

Klasifikasi Tumor Otak Berbasis Magnetic Resonance Imaging Menggunakan Algoritma Convolutional Neural Network

Fatmah Citra R¹, Fintri Indriyani², Indra Riyana Rahadjeng³

^{1,2,3}Universitas Bina Sarana Informatika, Indonesia

¹citrafatma274@gmail.com, ²fintri.fni@bsi.ac.id, ³riyana.irr@bsi.ac.id



Histori Artikel:

Diajukan: 18 Januari 2024

Disetujui: 23 Januari 2024

Dipublikasi: 27 Januari 2024

Kata Kunci:

Tumor Otak; Klasifikasi; Convolutional Neural Network; Magnetic Resonance Imaging; Alexnet;

Digital Transformation

Technology (Digitech) is an Creative Commons License This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International (CC BY-NC 4.0).

Abstrak

Tumor otak adalah kondisi yang ditandai dengan tumbuhnya sel-sel abnormal dan ganas di dalam otak. Citra digital melalui *Magnetic Resonance Imaging* (MRI) merupakan salah satu metode untuk membantu dokter dalam mengklasifikasikan jenis tumor otak. Namun, klasifikasi secara manual membutuhkan waktu yang lama dan memiliki risiko kesalahan yang besar, untuk itu diperlukan cara otomatis dan akurat dalam melakukan klasifikasi citra MRI. Pada penelitian ini, dirancang suatu sistem berbasis *deep learning*, yaitu *Convolutional Neural network* (CNN) dengan arsitektur *Alexnet*. Jumlah dataset yang digunakan dalam penelitian ini sebanyak 7.022 citra MRI dengan empat kelas yaitu *glioma*, *meningioma*, *pituitary*, dan *no tumor* yang bersumber dari *kaggle.com*. Para peneliti terdahulu telah mendapatkan hasil yang memuaskan di semua sub bidang analisis citra medis, seperti klasifikasi, deteksi, segmentasi, dan peningkatan citra. Dengan keberhasilan ini, para peneliti menemukan sebuah model yang dapat mendiagnosis dan mendeteksi secara otomatis, yang dapat membantu para ahli di bidangnya dan menunjukkan bahwa teknologi *deep learning* akan sangat bermanfaat bagi kemajuan analisis citra medis, hasil penelitian diperoleh akurasi sebesar 0,9642.

PENDAHULUAN

Penyakit tumor otak adalah pertumbuhan sel otak yang tidak normal dan tidak terkendali didalam atau di sekitar otak. Tumor otak terbagi menjadi tumor otak primer dan sekunder. Tumor otak primer adalah perubahan sel yang tidak normal dan tidak terkontrol yang berasal dari sel otak itu sendiri. Sedangkan tumor otak sekunder adalah tumor yang telah menyebar ke otak akibat kanker di tempat lain di tubuh (Mutiarra & Azizah, 2022; Ramadhani et al., 2022). Jumlah kasus tumor otak di dunia semakin meningkat setiap tahunnya. Di Indonesia, 300 pasien didiagnosis tumor otak setiap tahunnya. Tidak hanya orang dewasa, tumor otak juga bisa menyerang anak-anak yang relatif muda. Banyak orang mengabaikan gejala yang ditimbulkan oleh tumor otak (Andre et al., 2021).

Statistik mencatat 1/6 kematian di dunia adalah karena penyakit tumor. Pada tahun 2018, sebanyak 9,6 juta kematian dan 70% terdapat di negara berkembang. Untuk negara Indonesia, kematian karena penyakit tumor berada di posisi setelah ginjal, diabetes, stroke, dan darah tinggi (Hastomo & dan Sudjiran, 2021; Rahayuwati et al., 2020). Terlambatnya penanganan dini adalah faktor utama tingginya kematian, pertolongan yang terlambat dikarenakan pasien datang ke unit medis setelah dalam kondisi stadium tinggi. Para medis mendiagnosa tumor melalui saraf penglihatan, pendengaran, dan tingkat refleksi tubuh (Emril et al., 2020; Retnaningsih, 2021). Untuk mengetahui jenis tumor jinak atau ganas, biasanya dengan proses pengambilan sampling jaringan sel. Peralatan radiologi *Computer Tomography Scanner* (CT scan) dan MRI dapat digunakan untuk diagnosa deteksi tumor otak (Hastomo & dan Sudjiran, 2021).

