

Klasifikasi Tumor Otak dengan Resnet berdasarkan MRI

Akhmad Irsyad^{a,1}, Islamiyah^{a,2}, Hario Jati Setyadi^{a,3}, Fakhmul Amal^{a,4}

^a Sistem Informasi, Universitas Mulawarman, Samarinda

¹ akhmadirsyad@unmul.ac.id; ² islamiyah@ft.unmul.ac.id; ³ hario@ft.unmul.ac.id. ⁴ fakhmulamal@gmail.com

INFORMASI ARTIKEL

Histori Artikel

Diterima : 10 Agustus 2023
Direvisi : 19 Agustus 2023
Diterbitkan : 30 Agustus 2023

Kata Kunci:

Covid-19
Klasifikasi
Deep Learnin
EfficientNet

ABSTRAK

Tumor otak dapat dikategorikan sebagai kanker (ganas) atau non-kanker (jinak), dan pertumbuhannya dapat menimbulkan risiko kesehatan yang signifikan. Deteksi dini tumor otak sangat penting untuk penanganan yang efektif. Meskipun pencitraan resonansi magnetik (MRI) adalah metode yang efektif untuk mengidentifikasi tumor otak, terdapat tantangan dalam analisis hasil yang memerlukan tenaga medis terlatih. Oleh karena itu, penelitian ini mengembangkan metode otomatis menggunakan deep learning, khususnya arsitektur ResNet-50, untuk klasifikasi citra MRI. Dataset yang digunakan terdiri dari 7.023 gambar dengan empat kelas tumor: glioma, meningioma, normal, dan pituitary. Hasil evaluasi menunjukkan bahwa model ResNet-50 mencapai akurasi 71,55% dan F1-Measure 0,6919, lebih baik dibandingkan dengan model base CNN yang memiliki akurasi 71,34% dan F1-Measure 0,6714. Penelitian ini diharapkan dapat meningkatkan akurasi dan efisiensi deteksi otomatis tumor otak, serta memberikan kontribusi dalam manajemen klinis.

2023 SAKTI – Sains, Aplikasi, Komputasi dan Teknologi Informasi.

Hak Cipta.

I. Pendahuluan

Tumor otak merupakan suatu massa atau kumpulan sel abnormal yang terdapat di dalam otak. Tengkorak, yang berfungsi melindungi otak, memiliki struktur yang kaku, sehingga setiap pertumbuhan di dalam ruang terbatas ini dapat menimbulkan berbagai masalah. Tumor otak dapat dikategorikan sebagai kanker (ganas) atau non-kanker (jinak). Pertumbuhan tumor, baik jinak maupun ganas, dapat menyebabkan peningkatan tekanan di dalam tengkorak, yang berpotensi merusak jaringan otak dan mengancam keselamatan jiwa (Siyoun Biratu et al., 2021).

Metode yang umum digunakan untuk mendeteksi tumor otak adalah pencitraan resonansi magnetik (MRI). MRI adalah teknik *imaging* medis yang menggunakan medan magnet kuat dan gelombang radio untuk menghasilkan gambar rinci dari struktur dan jaringan di dalam otak (Wulansari & Rahman, 2022). Meskipun MRI merupakan alat yang sangat efektif untuk mengidentifikasi tumor otak, terdapat beberapa tantangan dalam proses deteksinya, terutama terkait dengan keterbatasan jumlah tenaga medis yang terlatih. Kekurangan profesional medis yang memiliki kemampuan dalam menganalisis hasil MRI dapat menghambat proses diagnosis yang cepat dan akurat, yang pada akhirnya dapat berdampak pada penanganan dan prognosis pasien.

