



Perbandingan Model Klasifikasi *Transfer Learning Convolutional Neural Network* Tumor Otak Menggunakan Citra *Magnetic Resonance Imaging*

Noval Pratama^{1*}, Muhaza Liebenlito², Yanne Irene³

Fakultas Sains dan Teknologi, UIN Syarif Hidayatullah Jakarta^{1,2,3}

Email: noval.pratama18@mhs.uinjkt.ac.id¹, muhazaliebenlito@uinjkt.ac.id²,
yanne.irene@uinjkt.ac.id³

ABSTRAK

Kata Kunci: Analisis Tumor Otak; Klasifikasi; CNN; Transfer Learning; Pemrosesan Citra Medis.

Analisis tumor otak menjadi subjek penting dalam kedokteran, di mana deteksi yang cepat dan akurat dapat mengarah pada perawatan yang lebih baik. Tujuan penelitian ini adalah untuk membandingkan dan mengevaluasi kinerja delapan model arsitektur jaringan pre-built yang telah dibangun sebelumnya dalam mengklasifikasikan tumor MRI menggunakan metodologi pembelajaran transfer learning. Pada penelitian ini dataset yang digunakan merupakan citra *Magnetic Resonance Imaging* (MRI) sebanyak 3.264 yang terdiri dari meningioma, glioma, *pituitary* dan yang tidak menderita tumor otak. Pada penelitian ini, peneliti menggunakan arsitektur jaringan yang telah dilatih sebelumnya pada kumpulan data besar untuk tugas klasifikasi umum. Pendekatan pembelajaran transfer ini memungkinkan kita untuk memanfaatkan fitur tingkat tinggi yang telah dipelajari oleh model dalam dataset umum dan menyesuaikannya dengan dataset spesifik tumor otak yang lebih kecil. Hasil eksperimen menunjukkan bahwa pendekatan transfer learning ini berhasil mengklasifikasikan jenis tumor otak dengan akurasi yang memuaskan, bahkan dengan dataset yang terbatas. Teknik ini menjanjikan untuk meningkatkan diagnosis dini dan manajemen tumor otak dalam praktik klinis dengan memanfaatkan kekuatan model yang ada tanpa perlu melatih model dari awal.

Corresponden Author: Noval Pratama

Email: noval.pratama18@mhs.uinjkt.ac.id

Artikel dengan akses terbuka dibawah lisensi



Pendahuluan

Tumor adalah sebutan untuk neoplasma atau lesi padat yang terbentuk akibat pertumbuhan sel tubuh yang tidak seharusnya yang mirip dengan simtom bengkak (Örgüç & Arkun, 2020). Tumor dapat terbentuk dan berkembang di beberapa organ tubuh manusia, salah satunya otak (Lah, Novak, & Breznik, 2020). Menurut sebuah data epidemiologi berdasarkan systematic review, insidensi tumor otak di dunia terjadi sebanyak 10,82 per 100.000 penduduk setiap tahun. Sedangkan rentangnya berkisar antara 0,01 sampai 25,95 per 100.000 penduduk setiap tahun (Evani, 2023). Tumor primer sendiri adalah tumor yang tumbuh atau terbentuk dengan sendirinya (Ningsi,

Mukarramah, & Cahyanti, 2021). Sedangkan tumor sekunder adalah tumor yang terbentuk dari metastasis atau penyebaran sel kanker dari organ lainnya. Tumor otak primer yang paling banyak ditemukan adalah glioma, *American Association of Neurological* menyebutkan bahwa sekitar 78% dari total kasus tumor otak ganas tergolong sebagai Glioma. Berdasarkan data statistik *Central Brain Tumor Registry of the United States* (CBTRUS), meningioma merupakan tumor otak paling banyak terdiagnosis secara histologi yaitu 36,8%, yang kemudian diikuti oleh tumor *pituitary* sebanyak 16,2%. Ketiga tumor tersebut memiliki tempat yang berbeda-beda pada otak manusia. *Adenoma pituitary* atau Tumor otak *pituitary* adalah jenis tumor otak yang tumbuh pada kelenjar *pituitary*, yaitu kelenjar yang mengontrol berbagai fungsi tubuh serta melepaskan hormone kedalam aliran darah (Malik et al., 2022). Sedangkan meningioma adalah jenis tumor otak yang terjadi di meninges, yaitu lapisan jaringan yang mengelilingi bagian luar otak dan sumsum tulang belakang (Teoh, 2022). Tumor otak glioma yang terjadi di sel-sel glial pada otak (Yudha, 2022).