Tumor pada otak dapat dideteksi melalui pemeriksaan *Magnetic Resonance Imaging* (MRI), setelah pasien menjalani proses pemeriksaan, dokter spesialis radiologi akan menganalisis dan mengambil kesimpulan dari citra yang dihasilkan oleh alat medis tersebut (Akhadi, 2020; Febrianti et al., 2020). Salah satu kelebihan dari menggunakan MRI ini adalah dapat mengamati diferensiasi pada jaringan lunak seperti jaringan "*white matter*" dan "*gray matter*" yang dapat dibedakan oleh citra MRI secara jelas. Dengan mengolah citra yang dihasilkan oleh alat MRI dapat dikembangkan metode pendeteksian tumor otak yang mampu mendeteksi dan mengklasifikasikan jenis tumor otak (Febrianti et al., 2020; Rofiky et al., 2017). Klasifikasi jenis tumor otak sangat penting bagi pasien dalam peningkatan perawatan. Dengan perawatan yang tepat, perencanaan, dan diagnosa yang akurat dapat meningkatkan harapan hidup pasien Tumor Otak (Ilawanda & Atsani, 2021). Dalam beberapa tahun terakhir, klasifikasi menggunakan pemrosesan gambar tradisional telah secara bertahap digantikan oleh *Deep learning*, salah satunya adalah *Convolutional Neural network*. *Convolutional Neural network* (CNN) telah banyak digunakan dalam masalah klasifikasi citra (Winnarto et al., 2022).

Convolutional Neural network (CNN) adalah salah satu jenis *neural network* yang biasa digunakan untuk memproses citra. CNN bisa digunakan untuk mendeteksi dan mengenali objek pada sebuah citra. Secara garis

besar, CNN tidak berbeda jauh dengan *neural network*, CNN terdiri dari neuron yang memiliki *weight*, bias, dan *activation function*. Secara umum, CNN terdiri dari *convolution*, *pooling*, dan *fully connected Layer* (Suta et al., 2019)

STUDI LITERATUR

1. *Magnetic Resonance Imaging* (MRI)

Magnetic Resonance Imaging (MRI) merupakan peralatan radiologi terbaik untuk melakukan diagnosa tumor otak yang rumit dan intensitasnya beragam. Keunggulan MRI antara lain mampu mendapatkan citra beresolusi tinggi dan aman diterapkan pada organ otak karena tidak mengandung radiasi ion. Namun, interpretasi atau pembacaan citra MRI membutuhkan waktu yang lama. Sehingga segmentasi citra perlu dilakukan. Segmentasi citra bertujuan untuk membagi daerah citra tumor dan daerah normal. Kemajuan teknologi menyebabkan kecepatan komputasi bukan lagi fokus utama para peneliti. Namun, hal terpenting adalah berusaha mendapatkan sistem yang mampu melakukan segmentasi dan mendapatkan informasi MRI yang akurat dan selalu meningkat. Tantangan segmentasi citra tumor otak saat ini adalah keakuratan, kemampuan metode yang dapat digunakan kembali, dan penerapan pada sistem cerdas (Diah Priyawati, Indah Soesanti, 2015).

2. *Artificial Intelligence*

Kecerdasan buatan adalah salah satu cabang ilmu komputer yang memiliki kapabilitas, antara lain mesin pintar (*smart machine*) untuk memecahkan persoalan yang rumit dengan cara yang lebih tepat dan dapat diarahkan oleh keperluan manusia (Dr. Ir. Manerep Pasaribu, 2022). *Artificial Intelligence* (AI) merujuk kepada rangkaian algoritma yang kemudian dikembangkan agar komputer memiliki kemampuan yang menyerupai dengan kemampuan manusia. *Intelligence* atau kecerdasan yang disematkan kedalam sebuah mesin dapat diklasifikasikan ke dalam beberapa tipe, misalnya:

- a. *Reasoning*: kemampuan menginterpretasi atau justifikasi solusi
- b. *Planning*: kemampuan menemukan cara untuk memecahkan masalah
- c. *Thinking*: kemampuan melakukan simulasi sebagai bagian dari pemecahan masalah
- d. *Language*: kemampuan memahami bahasa dalam alam manusia
- e. *Learning*: kemampuan menentukan cara yang lebih baik dalam memecahkan masalah.