Diperlukan pengembangan metode yang dapat mempermudah deteksi otomatis tumor otak untuk meningkatkan akurasi dan efisiensi diagnosis. Salah satu pendekatan dalam deteksi otomatis adalah dengan memanfaatkan deep learning untuk klasifikasi citra medis. Deep learning telah diterapkan secara luas dalam bidang citra medis, memberikan kemajuan signifikan dalam proses diagnosis dan pengobatan. Salah satu contohnya adalah penggunaan jaringan saraf konvolusional (CNN) untuk analisis citra radiologi, seperti X-ray (Rian et al., 2020), CT scan (Irsyad et al., 2023), dan MRI (Hastomo et al., 2021). Dalam aplikasi ini, model CNN dapat dilatih untuk mengenali pola-pola yang menunjukkan adanya kelainan, seperti tumor, fraktur, atau infeksi, dengan akurasi yang tinggi. Misalnya, penelitian telah menunjukkan bahwa model CNN dapat mendeteksi kanker paru-paru dari citra X-ray dengan tingkat sensitivitas yang lebih baik dibandingkan dengan metode tradisional. Dengan memanfaatkan teknik augmentasi data, transfer learning, dan fine-tuning, model deep learning ini dapat meningkatkan kemampuan generalisasi dan akurasi klasifikasi, sehingga memberikan hasil yang lebih cepat dan andal dalam diagnosis medis. Keberhasilan ini menunjukkan potensi besar deep learning dalam memperbaiki hasil klinis dan meningkatkan efisiensi layanan kesehatan.

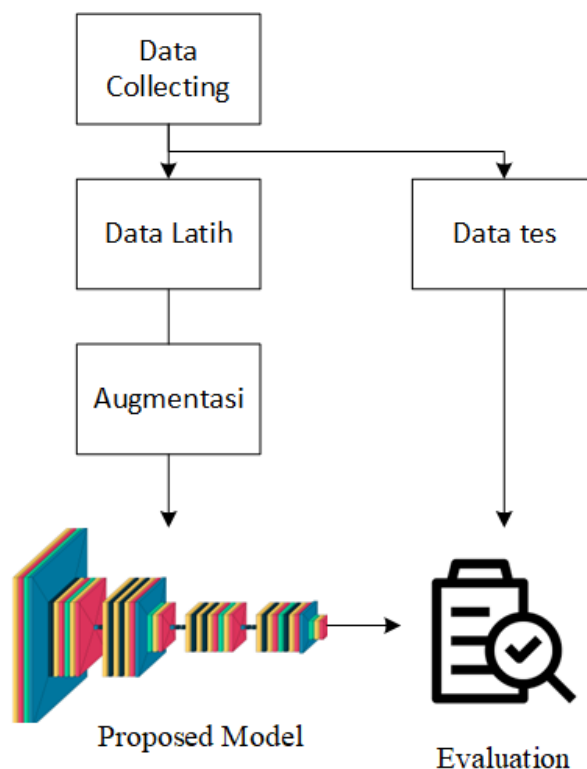
Salah satu arsitektur *deep learning* yang sering digunakan dalam analisis citra medis adalah Residual Network (ResNet) (Sanjaya & Ayub, 2020). ResNet dirancang untuk mengatasi masalah pelatihan jaringan

saraf yang dalam, di mana penambahan lapisan tambahan sering kali menyebabkan penurunan kinerja model akibat fenomena degradasi. Dengan menerapkan konsep residual learning, ResNet memungkinkan informasi dan gradien untuk mengalir melalui jaringan tanpa kehilangan detail penting. Arsitektur ini menggunakan "shortcut connections" yang menghubungkan lapisan-lapisan non-adjacent, sehingga memfasilitasi pembelajaran identitas fungsi yang mengurangi kesulitan dalam pelatihan jaringan yang dalam. Kelebihan utama dari ResNet adalah kemampuannya untuk mencapai akurasi tinggi dalam tugas klasifikasi meskipun dengan kedalaman yang signifikan, serta kemudahan dalam pengoptimalan yang berkontribusi pada peningkatan kinerja dalam berbagai aplikasi, termasuk deteksi tumor pada citra medis. Penerapan ResNet dalam konteks ini menunjukkan potensi besar dalam memperbaiki akurasi dan efisiensi deteksi otomatis di bidang radiologi.