Selain gejala-gejala yang ditimbulkan, untuk mengetahui lebih pasti terkait keberadaan sel tumor, maka pasien disarankan untuk melakukan CT Scan. Dapat mengetahui jenis – jenis tumor tersebut berdasarkan tempat terbentuknya neoplasma yang tak wajar tersebut. Berdasarkan penjelasan tersebut, maka perlu digunakan suatu metode untuk membagi ketiga jenis tumor otak yang telah kami sebutkan sebelumnya. Menggunakan *Convolution Neural Networks* (CNN) saat ini merupakan pilihan terbaik dalam aplikasi pencitraan medis contohnya dalam mengklasifikasi jenis tumor otak (Haq, 2022; Harani & Hasanah, 2020). Meskipun CNN mencapai hasil terbaik pada kumpulan data yang besar, tapi CNN membutuhkan banyak data dan sumber daya komputasi untuk dilatih. Dalam beberapa kasus, kumpulan data terbatas dan mungkin tidak cukup untuk melatih CNN dari awal. Dalam skenario seperti itu, untuk memanfaatkan kekuatan CNN dan pada saat yang sama mengurangi sumber daya komputasi, transfer learning dapat digunakan (Yudha, 2022). Salah satu arsitektur neural yang terbaik yaitu arsitektur VGG-16. VGG-16 merupakan model CNN yang dikemukakan oleh K. Simonyan dan A.Zisserman dari Universitas Oxford dalam penulisan yang berjudul “*Very Deep Convolutional Networks for large-scale Image Recognition*”. Model tersebut berhasil mencapai 92,7% dan merupakan 5 besar akurasi tes pada dataset ImageNet (Rizki & Marina, 2020). Ada beberapa jaringan saraf terlatih lainnya yang telah dipilih para peneliti untuk membandingkan tingkat akurasinya, seperti EfficientNetB0, DenseNet169, dan ResNet50.

Penelitian sebelumnya oleh (Harahap, Nafisa, Purba, & Putri, 2023) menyatakan bahwa melalui eksperimen dengan 4 cross-validation dan 30 epoch, MobileNetV2 menghasilkan rata-rata akurasi sebesar 86.46%, mampu mengklasifikasikan penyakit otak *pituitary* dengan sempurna, tetapi belum sepenuhnya efektif dalam mengklasifikasikan penyakit otak glioma, sering kali mendeteksinya sebagai meningioma. Penelitian oleh (Winnarto, Mailasari, & Purnamawati, 2022) yang menerapkan metode Convolutional Neural Network (CNN) untuk mengidentifikasi jenis citra tumor otak, mencapai tingkat akurasi sebesar 99.7% dan nilai F1-Score tertinggi mencapai 99.6%. Penelitian lain oleh (Nafiyah, 2023) fokus pada klasifikasi tumor otak menggunakan metode CNN dengan arsitektur MobileNetV2. Penelitian ini melibatkan

3167 citra MRI tumor otak dari empat kelas yang berbeda: Glioma Tumor, Meningioma Tumor, No Tumor, dan Pituitary Tumor. Model dilatih dengan adam optimizer, batch size 32, dan 30 epoch, dengan hasil pengujian mencapai akurasi sebesar 88.64%, precision 90%, dan recall 89%. Di samping itu, terdapat penelitian lain oleh (Hanin, Patmasari, & Fuâ, 2021) yang memfokuskan pada klasifikasi penyakit kulit dengan menerapkan metode *Convolutional Neural Network*. Penelitian ini mengembangkan sistem untuk mengidentifikasi penyakit kulit seperti cacar air, scabies, campak, dan jerawat, dan berhasil mencapai tingkat akurasi sebesar 96.53%.

