

KOMPARASI MOBILENETV2 DENGAN KUSTOMISASI TRANSFER LEARNING DAN HYPERPARAMETER UNTUK IDENTIFIKASI TUMOR OTAK

Muhammad Gabriel Somoal¹, Akhmad Rizal Dzkrillah^{*2}

^{1,2}Universitas Muhammadiyah Prof. DR. HAMKA, DKI Jakarta

Email: ¹gabrielsomoal@gmail.com, ²ahmad.rizal@uhamka.ac.id

*Penulis Korespondensi

(Naskah masuk: 16 Desember 2024, diterima untuk diterbitkan: 11 Februari 2025)

Abstrak

Tumor otak disebabkan dengan pertumbuhan sel otak yang abnormal pada jaringan otak yang menyebabkan kematian bagi pria dan wanita. Identifikasi tumor otak umumnya dilakukan dengan metode *biopsi* oleh dokter selama 10 hingga 15 hari. Namun, pendekatan modern diperlukan untuk menekan waktu dalam identifikasi tumor otak dengan teknologi *deep learning*. Dalam penelitian ini, menggunakan 4 kategori tumor otak yaitu *glioma*, *meningioma*, *notumor*, dan *pituitary* dengan akumulasi citra data sebanyak 20.000 data dan pembagian data meliputi 75% untuk *train* data, 15% untuk *validation* data, dan 10% untuk *testing* data. Penelitian ini bertujuan untuk membandingkan performa dari *Adam* dan *Stochastic Gradient Descent Optimizer*, dan model arsitektur *transfer learning MobileNetV2* dan *MobileNetV2* dalam identifikasi tumor otak. Penelitian ini menggunakan metode komparatif dengan metode evaluasi menggunakan *confusion matrix*. *Comparative analysis* dilakukan dengan membandingkan 4 skenario meliputi skenario 1 yaitu menggunakan *Adam optimizer* dan *transfer learning*, skenario 2 yaitu menggunakan *SGD optimizer* dan *transfer learning*, skenario 3 yaitu menggunakan *Adam optimizer* dan tanpa *transfer learning*, serta skenario 4 yaitu menggunakan *SGD optimizer* dan tanpa *transfer learning*. Hasil penelitian menunjukkan bahwa skenario 1 dengan penggunaan *Adam optimizer* dan model *transfer learning MobileNetV2* memperoleh *accuracy* sebesar 98%, *precision* sebesar 98%, *recall* sebesar 97,75%, dan *f1-score* sebesar 97,75% yang merupakan hasil model terbaik. Temuan ini mengindikasikan bahwa peran *transfer learning* sangat berpengaruh baik pada performa model dan diharapkan dapat memberikan wawasan lebih mendalam terkait model arsitektur yang paling akurat untuk identifikasi tumor otak serta menawarkan fondasi untuk pengembangan aplikasi berbasis *Magnetic Resonance Imaging* dalam citra medis.

Kata kunci: Transfer Learning MobileNetV2, Adam Optimizer, SGD Optimizer, Tumor Otak, Magnetic Resonance Imaging

COMPARISON OF MOBILENETV2 WITH CUSTOMISED TRANSFER LEARNING AND HYPERPARAMETER FOR BRAIN TUMOUR IDENTIFICATION

Abstract

Brain tumors are caused by the abnormal growth of brain cells in brain tissue, leading to death for both men and women. Typically, brain tumor identification is performed through a biopsy by doctors, taking 10 to 15 days. However, a modern approach is needed to reduce the time for brain tumor identification using deep learning technology. This study uses four categories of brain tumors: glioma, meningioma, no tumor, and pituitary tumor, with a dataset of 20,000 images. The data is divided into 75% for training, 15% for validation, and 10% for testing. The purpose of this study is to compare the performance of the Adam and Stochastic Gradient Descent (SGD) optimizers, as well as the MobileNetV2 and MobileNetV2 transfer learning architecture models in brain tumor identification. A comparative method is used, with evaluation through a confusion matrix. The analysis compares four scenarios: Scenario 1 using the Adam optimizer and transfer learning, Scenario 2 using the SGD optimizer and transfer learning, Scenario 3 using the Adam optimizer with no transfer learning, and Scenario 4 using the SGD optimizer with no transfer learning. The results show that Scenario 1, using the Adam optimizer and MobileNetV2 transfer learning, achieved the highest performance with 98% accuracy, 98% precision, 97.75% recall, and 97.75% F1-score. This finding highlights the significant impact of transfer learning on model performance, providing valuable insights into the most accurate architecture for brain tumor identification, and offers a foundation for developing Magnetic Resonance Imaging-based medical image applications.