Penelitian ini bertujuan untuk mengeksplorasi kontribusi Residual Network (ResNet) dalam mendeteksi tumor otak melalui analisis citra MRI. Dengan memanfaatkan arsitektur deep learning yang telah terbukti efektif dalam berbagai tugas klasifikasi citra, penelitian ini berfokus pada penilaian kemampuan ResNet dalam mengidentifikasi dan mengklasifikasikan jenis-jenis tumor otak berdasarkan fitur-fitur yang terkandung dalam citra MRI. Hasil dari penelitian ini diharapkan dapat memberikan wawasan yang lebih dalam mengenai efektivitas ResNet sebagai alat bantu diagnostik dalam bidang radiologi, serta meningkatkan akurasi deteksi otomatis tumor otak, yang pada gilirannya dapat berkontribusi pada perbaikan dalam manajemen klinis dan pengobatan pasien.

II. Material dan Metode (bold, 10 pt)

Penelitian ini dimulai dengan mengumpulkan data CT-scan paru-paru lalu data yang diperoleh dilakukan praproses, tujuan dilakukan praproses adalah untuk mengurangi noise yang ada pada gambar sehingga diperoleh hasil output yang lebih baik. Data yang telah di praproses selanjutnya dibagi menjadi data train dan data test. Nantinya data train akan digunakan augmentasi lalu dilakukan pelatihan model. Pada penelitian akan menggunakan arsitektur Resnet50. Hasil model pelatihan model Resnet50 akan di uji coba dengan data tes sehingga diperoleh hasil evaluasi dari model yang dibuat, untuk lebih jelas alur penelitian dapat dilihat pada Gambar 1.




Gambar 1. Alur Penelitian.

A. Dataset


Klasifikasi tumor otak dilakukan dengan menggunakan *dataset* dari Kaggle, dataset yang dikembangkan oleh Masoud Nickpakvar, (2021) memiliki empat kelas yaitu glioma, meningioma, normal dan pituitary. Dataset terdiri dari 7023 gambar MRI otak. Dataset akan dibagi menjadi data latih, data

validasi dan data tes, dengan perbandingan 60% untuk data latih, 20% data validasi, dan 20% data tes. Data validasi digunakan digunakan untuk memberikan evaluasi selama proses pelatihan model.



Gambar 2. (a) MRI otak dengan glioma, (b) MRI otak dengan meningioma, (c) MRI otak normal, (d) MRI otak dengan pituitary

B. Deep Residual Network



Gambar 3. Skip Connection (Irsyad & Tjandrasa, 2021).

Deep Residual Network (ResNet) adalah arsitektur yang diperkenalkan oleh He et al. pada tahun 2015 sebagai solusi untuk tantangan dalam pelatihan model *Deep Learning*, terutama dalam hal durasi pelatihan yang panjang dan penurunan performa pada model dengan lapisan yang sangat dalam. ResNet menawarkan pendekatan inovatif melalui penggunaan *skip connection*, yang memungkinkan sebagian informasi melewati

beberapa lapisan tanpa diubah, sehingga mencegah penurunan kinerja yang umumnya terjadi pada jaringan yang lebih dalam. Dibandingkan dengan arsitektur Convolutional Neural Networks (CNN) tradisional, ResNet memiliki keunggulan dalam mempertahankan kinerja yang optimal meskipun arsitektur jaringan semakin dalam. Selain itu, model ini juga lebih efisien dalam komputasi dan mampu melatih jaringan secara lebih efektif (He et al., 2016). Ilustrasi implementasi *skip connection* pada ResNet dapat dilihat pada Gambar 3.

C. Coefficient Metrics

Metrik seperti *F-Measure*, *precision*, dan *recall* digunakan untuk mengevaluasi hasil klasifikasi. Precision mengukur proporsi dari situasi positif yang diprediksi yang benar-benar terkonfirmasi sebagai positif. Di sisi lain, recall menghitung persentase dari kasus positif yang sesungguhnya yang berhasil diprediksi dengan tepat sebagai positif (Zou et al., 2004). Secara umum, *precision* dan *recall* dapat dirumuskan menggunakan Persamaan 4, dan informasi lebih lanjut dapat ditemukan pada Gambar 4.