Penelitian sebelumnya mengarah pada pemilihan arsitektur neural untuk transfer learning, dengan VGG-16 dianggap sebagai pilihan terbaik berdasarkan akurasi pada dataset *ImageNet*, dan alternatif lain seperti *EfficientNetB0*, *DenseNet169*, dan *ResNet50*. Sebaliknya, penelitian terkini lebih terfokus pada evaluasi kinerja VGG16 dan DenseNet169 dalam mengklasifikasikan citra MRI tumor otak manusia dengan metode transfer learning. Dari hasil penelitian, *DenseNet169* terbukti unggul dengan akurasi 98%, sedangkan VGG16 mencapai 75%. Analisis kinerja melibatkan *precision*, *recall*, dan *f1-score*, di mana *DenseNet169* secara konsisten menunjukkan hasil lebih tinggi. Keseluruhan, penelitian ini membawa kebaruan dengan meningkatkan akurasi diagnostik dan klasifikasi pada kasus tumor otak, yang dapat mempercepat pengobatan dan meningkatkan peluang kesembuhan. Hal ini berfungsi sebagai dasar untuk penelitian lebih lanjut guna mengembangkan model yang lebih canggih atau aplikasi praktis dalam sistem layanan kesehatan.

Penelitian ini berdampak positif terhadap sektor kesehatan, karena tumor otak merupakan kanker yang serius dan mematikan. Pendekatan menggunakan CNN dan transfer learning dalam mengklasifikasikan tumor otak melalui citra MRI merupakan terobosan baru, dimana pada riset ini membandingkan model CNN yang berbeda dalam konteks transfer learning, mengidentifikasi model yang paling efektif untuk tugas klasifikasi tumor otak.

Tujuan penelitian ini adalah untuk membandingkan dan mengevaluasi kinerja delapan model arsitektur jaringan *pre-built* yang telah dibangun sebelumnya dalam mengklasifikasikan tumor MRI menggunakan metodologi pembelajaran *transfer learning*. Penelitian ini bertujuan untuk memberikan wawasan tentang cara kerja masing-masing arsitek dengan menggunakan matriks konfusi dan pengukuran seperti recall, akurasi, presisi, dan f1-score. Selanjutnya, penelitian ini juga berfokus pada optimasi klasifikasi untuk menemukan arsitektur jaringan optimal dengan karyawan yang berkinerja terbaik dan mengidentifikasi faktor-faktor yang mempengaruhi kinerja tersebut.


Pengembangan dataset citra MRI tumor otak yang lebih luas dan beragam diperlukan untuk meningkatkan generalisasi model, serta mempertimbangkan subtype tumor otak yang kurang terwakili. *Deep Learning*, khususnya CNN sering dianggap sebagai “*Black Box*” karena sulit untuk diinterpretasi atau dimengerti secara intuitif oleh manusia, penelitian lebih lanjut dapat mencoba memperbaiki interpretabilitas model untuk memahami bagaimana model memutuskan klasifikasi, terutama pada bidang medis yang memerlukan keputusan yang jelas. Penelitian dapat diperluas dengan eksplorasi model yang lebih baru atau kompleks, membandingkan berbagai algoritma transfer

learning untuk meningkatkan pemahaman tentang pendekatan yang paling efektif. Studi lebih lanjut diperlukan untuk menguji keberlanjutan model terhadap variasi data dan sejauh mana model dapat digeneralisasi.

