahwa model CNN mampu memberikan kinerja yang stabil dan seimbang antar kelas. Akurasi tinggi mengindikasikan kemampuan model untuk melakukan klasifikasi dengan tingkat kesalahan yang rendah, sementara nilai sensitivitas dan spesifisitas yang tinggi menegaskan keandalan model dalam konteks diagnostik medis.

Menurut Afshar et al. (2018) dan Ari & Hanbay (2018), penggunaan CNN dalam klasifikasi tumor otak memberikan keunggulan karena mampu mengekstraksi fitur hierarkis dari citra MRI tanpa memerlukan rekayasa fitur manual (handcrafted features). Hasil penelitian ini juga selaras dengan pandangan Litjens et al. (2017) yang menekankan pentingnya sensitivitas tinggi untuk menghindari false negative (kasus tumor yang tidak terdeteksi), serta spesifisitas tinggi untuk meminimalkan kesalahan diagnosis pada pasien sehat.

Dengan demikian, hasil klasifikasi pada penelitian ini membuktikan bahwa arsitektur SimpleCNN yang digunakan mampu mencapai keseimbangan antara kompleksitas komputasi dan performa diagnostik. Meskipun termasuk model sederhana, SimpleCNN terbukti mampu memberikan hasil yang kompetitif dan dapat dijadikan dasar pengembangan sistem deteksi dini tumor otak berbasis citra MRI secara efisien.

KESIMPULAN

Penelitian ini menyimpulkan bahwa model *SimpleCNN* yang dibangun dan dilatih, dapat melakukan klasifikasi jenis tumor otak (*glioma*, *meningioma*, *pituitary*, dan *no tumor*) secara efektif melalui citra *MRI* dengan akurasi validasi mencapai 93,67% dan hasil evaluasi yang konsisten pada percobaan data. Proses pelatihan menggunakan *optimizer* Adam dan *CrossEntropyLoss*, serta teknik augmentasi data mampu meningkatkan kemampuan generalisasi model dan mencegah terjadinya *overfitting*. Pelatihan model menunjukkan bahwa arsitektur ini efisien dan dapat diandalkan meskipun dijalankan dibawah perangkat keras yang memiliki keterbatasan.

Evaluasi model memperkuat bawasannya pendekatan model arsitektur *SimpleCNN* ini sangat potensial untuk di integrasikan ke dalam sistem diagnosis medis berbasis *deep learning* guna mempercepat dan meningkatkan akurasi deteksi tumor otak.

REFERENSI

- [1] Afshar, Parnian, Arash Mohammadi, and Konstantinos N Plataniotis. 2018. "Concordia Institute for Information Systems Engineering, Concordia University, Montreal, QC, Canada Department of Electrical and Computer Engineering, University of Toronto, Toronto, ON, Canada Emails: { p Afs, Arashmoh } @ EnCs . Concordia . Ca." 2018 25th IEEE International Conference on Image Processing (ICIP): 3129–33.
- [2] Akinyelu, Andronicus A., Fulvio Zaccagna, James T. Grist, Mauro Castelli, and Leonardo Rundo. 2022. "Brain Tumor Diagnosis Using Machine Learning, Convolutional Neural Networks, Capsule Neural Networks and Vision Transformers, Applied to MRI: A Survey." *Journal of Imaging* 8(8): 1–40. doi:10.3390/jimaging8080205.
- [3] Song, Huaxiang, and Yong Zhou. 2023. "Simple Is Best: A Single-CNN Method for Classifying Remote Sensing Images."