		Actual	
		Positive	Negative
Predicted	Positive	TN	FN
	Negative	FP	TP

Gambar 4. Confusion Matrix.

Metrik koefisien didefinisikan dan diilustrasikan dalam Gambar 4. True Positive (TP) merupakan salah satu metrik ini, yang menunjukkan data yang diklasifikasikan sebagai positif oleh model dan di mana label sebenarnya juga positif. True Negative (TN) merujuk pada nilai yang diklasifikasikan sebagai negatif oleh model, di mana label sebenarnya juga negatif. Data False Positive (FP) didefinisikan sebagai informasi yang diklasifikasikan sebagai positif oleh model, meskipun nilai sebenarnya negatif. Sementara itu, False Negative (FN) adalah kebalikan dari false positive, di mana data diklasifikasikan sebagai negatif meskipun nilai sebenarnya positif (Gifari et al., 2022). Nilai yang diperoleh dari metrik koefisien dapat digunakan untuk menghitung akurasi, precision, dan recall menggunakan Persamaan 1.

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

$$Precision = \frac{TP}{TP+FP} \quad (1)$$

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

F-measure parameter pengukuran yang diperlukan untuk memaksimalkan hasil yang dicapai. F-measure secara efektif menghubungkan True Positive dengan rata-rata dari Prediksi Positif dan Real Positive. Persamaan 2 dapat digunakan untuk merumuskan F-measure. Hasil klasifikasi menjadi lebih baik seiring dengan meningkatnya nilai F-measure.

$$F_{measure} = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (2)$$

III. Hasil dan Pembahasan

Penelitian dilakukan dengan membandingkan hasil klasifikasi menggunakan arsitektur Resnet50 dengan base CNN, base CNN terdiri dari tiga layer convolutional layer yang menggunakan maxpooling dan activation relu, lalu di akhir arsitektur ditambahkan flatten, dense layer, dropout, dan output menggunakan softmax karena data memiliki 4 kelas. Dari hasil penelitian yang ditunjukkan pada tabel 1, ujicoba dengan arsitektur

Resnet50 memiliki hasil yang lebih baik apabila dibandingkan dengan base CNN, hal ini dapat dilihat dengan hasil F-measure Resnet50 sebesar 0.6919, sedangkan base CNN sebesar 0.6714.


Tabel 1. Perbandingan hasil Uji Coba.

Model	Accuracy	Recall	Precision	F1-Measure
Base CNN	0.7134	0.6911	0.7213	0.6714
Resnet50	0.7155	0.7062	0.7089	0.6919

Gambar 5 adalah matriks yang menunjukkan performa model ResNet-50 yang digunakan untuk klasifikasi tumor otak, dengan empat kelas tumor yang dilabeli 0, 1, 2, dan 3. 0 adalah MRI otak Glukoma, 1 adalah MRI otak meningioma, 2 adalah MRI otak normal, 3 adalah MRI otak pituitary.

Pada coefficient metrics ini, sumbu vertikal (Y) menunjukkan label sebenarnya dari sampel data, sedangkan sumbu horizontal (X) menunjukkan label yang diprediksi oleh model. Elemen-elemen diagonal menggambarkan jumlah sampel yang diklasifikasikan dengan benar, sementara elemen-elemen di luar diagonal menunjukkan jumlah sampel yang salah diklasifikasikan.