Metode Penelitian

Tahapan Pre-processing

Pada penelitian ini dataset yang digunakan merupakan citra *Magnetic Resonance Imaging* (MRI) sebanyak 3.264 yang terdiri dari meningioma, glioma, *pituitary* dan yang tidak menderita tumor otak. Data dapat diakses pada *Brain Tumor Classification*. Dataset yang telah diambil akan di labeli selanjutnya sebelum data dibagi menjadi data training dan testing peneliti melakukan *resize* pada data menjadi 150* 150 setelah itu dataset akan dibagi menjadi data training sebesar 90% dan data testing sebesar 10%. Dataset dari tipe *Multiclass Classification* memiliki satu atribut kelas yang terdiri dari banyak nilai.



Gambar 1. Sampel Gambar Dengan Masing-Masing Labelnya

Convolutional Neural Network (CNN/ConvNet)

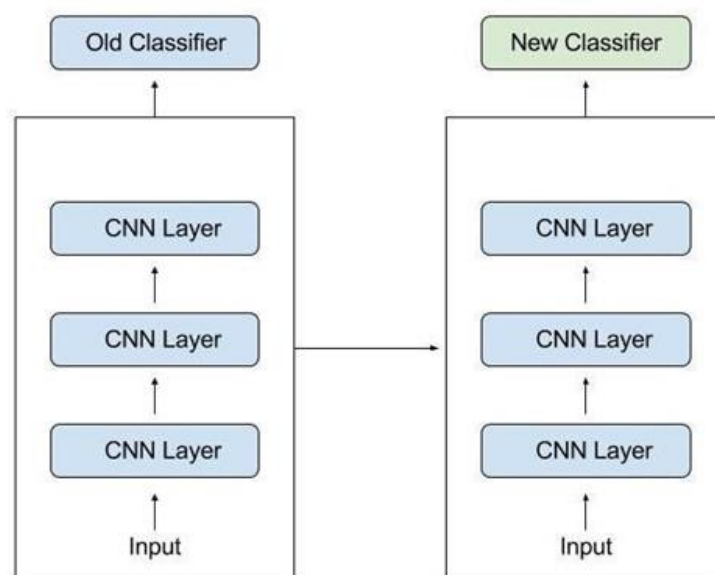
Convolutional Neural Network (CNN/ConvNet) adalah algoritma dari *deep learning* yang biasa digunakan pada data dua dimensi seperti gambar, *ConvNet* digunakan untuk mendeteksi dan mengenali objek pada sebuah gambar menggunakan metode *supervised learning*. *Convolutional Neural Network* memiliki cara kerja sel-sel saraf pada manusia, pada algoritma *ConvNet* memiliki tiga susunan neuron yaitu *width*, *height*, dan *depth*. Beberapa komponen utama pada *ConvNet* yaitu *Convolution Layer*, *Pooling Layer*, dan *Fully Connected*. *Convolution Layer* merupakan tempat dilakukannya operasi konvolusi antara matriks citra input dengan matriks-matriks filter. Setelah dilakukan proses konvolusi, selanjutnya lakukan aktivasi fungsi aktivasi menggunakan fungsi *Rectified Linear Unit (ReLU)*. *Pooling Layer* dilakukan untuk memperkecil ukuran *feature map*.

Jenis pooling yang digunakan yaitu *max pooling*, yang memilih nilai maksimum untuk jendela tertentu. Proses ini mirip dengan *convolution layer* yang digunakan untuk memindahkan jendela melintasi area gambar, tetapi di sini kita menggunakan jendela sebagai referensi untuk memilih nilai maksimum untuk rentang tertentu. Proses ini menghasilkan output berupa matriks *feature map* yang berisi maksimum yang dipilih. *Fully Connected layer* terbagi menjadi tiga bagian yaitu *input layer*, *hidden layer* dan *output layer*. *Input Layer* berguna untuk menggabungkan seluruh matriks *feature map* dari proses *pooling layer* lalu semua piksel tersebut direntangkan menjadi sebuah vektor sepanjang jumlah piksel dari matriks yang didapat pada *pooling layer*. Kemudian seluruh nilai pada input layer digunakan untuk perhitungan pada *hidden layer*. Perhitungan pada layer ini yaitu mengalikan nilai-nilai yang ada di input layer dengan bobot yang sudah

diinisialisasi sebelumnya lalu ditambahkan dengan nilai bias. Kemudian akan didapatkan nilai *output* Z jika fungsi aktivasi ReLU dimasukkan untuk semua hasil perhitungan. Hasil perhitungan ini digunakan dalam proses perhitungan pada *output layer*. *Output layer* akan mengalikan nilai yang dihitung di *hidden layer* dengan bobot yang diinisialisasi sebelumnya, dan kemudian menambahkan nilai bias.