Keywords: Transfer Learning MobileNetV2, Adam Optimizer, SGD Optimizer, Brain Tumour, Magnetic Resonance Imaging

1. PENDAHULUAN

Tumor otak menempati urutan ke-10 dalam kategori penyakit yang dapat menyebabkan kematian bagi pria dan wanita (DEEKSHA et al., 2020) serta anak-anak dan orang dewasa (HAO et al., 2021). Tumor otak disebabkan dengan adanya pertumbuhan sel otak yang abnormal pada jaringan otak secara tidak wajar (ANDRE, WAHYU and PURBANINGTYAS, 2021) dan mengganggu fungsi sistem saraf pusat (ESSIANDA et al., 2023). Beberapa jenis tumor otak antara lain *glioma*, *meningioma*, *notumor*, dan *pituitary*. Namun, jika dilihat pada citra nya hampir mirip (AULIA ALFARISI HARAHAP et al., 2021). Metode yang biasa dilakukan oleh dokter dalam identifikasi jenis tumor otak adalah dengan pengamatan langsung atau *biopsi* (SUTA, HARTATI and DIVAYANA, 2019). Namun, proses ini memerlukan waktu yang cukup lama dengan *interval* 10 hingga 15 hari (PASSA, NURMAINI and RINI, 2023). Oleh karena itu, diperlukan solusi untuk berupa identifikasi secara efisien dan efektif dengan menggunakan teknologi *deep learning* yang dapat membantu dokter dalam klasifikasi dan diagnosa jenis tumor otak (AULIA ALFARISI HARAHAP et al., 2021), (SEPTIPALAN et al., 2024).

Salah satu metode yang populer dalam teknologi *deep learning* adalah *convolutional neural network* (AULIA ALFARISI HARAHAP et al., 2021) yang bekerja secara hierarki (FAUZI JESSAR, TOTO WIBOWO and RACHMAWATI, 2021) dengan teknik pembelajaran yang membutuhkan sejumlah data besar dengan anotasi berkualitas tinggi (HAO et al., 2021) melalui pengembangan dengan *multilayer perceptron* (YANTO et al., 2021a) yakni jaringan-jaringan yang sepenuhnya saling terhubung (NURLIANI et al., 2024) dengan pengolahan data dalam bentuk dua dimensi (YANTO et al., 2023), misalnya suara dan gambar (YANTO et al., 2021a) melalui penerimaan *input* berupa citra (RAHMAN SYA'BANI, HAMZAH and SUSANTI, 2022) dalam bentuk *feature learning* dan *classification* (YANTO and HERAWAN HAYADI, 2020) dan dilakukan pemrosesan hingga menjadi data informasi (YANTO et al., 2021b). *Feature learning* berkontribusi dalam melakukan ekstraksi data dari sebuah citra menjadi sebuah *features* yang merepresentasikan citra berupa angka-angka, atau dapat dikatakan bahwa *input* berupa citra dan *output* berupa *features* (ARSYAD, WULANNINGRUM and SETIAWAN, 2024). Kemudian, *features* dihasilkan dari tahap *feature learning* masih dalam bentuk *multidimensional array* sehingga *input* sebelum di proses ke tahap *classification* diperlukan teknik *flatten* terlebih dahulu yakni konversi *multidimensional array* menjadi sebuah *vector* atau *array* satu dimensi (TSALSABILA RHAMADIYANTI, 2024).

Convolutional neural network dapat difungsikan untuk identifikasi dan klasifikasi citra dengan skala yang besar (AULIA ALFARISI

HARAHAP et al., 2021) data yang dilabeli dengan memanfaatkan metode *supervised learning* (YANTO et al., 2021a), (KASIM and SATYA NUGRAHA, 2021) untuk memecahkan masalah *linear* maupun *nonlinear* (MUCHTAR et al., 2021). Namun, penggunaan algoritma *convolutional neural network* tidak selalu nya bagus, terkadang mendapatkan masalah seperti *overfitting* dan *underfitting*. Teknik yang dapat digunakan untuk mengatasi hal tersebut dengan memanfaatkan data augmentasi (TSALSABILA RHAMADIYANTI, 2024), *transfer learning* ataupun optimasi *hyperparameter*.