Beberapa poin penting dari matriks ini adalah sebagai berikut: Untuk kelas 0, terdapat 66 sampel yang diklasifikasikan dengan benar, tetapi juga terdapat beberapa kesalahan di mana 61 sampel diprediksi sebagai kelas 1 dan 19 sampel diprediksi sebagai kelas 3. Untuk kelas 1, sebanyak 77 sampel diklasifikasikan dengan benar, namun ada 43 sampel yang salah diklasifikasikan sebagai kelas 2. Kelas 2 menunjukkan kinerja yang sangat baik dengan 187 sampel yang diklasifikasikan dengan benar, dan hanya sedikit kesalahan. Kelas 3 juga menunjukkan performa yang baik, dengan 142 sampel yang benar diklasifikasikan dan hanya 2 sampel yang salah prediksi sebagai kelas 1. Secara keseluruhan, model menunjukkan kinerja yang baik pada klasifikasi kelas 2 dan kelas 3, tetapi ada beberapa kebingungan atau kesalahan prediksi yang lebih tinggi pada kelas 0 dan kelas 1, terutama antara kelas 0 dan 1 serta antara kelas 1 dan 2.



Gambar 5. Hasil Coefficient metrics Resnet50.

Tabel 2. Hasil Evaluasi per kelas arsitektur Resnet50.

kelas	Recall	Precison	F1-Measure
Glukoma	0.4430	0.7586	0.5593
meningioma	0.4968	0.5347	0.5151
normal	0.8990	0.8026	0.8481
pituitary	0.9861	0.7396	0.8452

Berdasarkan metrik evaluasi pada Tabel 2, performa model klasifikasi tumor otak untuk kelas Glaukoma, model memiliki nilai recall sebesar 0,4430, yang menunjukkan bahwa hanya 44,30% dari semua kasus glaukoma berhasil diidentifikasi dengan benar oleh model. Meskipun demikian, precision untuk kelas ini mencapai 0,7586, yang berarti dari semua prediksi yang menyatakan glaukoma, 75,86% adalah benar-benar kasus glaukoma. Kombinasi ini menghasilkan nilai F1-Measure sebesar 0,5593, yang menunjukkan bahwa model kurang optimal dalam menangani klasifikasi glaukoma.

Pada kelas Meningioma, model memiliki recall sebesar 0,4968, yang berarti hampir setengah dari total kasus meningioma berhasil terdeteksi. Namun, precision untuk kelas ini hanya 0,5347, yang menunjukkan bahwa prediksi meningioma kurang akurat. Dengan nilai F1-Measure sebesar 0,5151, performa model untuk mendeteksi meningioma tergolong sedang, dan masih membutuhkan peningkatan. Kelas Normal, performa model sangat baik dengan nilai recall sebesar 0,8990, yang berarti 89,90% dari kasus normal teridentifikasi dengan benar. Precision juga cukup tinggi pada 0,8026, menunjukkan bahwa sebagian besar prediksi normal adalah akurat. Hal ini menghasilkan nilai F1-Measure sebesar 0,8481, yang menunjukkan kinerja yang sangat baik dalam mengklasifikasikan kelas ini.

Kelas Pituitary menunjukkan hasil yang hampir sempurna dengan recall sebesar 0,9861, yang berarti hampir semua kasus pituitary berhasil diidentifikasi dengan benar. Namun, precision untuk kelas ini sedikit lebih rendah di angka 0,7396, yang menunjukkan bahwa tidak semua prediksi untuk pituitary sepenuhnya akurat. Meskipun demikian, dengan nilai F1-Measure sebesar 0,8452, model menunjukkan kinerja yang sangat baik dalam mengklasifikasikan tumor pituitary. Secara keseluruhan, model ini bekerja sangat baik dalam mendeteksi tumor Normal dan Pituitary, namun masih membutuhkan perbaikan dalam mengklasifikasikan Glaukoma dan Meningioma, terutama dalam meningkatkan recall untuk mencegah banyaknya kasus yang terlewatkan.