3. *Machine learning*

Machine learning adalah pembelajaran yang memberi komputer perintah untuk belajar dari data tanpa dilakukan sesuatu hal terperinci untuk harus mengikuti instruksi yang dideprogram. Tujuan dari *Machine learning* adalah untuk melatih mesin berdasarkan data dan algoritma yang diberikan. Menggunakan data dan informasi yang diproses, mesin belajar bagaimana membuat keputusan. ML bersifat dinamis, yang artinya memiliki kemampuan untuk mengubah dirinya sendiri saat diterapkan ke data yang lebih banyak (Andre et al., 2021).

4. *Deep learning*


Deep learning atau *deep structured learning/hierarchical learning* adalah bagian dari kecerdasan buatan dan *machine learning*, yang merupakan pengembangan dari *neural network multiple Layer* untuk memberikan ketepatan tugas. Contohnya seperti deteksi objek, pengenalan suara, terjemahan bahasa, dan lain sebagainya. Meski menjadi subbidang dari *machine learning*, *deep learning* ternyata memiliki teknik yang berbeda. Karena *deep learning* secara otomatis melakukan representasi dari data, seperti gambar, video, hingga teks tanpa memperkenalkan aturan kode atau pengetahuan domain manusia (Ari, 2022). *Deep learning* merupakan bagian dari *Machine learning* yang melakukan pembelajaran secara hirarki. Metode ini merupakan pengembangan dari *artificial neural network* pada *machine learning*. *Deep learning* melakukan pembelajaran yang terdiri dari banyak *Layer*. *Layer* awal menghasilkan fitur – fitur lebih kompleks (Setiawan, 2021).

5. *Convolutional Neural network* (CNN)

Convolutional Neural network (CNN) adalah variasi dari *MultiLayer Perception* yang terinspirasi oleh jaringan saraf manusia berdasarkan temuan Hubel dan Wiesel yang melakukan penelitian korteks visual pada indera penglihatan kucing. Studi ini sangat terinspirasi dengan cara kerja korteks visual pada hewan yang sangat kuat dalam sistem pemrosesan visual (Anton et al., 2021). CNN adalah multi-*Layer* perceptron yang merupakan salah satu varian dari *deep neural network* yang sering digunakan sebagai metode untuk mengklasifikasikan data citra digital. Saat ini, CNN banyak diaplikasikan ke dalam berbagai bidang kehidupan, di antaranya untuk rekomendasi sistem, analisis gambar medis, pemrosesan bahasa alami, analisis financial time series (Sayuti, 2021)

Convolutional Neural network (CNN) adalah metode *deep learning* yang banyak digunakan dalam computer vision, seperti klasifikasi, deteksi, dan segmentasi. CNN belajar mengekstrak fitur dari citra dengan mengulang pembelajaran dan kemudian menghasilkan *feature map*. Struktur CNN berisi lapisan input, lapisan tersembunyi, dan lapisan output. Jenis CNN yang umum digunakan mirip dengan *Multilayer Perceptron* (MLP) yang mencakup beberapa *Convolutional Layer*, *Pooling Layer*, dan terakhir merupakan *Fully Connected Layer*.

Arsitektur CNN memiliki dua bagian utama yaitu *Feature learning* dan *Classification* seperti terlihat pada gambar berikut.



Gambar 1. Struktur CNN

Feature learning terdiri dari lapisan konvolusi, fungsi aktivasi seperti ReLU (*Rectified Linear Unit*), dan *Pooling*. Lapisan ini sering diulang atau disusun menjadi beberapa lapisan sesuai kebutuhan arsitektur yang dibuat. Bagian klasifikasi terdiri dari *Flatten*, *Fully Connected*, dan *Softmax* (Sayuti, 2021). Adapun arsitektur yang dimiliki oleh *Convolutional Neural network* sebagai berikut:

a. *Convolutional Layer*

Convolution Layer melakukan operasi konvolusi pada output dari *Layer* sebelumnya (*input Layer*). *Layer* ini adalah proses utama yang mendasari sebuah CNN. Konvolusi adalah suatu istilah matematis yang berarti mengaplikasikan sebuah fungsi pada output fungsi lain secara berulang. Dalam pengolahan citra, konvolusi berarti mengaplikasikan sebuah kernel pada citra disemua offset yang memungkinkan.