- Networks and Heterogeneous Media 18(4): 1600–1629. doi:10.3934/nhm.2023070.
- [4] Litjens, Geert, Thijs Kooi, Babak Ehteshami Bejnordi, Arnaud Arindra Adiyoso Setio, Francesco Ciompi, Mohsen Ghafoorian, Jeroen A.W.M. van der Laak, Bram van Ginneken, and Clara I. Sánchez. 2017. “A Survey on Deep Learning in Medical Image Analysis.” *Medical Image Analysis* 42(December 2012): 60–88. doi:10.1016/j.media.2017.07.005.
- [5] Ari, Ali, and Davut Hanbay. 2018. “Deep Learning Based Brain Tumor Classification and Detection System.” *Turkish Journal of Electrical Engineering and Computer Sciences* 26(5): 2275–86. doi:10.3906/elk-1801-8.
- [6] Bhatt, Dulari, Chirag Patel, Hardik Talsania, Jigar Patel, Rasmika Vaghela, Sharnil Pandya, Kirit Modi, and Hemant Ghayvat. 2021. “Cnn Variants for Computer Vision: History, Architecture, Application, Challenges and Future Scope.” *Electronics (Switzerland)* 10(20): 1–28. doi:10.3390/electronics10202470.
- [7] Veeramuthu, A., S. Meenakshi, G. Mathivanan, Ketan Kotecha, Jatinderkumar R. Saini, V. Vijayakumar, and V. Subramaniaswamy. 2022. “MRI Brain Tumor Image Classification Using a Combined Feature and Image-Based Classifier.” *Frontiers in Psychology* 13(March): 1–12. doi:10.3389/fpsyg.2022.848784.
- [8] Kumari, Priyanka, and Yogesh Mohan. 2022. “Performance Analysis of Machine Learning Techniques for Predicting Brain Tumor.” (December).
- [9] Meng, Nan, Edmund Y. Lam, Kevin K. Tsia, and Hayden Kwok Hay So. 2019. “Large-Scale Multi-Class Image-Based Cell Classification with Deep Learning.” *IEEE Journal of Biomedical and Health Informatics* 23(5): 2091–98. doi:10.1109/JBHI.2018.2878878.
- [10] Díaz-Pernas, Francisco Javier, Mario Martínez-Zarzuela, David González-Ortega, and Míriam Antón-Rodríguez. 2021. “A Deep Learning Approach for Brain Tumor Classification and Segmentation Using a Multiscale Convolutional Neural Network.” *Healthcare (Switzerland)* 9(2). doi:10.3390/healthcare9020153.
- [11] Abdusalomov, Akmalbek Bobomirzaevich, Mukhriddin Mukhiddinov, and Taeg Keun Whangbo. 2023. “Brain Tumor Detection Based on Deep Learning Approaches and Magnetic Resonance Imaging.” *Cancers* 15(16). doi:10.3390/cancers15164172.
- [12] Oyedare, Taiwo, Vijay K. Shah, Daniel J. Jakubisin, and Jeffrey H. Reed. 2023. “Keep It Simple: CNN Model Complexity Studies for Interference Classification Tasks.” *IEEE INFOCOM 2023 - Conference on Computer Communications Workshops, INFOCOM WKSHPS 2023*. doi:10.1109/INFOCOMWKSHPS57453.2023.10226045.
- [13] Hassan, Aya, Moatamed Refaat, and Ashraf Hemeida. 2022. “Image Classification Based Deep Learning: A Review.” *Aswan University Journal of Sciences and Technology* 2(1): 11–35. doi:10.21608/aujst.2022.259887.
- [14] Amin, Javaria, Muhammad Sharif, Anandakumar Haldorai, Mussarat Yasmin, and Ramesh Sundar Nayak. 2022. “Brain Tumor Detection and Classification Using Machine Learning: A Comprehensive Survey.” *Complex and Intelligent Systems* 8(4): 3161–83. doi:10.1007/s40747-021-00563-y.
- [15] Elngar, Ahmed A., Mohamed Arafa, Amar Fathy, Basma Moustafa, Omar Mahmoud, Mohamed Shaban, and Nehal Fawzy. 2021. “Image Classification Based On CNN: A Survey.” *Journal of Cybersecurity and Information Management* 6(1): PP. 18-50. doi:10.54216/jcim.060102.
- [16] Anwar, Syed Muhammad, Muhammad Majid, Adnan Qayyum, Muhammad Awais, Majdi Alnowami, and Muhammad Khurram Khan. 2018. “Medical Image Analysis Using Convolutional Neural Networks: A Review.” *Journal of Medical Systems* 42(11): 1–13. doi:10.1007/s10916-018-1088-1.
- [17] Agarwal, Shruti, Dhyanendra Jain, Shubh Gupta, Saijal Sawhney, and Yash Mittal. 2023. “Brain Tumor Detection and Classification Using Deep Learning.” *Proceedings - IEEE 2023 5th International Conference on Advances in Computing, Communication Control and Networking, ICAC3N 2023*: 635–40. doi:10.1109/ICAC3N60023.2023.10541584.
- [18] Kingma, Diederik P., and Max Welling. 2014. “Auto-Encoding Variational Bayes.” *2nd International Conference on Learning Representations, ICLR 2014 - Conference Track Proceedings (ML)*: 1–14. doi:10.61603/ceas.v2i1.33.2
- [19] M. S. Hossain, G. Muhammad, and M. Alhamid, "Automatic human activity recognition using deep learning for IoT-based healthcare systems," *IEEE Access*, vol. 6, pp. 42141-42151, 2018.
- [20] Kaggle Dataset: Brain Tumor Classification (MRI). [Online]. Available: <https://www.kaggle.com/navoneel/brain-mri-images-for-brain-tumor-detection>