IV. Kesimpulan

Penelitian ini berhasil menunjukkan bahwa arsitektur ResNet-50 dapat digunakan secara efektif untuk mendeteksi tumor otak melalui analisis citra MRI. Hasil evaluasi menunjukkan bahwa model ini memberikan akurasi yang lebih tinggi dibandingkan dengan model base CNN. Model ResNet-50 menunjukkan performa yang sangat baik dalam mengidentifikasi kelas tumor normal dan pituitary, dengan nilai recall dan F1-Measure yang tinggi. Namun, kinerja model pada kelas glaukoma dan meningioma masih memerlukan perbaikan, terutama dalam meningkatkan recall untuk mencegah banyaknya kasus yang terlewat. Secara keseluruhan, penelitian ini menyimpulkan bahwa penggunaan deep learning, khususnya ResNet, dapat meningkatkan akurasi deteksi otomatis tumor otak, yang berpotensi berkontribusi pada perbaikan dalam manajemen klinis dan pengobatan pasien.

Daftar Pustaka

- Gifari, O. I., Adha, M., Freddy, F., & Durrand, F. F. S. (2022). Analisis Sentimen Review Film Menggunakan TF-IDF dan Support Vector Machine. *Journal of Information Technology*, 2(1), 36–40. <https://doi.org/10.46229/jifotech.v2i1.330>
- Hastomo, W., Sugiyanto, & Sudjiran. (2021). Convolution Neural Network Arsitektur Mobilenet-V2 Untuk Mendeteksi Tumor Otak. *Seminar Nasional Teknologi Informasi Dan Komunikasi STI&K (SeNTIK)*, 5(1), 17–21.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 770–778. <https://doi.org/10.1109/CVPR.2016.90>
- Irsyad, A., & Tjandrasa, H. (2021). Detection of COVID-19 from Chest CT Images Using Deep Transfer Learning. *International Conference On Information & Communication Technology And System (ICTS)*.
- Irsyad, A., Tjandrasa, H., & Hidayati, S. C. (2023). Segmentation of COVID-19 Chest CT Images Based on SwishUnet. *International Journal of Intelligent Engineering and Systems*, 16(3), 565–578. <https://doi.org/10.22266/ijies2023.0630.45>
- Masoud Nickpakvar. (2021). *Brain Tumor MRI Dataset*. Kaggle. <https://www.kaggle.com/datasets/masoudnickparvar/brain-tumor-mri-dataset>

- Rian, F., Romi, W., & Alief, M. (2020). Sistem Deteksi Otomatis Coronavirus Disease (Covid-19) Menggunakan Gambar Chest Xray Dengan Jetson Nano. *Jurnal Ilmiah Setrum, Vol. 9, No. 2, Pp. 162–168.*
- Sanjaya, J., & Ayub, M. (2020). Augmentasi Data Pengenalan Citra Mobil Menggunakan Pendekatan Random Crop, Rotate, dan Mixup. *Jurnal Teknik Informatika Dan Sistem Informasi, 6(2), 311–323.* <https://doi.org/10.28932/jutisi.v6i2.2688>
- Siyoun Biratu, E., Schwenker, F., Ayano, Y. M., Debelee, T. G., Militello, C., Conti, V., Zaccagna, F., & Han, C. (2021). A Survey of Brain Tumor Segmentation and Classification Algorithms. *Journal of Imaging 2021, Vol. 7, Page 179, 7(9), 179.* <https://doi.org/10.3390/JIMAGING7090179>
- Wulansari, A., & Rahman, A. T. (2022). Analisa gambar citra MRI otak dengan watershed dan ekstraksi fitur GLCM. *JNANALOKA, 39–46.* <https://doi.org/10.36802/JNANALOKA.2022.V3-NO2-39-46>
- Zou, K. H., Warfield, S. K., Bharatha, A., Tempany, C. M. C., Kaus, M. R., Haker, S. J., Wells, W. M., Jolesz, F. A., & Kikinis, R. (2004). Statistical Validation of Image Segmentation Quality Based on a Spatial Overlap Index. *Academic Radiology, 11(2), 178–189.* [https://doi.org/10.1016/S1076-6332\(03\)00671-8](https://doi.org/10.1016/S1076-6332(03)00671-8)