b. *Pooling Layer*

Pooling Layer adalah proses mereduksi input secara spasial atau mengurangi jumlah parameter dengan operasi down sampling. Dimensi dari setiap feature map akan berkurang tetapi menyimpan informasi yang paling penting. *Pooling Layer* memiliki fungsi untuk mempercepat operasi dan meningkatkan kinerja seluruh *convolutional Layer*. Terdapat dua metode dalam *Pooling Layer*, yaitu *max pooling* dan *average pooling*.

c. *Fully Connected Layer*

Lapisan yang terhubung sepenuhnya adalah struktur dasar dari jaringan saraf, dimana semua neuron terhubung. Lapisan ini biasanya diimplementasikan pada akhir jaringan. Lapisan ini menggunakan fungsi aktivasi softmax pada lapisan output untuk klasifikasi. Fungsi aktivasi softmax memecahkan masalah Pembelajaran Jaringan Saraf Multikelas dan Klasifikasi Gambar. Satu set piksel diambil sebagai input. Output dari softmax dapat mewakili distribusi kelas. Menghitung semua probabilitas label yang mengambil nilai antara 0 dan 1, jika dijumlahkan semuanya adalah nilai 1. Lapisan ini merangkum semua fitur yang telah diekstrak atau internal ke lapisan ekstraksi fitur-fitur proses pembelajaran. Perbandingan antara lapisan yang terhubung sepenuhnya dan lapisan ekstraksi fitur adalah neuron pada lapisan ekstraksi fitur hanya terhubung ke wilayah input tertentu. Sementara secara penuh lapisan terhubung berisi semua neuron yang terhubung (Gunawan & Setiawan, 2022)

6. *Confusion matrix*


Confusion matrix adalah ukuran kinerja untuk masalah klasifikasi pembelajaran mesin yang dapat menghasilkan dua kelas atau lebih. Matriks konfusi adalah tabel yang berisi 4 kombinasi berbeda dari nilai prediksi dan nilai sebenarnya. Beberapa istilah yang digunakan untuk mencari nilai akurat adalah *true positive (TP)*, *true negative (TN)*, *false positive (FP)*, dan *false negative* (Wulandari et al., 2020).

		Actual Values	
		Positive (1)	Negative (0)
Predicted Values	Positive (1)	TP	FP
	Negative (0)	FN	TN

Gambar 2. *Confusion Matrix*

METODE

Untuk mendapatkan model yang tepat agar bisa mengklasifikasikan gambar tumor otak (meningioma, glioma, pituitary, dan tumor), dibutuhkan data dengan tahapan preprocessing yang tepat serta hyperparameter model CNN yang tepat, sehingga hasil evaluasi yang diperoleh memuaskan. Semua tahapan yang dilakukan sesuai dengan alur penelitian yang dapat dilihat di bawah ini:



Gambar 3. Alur Penelitian

Skenario Pengujian Pengujian terdiri dari enam skenario untuk mengetahui parameter optimal dalam sistem klasifikasi tumor otak. Skenario tersebut mencakup uji ukuran gambar yang optimal, uji rasio data latih, data validasi, dan data uji untuk mendapatkan rasio terbaik. Selain itu, terdapat skenario optimasi uji untuk menentukan pengoptimal yang dapat mencapai kinerja sistem yang optimal, skenario pengujian *learning rate*, skenario pengujian *batch size*, dan skenario pengujian *epoch* untuk mendapatkan performa terbaik.

Pengukuran Kinerja Pada tahap ini, dilakukan pengujian kinerja sistem untuk menentukan seberapa efektif sistem ini dalam klasifikasi citra kelas yang diinginkan, yaitu *glioma*, *meningioma*, *pituitary*, dan tumor. Kinerja sistem dapat terlihat dengan menganalisis nilai akurasi, *loss*, *presisi*, *recall*, dan *F1 score*. Selain itu, terdapat juga *Confusion matrix* yang terdiri dari nilai aktual dan nilai prediksi, dimana nilai ini bisa membantu menunjukkan kemampuan klasifikasi kedalam sistem kelas yang sesuai.