Transfer Learning

Transfer learning adalah teknik atau metode yang memecahkan masalah serupa lainnya dengan menggunakan model yang dilatih pada dan dari kumpulan data dan mengubah serta memperbarui parameter agar sesuai dengan kumpulan data baru (Ghazi, Yanikoglu, & Aptoula, 2017). Oleh karena itu, karena pemahaman layers sebelumnya mengenali objek, peneliti akan melatih kembali lapisan terakhir sehingga peneliti dapat mempelajari perbedaannya dengan kacamata objek lain dan cara kerja *transfer learning*, seperti yang ditunjukkan di bawah ini.



Gambar 2. Transfer Learning

Pada penelitian ini terdapat dua arsitektur jaringan saraf yaitu VGG16 dan DenseNet169 telah digunakan untuk tugas pembelajaran mendalam dan pembelajaran transfer.

VGG16

VGG16 adalah arsitektur model VGG yang paling umum digunakan. VGG16 adalah model CNN yang menggunakan lapisan *convolutional* dengan spesifikasi *filter convolutional* kecil (3×3). Ukuran filter konvolusi memungkinkan kita untuk meningkatkan kedalaman jaringan saraf dengan meningkatkan lapisan konvolusi.

DenseNet169

DenseNet169 dimaksudkan untuk menghubungkan semua lapisan ke semua lapisan lain dalam jaringan secara *feedforward*. Oleh karena itu, untuk setiap lapisan, *feature map* dari setiap lapisan sebelumnya digunakan sebagai input ke lapisan berikutnya. Densenet mempunyai beberapa keunggulan antara lain mengurangi jumlah parameter, meningkatkan distribusi fitur, meningkatkan pengambilan fitur, dan mengurangi masalah gradien. DenseNet mudah untuk dilatih karena setiap lapisan

memiliki akses langsung ke gradien lapisan input melalui fungsi kerugiannya. Ini memberikan pemeriksaan verbose implisit.

Hasil dan Pembahasan


Klasifikasi dengan Arsitektur VGG16

Pada tahap ini kami mengunduh model *pre-built* sehingga kita bisa melakukan transfer learning, selanjutnya parameter *include_top* diatur menjadi *False* agar *output layer* dari model *pre-built* tidak diikuti sertakan. Setelah model *pre-built* telah terunduh, kami menambahkan *output layer* yang sesuai dengan *case* yang sedang diteliti, disini kami menambahkan beberapa layer yaitu :

1. *GlobalAveragePooling2D* : Layer ini bertindak mirip dengan lapisan *Max Pooling* di *CNN*, satu-satunya perbedaan adalah bahwa ia menggunakan nilai rata-rata, bukan nilai max saat *Pooling*. Ini sangat membantu dalam mengurangi beban komputasi pada mesin saat pelatihan.
2. *Dropout* : Layer ini menghilangkan beberapa neuron pada setiap langkah dari lapisan membuat neuron lebih independen dari neuron tetangga. Ini membantu dalam menghindari overfitting. Neuron yang akan dihilangkan dipilih secara acak. Parameter laju adalah kemungkinan aktivasi neuron yang disetel ke 0, sehingga menjatuhkan neuron.
3. *Dense* : Ini adalah *output layer* yang mengklasifikasikan gambar ke dalam 1 dari 4 kelas yang tersedia dan menggunakan fungsi softmax yang merupakan generalisasi dari fungsi sigmoid.

Selanjutnya kami mengatur fungsi callback tujuannya adalah untuk membantu memperbaiki bug lebih cepat dan dapat membantu membuat model yang lebih baik. Disini kami menggunakan fungsi callback yaitu TensorBoard, ModelCheckpoint dan ReduceLROnPlateau. Akhirnya kami melakukan training model menggunakan model prebuilt dengan arsitektur VGG16 dan output layer seperti yang telah disebutkan diatas.

Epochs vs. Training and Validation Accuracy/Loss



Gambar 3. Training Accuracy

Gambar 3 menunjukkan *training accuracy* naik stagnan dari 0.3163 ke 0.7650 dan pada *training loss* dapat dilihat terjadi penurunan *loss* yang signifikan pada *epoch* kedua dari 10.1341 ke 1.2344, dan *loss* terakhir berada pada angka 0.5683 sedangkan *validation accuracy* naik secara fluktuatif dari 0.4286 ke 0.7007 dan *validation loss* stagnan turun dari 1.2509 ke 0.6817.

Tabel 1. Confusion Matrix


Precision	Recall	F1-Score	Accuracy
0.76	0.77	0.75	0.75

Tabel 1 menunjukkan hasil *confusion matrix* dari proses *training* menggunakan model transfer learning VGG16.

Klasifikasi dengan Arsitektur DenseNet169

Sama halnya dengan proses pada VGG16 diatas, pada klasifikasi ini peneliti melakukan langkah langkah yang sama, namun tentunya berbeda dengan model *pre-built* yang diunduh, kali ini model yang di unduh adalah model DenseNet169, selanjutnya adalah proses *training* model.

Epochs vs. Training and Validation Accuracy/Loss



Gambar 4. Training Accuracy

Dapat dilihat pada Gambar 4 *training accuracy* stagnan naik dari 0.7806 ke 0.9974 dan *training loss* stagnan turun dari 0.6304 ke 0.0082 sedangkan *validation accuracy* fluktuatif naik dari 0.5680 ke 0.9694 dan *validation loss* fluktuatif turun dari 7.4537 ke 0.1043

Tabel 2. Confusion Matrix dari Proses Training


Precision	Recall	F1-Score	Accuracy
0.97	0.98	0.98	0.98

Dapat dilihat hasil nilai *confusion matrix* dari proses *training* menggunakan model transfer learning DenseNet169 pada tabel 2.


Perbandingan Confusion Matrix

Performa klasifikasi untuk tiap arsitektur *network* disajikan dalam bentuk *Confusion matrix* yang ditunjukkan pada Gambar 5 dan Gambar 6. Untuk mengevaluasi hasil klasifikasi tersebut, digunakan empat *performance metrics* yaitu *Accuracy*, *Precision*, *Recall* dan *F1-score*.

Heatmap of the Confusion Matrix



Gambar 5. VGG16



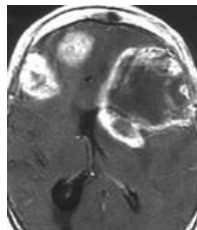
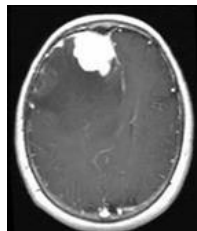
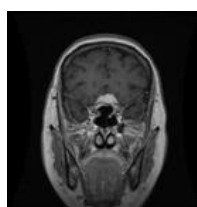
Gambar 6. DenseNet169

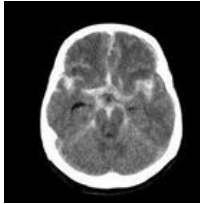
Nilai pada diagonal utama *confusion matrix* mewakili semua contoh yang diklasifikasikan dengan benar. Semakin gelap warna hijau pada diagonal utama *confusion matrix* di *heatmap plot* maka semakin akurat model mengklasifikasikan, sebaliknya jika warna hijau semakin gelap diluar dari diagonal utama maka semakin banyak model melakukan kesalahan klasifikasi. Antara gambar 5 dan gambar 6 dapat dilihat bahwa kesalahan klasifikasi paling sering terjadi pada gambar 5 yaitu arsitektur model VGG16.