	Prediksi				
	Kelas	<i>Glioma</i>	<i>Meningioma</i>	<i>Pituitary</i>	<i>No tumor</i>
Aktual	<i>Glioma</i>	C_1	C_2	C_3	C_4
	<i>Meningioma</i>	C_5	C_6	C_7	C_8
	<i>Pituitary</i>	C_9	C_{10}	C_{11}	C_{12}
	<i>No tumor</i>	C_{13}	C_{14}	C_{15}	C_{16}

Gambar 4. Confusion Matrix

TP adalah data aktual yang dapat diprediksi dengan benar. Misalnya, pada glioma, nilai ini adalah nilai TP. TN adalah jumlah dari semua nilai dalam matriks, tidak melibatkan nilai kolom dan baris kelas yang dihitung. Misalnya, nilai penjumlahan adalah nilai TN untuk kategori glioma. FP adalah jumlah nilai kolom di kelas yang dihitung, nilai TP tidak terlibat. Misalnya, nilai adalah nilai FP untuk kelas glioma. FN adalah jumlah dari nilai baris di kelas yang dihitung, nilai TP tidak terlibat. Misalnya, ++ adalah nilai FN untuk kelas glioma. Setelah dicari nilai tersebut, hasil tersebut dapat digunakan untuk menghitung nilai akurasi, presisi, recall, skor F1, dan loss.

1. Akurasi

Akurasi merupakan rasio pengukuran nilai prediksi yang sebenarnya. Rumusan akurasi dapat dituliskan kedalam persamaan berikut:

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

2. Presisi

Presisi merupakan perbandingan antara nilai yang berhasil di prediksi dengan benar terhadap seluruh nilai yang diprediksi oleh sistem. Secara sistematis dituliskan kedalam persamaan berikut:

$$\frac{TP}{TP + FP}$$

3. Recall

Recall merupakan perbandingan antara nilai yang berhasil diprediksi benar oleh sistem terhadap seluruh nilai aktualnya. Secara sistematis dapat dituliskan dalam persamaan sebagai berikut:

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

4. F1 Score

F1 Score merupakan perbandingan rata-rata hasil prediksi dan recall yang telah didapatkan. Secara sistematis dapat dituliskan dalam persamaan berikut:

$$2x = \frac{(precision \times recall)}{(precision + recall)}$$

5. Loss

Loss function digunakan untuk menghitung error antara nilai yang diprediksi dengan nilai aktualnya. Penelitian ini menggunakan crossentropy loss function yang umumnya digunakan untuk multiclass. Secara sistematis disajikan dalam persamaan berikut:

$$H(P,Q) = -\sum P(x) \cdot \log(Q(x))$$

H = fungsi crossentropy

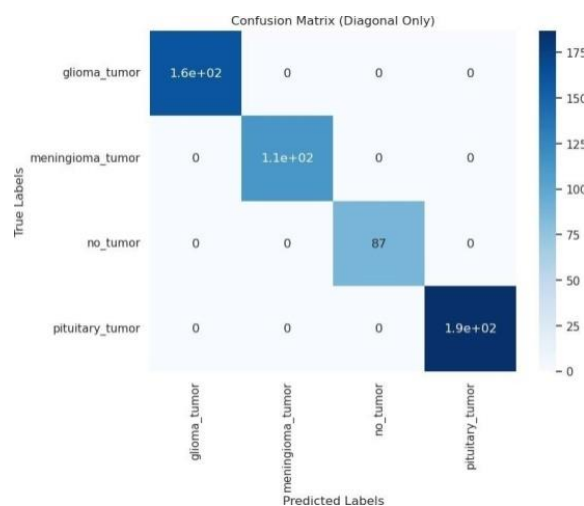
P = distribusi target

Q = perkiraan distribusi target

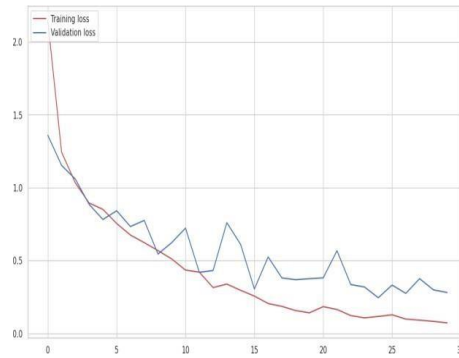
HASIL

Evaluasi ini merupakan analisis hasil penelitian terhadap model CNN yang digunakan dalam eksperimen. Evaluasi hasil tersebut menggunakan matriks akurasi, recall, dan presisi. Setelah melatih model, kami melihat pertumbuhan nilai loss pada data uji sejak awal pelatihan hingga akhir pelatihan. Hal ini dilakukan untuk mengetahui kapan model mulai mengalami overfitting dan kapan model mencapai nilai loss minimum pada data uji. Model CNN dengan nilai loss minimum pada data uji akan dipilih, kemudian dievaluasi untuk melihat performa masing-masing model dalam memprediksi setiap data.