Kesalahan Klasifikasi

Berdasarkan evaluasi kinerja dan analisis yang lebih rinci, peneliti menampilkan beberapa hasil prediksi dari model klasifikasi yang telah dibuat yaitu model arsitektur VGG16 dan DenseNet169 yang ditunjukkan pada tabel 3 dibawah.

Tabel 3. Model Arsitektur VGG16 dan DenseNet169

Contoh Gambar	Kelas Sebenarnya	VGG16	DenseNet169
	Glioma	Tidak Tumor	Glioma
	Meningioma	Meningioma	Meningioma
	<i>Pituitary</i>	Meningioma	<i>Pituitary</i>

Contoh Gambar	Kelas Sebenarnya	VGG16	DenseNet169
	Tidak Tumor	Tidak Tumor	Tidak Tumor

Dapat dilihat pada tabel 3 bahwa model dengan arsitektur VGG16 gagal mengklasifikasikan kelas *glioma tumor* dan *pituitary tumor*, lain halnya dengan model arsitektur DenseNet169 yang dapat mengklasifikasikan kelas *tumor* dengan baik.

Tabel 4. Perbandingan Nilai *Confusion Matrix* pada Setiap Model

Metrics	VGG16	DenseNet169
<i>Precision</i>	0.76	0.97
<i>Recall</i>	0.77	0.98
<i>Accuracy</i>	0.75	0.98
<i>F1-Score</i>	0.75	0.98

Dapat kita lihat juga perbandingan nilai *confusion matrix* pada setiap model pada tabel 4, ketika dilihat dari perbandingan tiap nilai *metrics* model DenseNet169 memiliki nilai *precision*, *recall*, *accuracy* dan *f1-score* lebih tinggi dibandingkan dengan VGG16 yang memiliki nilai lebih rendah.

Kesimpulan

Penelitian ini melakukan analisis perbandingan kinerja arsitektur jaringan dalam klasifikasi citra MRI dari tumor pada otak manusia. Metode *transfer learning* menggunakan arsitektur *pre-built* diterapkan untuk mengklasifikasikan gambar tumor. Arsitektur *pre-built* yang digunakan yaitu VGG16 dan DenseNet169. *Confusion matrix* dengan *performance metrics* yaitu *precision*, *recall*, *accuracy* dan *f1-score* digunakan untuk menilai kinerja setiap arsitektur *pre-built* yang diterapkan. Hasil penelitian ini menunjukkan bahwa kedua arsitektur *pre-built* yang digunakan berhasil mengklasifikasikan citra MRI dari tumor pada otak dengan menggunakan metode *transfer learning*. Sebanyak 3.264 gambar yang telah diklasifikasikan dengan komposisi data training sebesar 90% dan data testing sebesar 10%, dari jumlah keseluruhan dataset, DenseNet169 memiliki hasil yang lebih tinggi dibandingkan dengan VGG16. Untuk *accuracy metric*, DenseNet169 mencapai nilai 98%, sedangkan VGG16 hanya mencapai 75%. Pada *Performance metric* lainnya yaitu *recall* dan *f1-score* menunjukkan urutan yang sama yaitu DenseNet169 dan VGG16. Selanjutnya pada *metric precision* nilai DenseNet memiliki hasil jauh lebih tinggi yaitu 97%, dibandingkan dengan VGG16 yang hanya 76%. Oleh karena itu, berdasarkan seluruh proses yang telah dilakukan, DenseNet169 adalah arsitektur *pre-built* dengan kinerja terbaik untuk klasifikasi citra MRI dari tumor pada otak manusia. Untuk arah penelitian selanjutnya, disarankan untuk meningkatkan *accuracy* dan nilai *performance metrics* lainnya menggunakan arsitektur *pre-built* dengan menerapkan teknik lainnya seperti augmentasi atau algoritma optimasi.