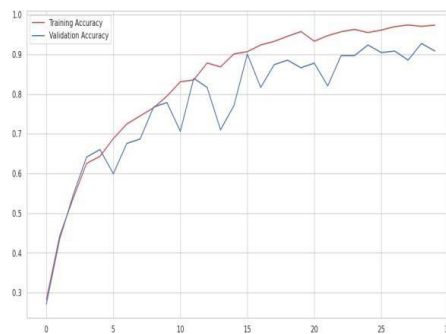
Setelah melatih model dengan data latih, akan dihasilkan model yang siap dievaluasi. Evaluasi dilakukan dengan menganalisis matriks klasifikasi yang mencakup presisi dan recall setiap kelas, serta akurasi dari model.



Gambar 5. Confusion Matrix



Gambar 6. Model Accuracy



Gambar 7. Model Loss

Pada gambar tersebut, hasil akhir model CNN (*Convolutional Neural network*) memperoleh akurasi sebesar 95%, presisi 86%, recall 90%, dan F1-score 88%.

PEMBAHASAN

Hasil penelitian menunjukkan hasil evaluasi performa model *Convolutional Neural network* (CNN) dalam melakukan klasifikasi menggunakan data citra. Tingkat akurasi mencerminkan seberapa banyak prediksi yang benar dibandingkan dengan total jumlah sampel, akurasi model CNN mencapai 95%, artinya model berhasil memprediksi kategori klasifikasi dengan benar pada sebagian besar data. Selanjutnya, presisi mengukur sejauh mana prediksi positif yang dibuat oleh model adalah benar. Hasil penelitian menunjukkan, presisi sebesar 86% menunjukkan bahwa dari semua prediksi yang diberikan oleh model sebagai positif, 86% di antaranya benar-benar positif.

Selanjutnya, recall mengukur sejauh mana model mampu mendeteksi semua instance yang sebenarnya positif. Dengan recall sebesar 90%, model mampu menangkap sebagian besar kasus positif yang sebenarnya. Terakhir F1-score adalah metrik gabungan antara presisi dan recall. Dalam hal ini, F1-score sebesar 88% mencerminkan keseimbangan antara kemampuan model untuk memberikan prediksi positif yang benar dan kemampuannya mendeteksi semua kasus positif yang sebenarnya. Hasil akhir tersebut mengindikasikan bahwa model CNN yang dikembangkan memiliki performa yang baik dalam klasifikasi tumor otak, dengan tingkat akurasi yang tinggi dan keseimbangan antara presisi dan recall. Hal ini menunjukkan potensi model untuk digunakan dalam membantu diagnosis dan klasifikasi jenis tumor otak berdasarkan citra MRI.

KESIMPULAN

Hasil penelitian ini mengungkapkan bahwa penggunaan algoritma *Convolutional Neural network* (CNN) dalam klasifikasi tumor otak berbasis MRI memberikan peningkatan performa yang signifikan. Dengan akurasi mencapai 95%, presisi sebesar 86%, recall 90%, dan F1-score 88%, hasil ini menunjukkan efektivitas metode ini dalam mengidentifikasi dan mengklasifikasikan jenis tumor otak. Dengan menggunakan teknologi MRI, penelitian ini mencoba mengatasi keterbatasan diagnosis konvensional dengan memberikan solusi yang lebih akurat dan efisien. Jurnal referensi utama, "brain-tumor-classification-mri," telah memberikan kontribusi dengan mencapai akurasi sebesar 0.9068. Namun, penelitian ini berhasil melampaui hasil tersebut dengan mencapai akurasi 95%. Hal ini menunjukkan kemajuan yang signifikan dalam pengembangan model klasifikasi tumor otak. Lebih lanjut, hasil penelitian ini menekankan pentingnya penerapan teknologi modern, seperti *Convolutional Neural network*, dalam domain medis. Kemampuan CNN untuk memproses citra secara mendalam dan mengenali pola kompleks memberikan harapan baru dalam meningkatkan diagnosis dan perawatan tumor otak. Dengan

adanya metode klasifikasi yang lebih canggih, diharapkan dapat meningkatkan tingkat deteksi dini, mempercepat proses diagnosis, dan pada akhirnya meningkatkan prognosis pasien. Hal ini berpotensi memberikan dampak positif dalam upaya pencegahan dan penanganan penyakit tumor otak yang semakin mendesak untuk diperhatikan dalam dunia kesehatan.

REFERENSI

- Akhadi, M. (2020). *Sinar-X Menjawab Masalah Kesehatan*. Deepublish.
- Andre, R., Wahyu, B., & Purbaningtyas, R. (2021). *Klasifikasi Tumor Otak Menggunakan Convolutional Neural Network Dengan Arsitektur Efficientnet-B3* (Vol. 11, Issue 3).
- Anton, A., Nissa, N. F., Janiati, A., Cahya, N., & Astuti, P. (2021). Application of Deep Learning Using Convolutional Neural Network (CNN) Method For Women's Skin Classification. *Scientific Journal of Informatics*, 8(1), 144–153. <https://doi.org/10.15294/sji.v8i1.26888>
- Ari, A. (2022). Deep Learning. *Universitas STEKOM*.
- Diah Priyawati, Indah Soesanti, I. H. (2015). *Kajian Pustaka Metode Segmentasi Citra Pada Mri Tumor Otak*. 207–215.
- Dr. Ir. Manerep Pasaribu, M. . (2022). *Artificial Intelligence*. keputakaan populer gramedia.
- Emril, D. R., Fajri, N., & Rahayu, N. S. (2020). The New Concept of Cancer Pain Management: Should We Modify the WHO's Step Ladder? *The Challenges Of Neurological Development In 4.0 Generation Of Industrial Revolutionary Era*, 296.
- Febrianti, A. S., Sardjono, T. A., & Babgei, A. F. (2020). Klasifikasi Tumor Otak pada Citra Magnetic Resonance Image dengan Menggunakan Metode Support Vector Machine. *Jurnal Teknik ITS (SINTA: 4, IF: 1.1815)*, 9(1), A118–A123.
- Gunawan, & Setiawan. (2022). *Convolutional Neural Network dalam Analisis Citra Medis* (Vol. 2, Issue 2).
- Hastomo, W., & dan Sudjiran, S. (2021). Convolution Neural Network Arsitektur Mobilenet-V2 Untuk Mendeteksi Tumor Otak. *Seminar Nasional Teknologi Informasi Dan Komunikasi STI&K (SeNTIK)*, 5(1), 17–21.
- Ilawanda, Z. M., & Atsani, G. F. (2021). Gambaran Radiologis pada Bidang Neurologis Tumor Otak. *Jurnal Fusion*, 1(12), 987–1001.
- Mutiara, T. A., & Azizah, Q. N. (2022). Klasifikasi Tumor Otak Menggunakan Ekstraksi Fitur HOG dan Support Vector Machine. *Jurnal Infortech*, 4(1), 45–50.
- Rahayuwati, L., Rizal, I. A., Pahria, T., Lukman, M., & Juniarti, N. (2020). Pendidikan kesehatan tentang pencegahan penyakit kanker dan menjaga kualitas kesehatan. *Media Karya Kesehatan*, 3(1).
- Ramadhani, R. A., Pangestu, B. W., & Purbaningtyas, R. (2022). Klasifikasi Tumor Otak Menggunakan Convolutional Neural Network dengan Arsitektur EfficientNet-B3. *JUST IT: Jurnal Sistem Informasi, Teknologi Informasi Dan Komputer*, 12(3), 55–59.
- Retnaningsih, D. (2021). *Keperawatan Paliatif*. Penerbit NEM.
- Rofiky, A., Rahardjo, P., & Soeharmanto, D. (2017). Comparison of number of diffusion gradient direction in brain imaging diffusion tensor; case study of tumor brain. *Journal of Vocational Health Studies*, 1(1), 15–17.
- Sayuti, R. (2021). *Convolutional Neural Networks Untuk Visi Komputer* (1st ed.). deepublish.
- Setiawan, W. (2021). *DEEP LEARNING menggunakan Convolutional Neural Network* (cetakan 1). Media Nusa Creative.
- Suta, I. B. L. M., Hartati, R. S., & Divayana, Y. (2019). Diagnosa Tumor Otak Berdasarkan Citra MRI (Magnetic Resonance Imaging). *Majalah Ilmiah Teknologi Elektro*, 18(2). <https://doi.org/10.24843/mite.2019.v18i02.p01>
- Winnarto, M. N., Mailasari, M., & Purnamawati, A. (2022). Klasifikasi Jenis Tumor Otak Menggunakan Arsitektur Mobilenet V2. *Jurnal SIMETRIS*, 13(2).