Bibliografi

- Evani, Saphira. (2023). Epidemiologi Tumor Otak. Retrieved from alomedika.com website: <https://www.alomedika.com/penyakit/onkologi/tumor-otak/epidemiologi>
- Ghazi, Mostafa Mehdipour, Yanikoglu, Berrin, & Aptoula, Erchan. (2017). Plant identification using deep neural networks via optimization of transfer learning parameters. *Neurocomputing*, 235, 228–235.
- Hanin, Muhammad Atsil, Patmasari, Raditiana, & Fuâ, R. Yunendah Nur. (2021). Sistem Klasifikasi Penyakit Kulit Menggunakan Convolutional Neural Network (cnn). *EProceedings of Engineering*, 8(1).
- Haq, Ahmad Fayyadh Qaimul. (2022). *Deteksi tumor otak menggunakan Modification LU-NET berbasis CITRA MRI*. Universitas Islam Negeri Maulana Malik Ibrahim.
- Harahap, Fahri Aulia Alfarisi, Nafisa, Anti Nada, Purba, Erika Nia Devina Br, & Putri, Nurul Adawiyah. (2023). Implementasi Algoritma Convolutional Neural Network Arsitektur Model MobileNetV2 dalam Klasifikasi Penyakit Tumor Otak Glioma, Pituitary dan Meningioma. *Jurnal Teknologi Informasi, Komputer, Dan Aplikasinya (JTika)*, 5(1), 53–61.
- Harani, Nisa Hanum, & Hasanah, Miftahul. (2020). *Deteksi Objek dan Pengenalan Karakter Plat Nomor Kendaraan Indonesia Berbasis Python*. Kreatif.
- Lah, Tamara T., Novak, Metka, & Breznik, Barbara. (2020). Brain malignancies: Glioblastoma and brain metastases. *Seminars in Cancer Biology*, 60, 262–273. Elsevier.
- Malik, Zukri, Salam, Ainul Yaqin, Wardani, Hamidah Retno, Panma, Yuanita, Lestari, Trijati Puspita, Rahim, Alfyan, Wijayanti, Anggia Riske, & Faridah, Virgianti Nur. (2022). *Keperawatan Medikal Bedah II*. Rizmedia Pustaka Indonesia.
- Nafiiyah, Nur. (2023). Identifikasi Tumor Otak Citra MRI dengan Convolutional Neural Network. *Jurnal Informatika: Jurnal Pengembangan IT*, 8(3), 213–219.
- Ningsi, Agustina, Mukarramah, Sitti, & Cahyanti, Arika. (2021). Pengetahuan dan Sumber Informasi Berhubungan dengan Tindakan Pemeriksaan Payudara Sendiri pada Siswi SMA. *Jurnal Kebidanan Malakbi*, 2(2), 35–39.
- Örgüç, Sebnem, & Arkun, Remide. (2020). Tumor-like lesions of bone and soft tissues and imaging tips for differential diagnosis. *Seminars in Musculoskeletal Radiology*, 24(06), 613–626. Thieme Medical Publishers, Inc. 333 Seventh Avenue, 18th Floor, New York, NY
- Rizki, Ade Muhammad, & Marina, Nola. (2020). Klasifikasi kerusakan bangunan sekolah menggunakan metode convolutional neural network dengan pre-trained model VGG-16. *Jurnal Ilmiah Teknologi Dan Rekayasa*, 24(3), 197–206.

- Teoh, Teik Toe. (2022). CNN for Brain Tumor Classification. In *Convolutional Neural Networks for Medical Applications* (pp. 19–34). Springer.
- Winnarto, Monikka Nur, Mailasari, Mely, & Purnamawati, Annida. (2022). Klasifikasi Jenis Tumor Otak Menggunakan Arsitektur MobileNet V2. *J. SIMETRIS*, 13(2), 1–12.
- Yudha, I. Gde Anom A. (2022). Tumor Otak, Penyebab dan Penanganannya.