Transfer learning merupakan prinsip pada *neural network* yang digunakan untuk membantu pelatihan pada data yang sedikit dan dapat mempercepat proses serta meningkatkan performa pelatihan (MUHAMMAD, ARIMURTHY and CHAHYATI, 2023), (WINNARTO, MAILASARI and PURNAMAWATI, 2022) dengan memanfaatkan arsitektur yang sudah ada (AULIA ALFARISI HARAHAP et al., 2021). *Transfer learning* dapat membantu mengatasi masalah *overfitting* dan *underfitting* dengan memanfaatkan representasi mendalam dari data yang sudah dilatih sebelumnya sebagai dasar untuk membangun arsitektur baru (BEIKMOHAMMADI and FAEZ, 2018), (SETIAWAN, 2020). Pada model arsitektur *MobileNetV2* jika dikombinasikan dengan *transfer learning*, maka ekstraksi fitur telah dilatih oleh *ImageNet* sebagai ekstraktor fitur (WINNARTO, MAILASARI and PURNAMAWATI, 2022). Kemudian, proses klasifikasi menggunakan *convolutional layer* 1x1, *global average pooling* dan *dense layer* dengan *activation function* berupa *softmax activation function*. Menurut (HANG et al., 2019) parameter yang terdapat pada *fully connected layer* menyebabkan kecepatan pada pelatihan jaringan menjadi lambat untuk *training* data dan mengakibatkan mudah terjadinya *overfitting*. Oleh karena itu, *global average pooling* digunakan untuk menghasilkan satu peta fitur pada setiap kelas data klasifikasi dan langsung diproses ke dalam *softmax activation function layer* (WINNARTO, MAILASARI and PURNAMAWATI, 2022). *Softmax activation function layer* dimanfaatkan pada *fully connected layer* untuk klasifikasi terhadap empat kelas data jenis tumor otak yang meliputi *glioma*, *meningioma*, *notumor*, dan *pituitary*.

Penelitian yang dilakukan oleh (MUKTI et al., 2024) dengan judul "Akurasi 12 Layer Convolutional Neural Network (CNN) Untuk Jenis Tumor Otak Dari Hasil Citra MRI Dengan Google Colab Dan dataset Kaggle" menerapkan 12 layer dengan model CNN murni dan menggunakan *K-Fold Cross Validation* dengan 80% untuk data *train* dan 20% untuk data *test* dengan total 5.712 data citra dari akumulasi 4 data kelas tumor otak dengan akurasi 79%. Penelitian lainnya yang dilakukan oleh (HUSEN, 2024) dengan judul "Klasifikasi Citra MRI Tumor Otak Menggunakan Metode Convolutional Neural

Network” menerapkan model CNN serta data augmentasi dalam prosesnya dengan total 726 data citra dari akumulasi 4 data kelas tumor otak dengan data yang tidak seimbang dengan akurasi 93%. Penelitian lainnya yang dilakukan oleh (FADIYAH ALYA, WIBOWO and PARADISE, 2023) dengan judul “*CLASSIFICATION OF BATIK MOTIF USING TRANSFER LEARNING ON CONVOLUTIONAL NEURAL NETWORK (CNN)*” menerapkan model VGG-16 dengan *transfer learning* yang berfokus pada perbandingan penggunaan dengan dan tanpa *transfer learning* terhadap klasifikasi motif batik dengan akurasi 89%.

Perbedaan penelitian ini dengan penelitian yang dilakukan oleh (MUKTI et al., 2024) dan (HUSEN, 2024) terdapat kebaruan pada penggunaan *transfer learning* dalam proses pembuatan model dan oleh (HUSEN, 2024) terdapat kebaruan pada *adam optimizer* sebagai bentuk kustomisasi *hyperparameter* sehingga peran *adam optimizer* dapat mempercepat konvergensi dan peran *transfer learning* dapat meningkatkan nilai akurasi dari penelitian sebelumnya.

Perbedaan penelitian ini dengan penelitian yang dilakukan oleh (FADIYAH ALYA, WIBOWO and PARADISE, 2023) terletak pada kebaruan dalam model arsitektur dengan menggunakan *MobileNetV2* sehingga dapat meningkatkan efisiensi komputasi.

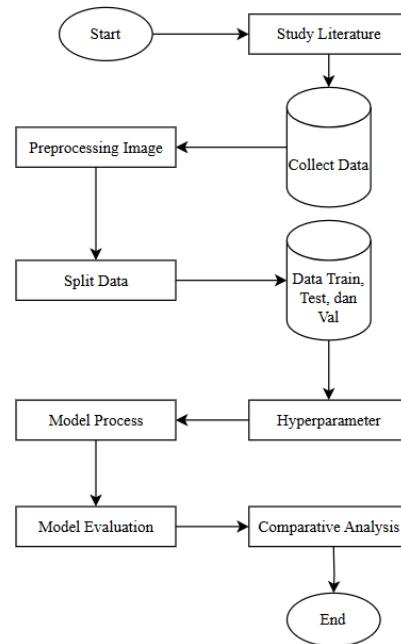
Penelitian ini berkontribusi untuk memperkaya kajian terkait *deep learning* dengan menggunakan *transfer learning* terhadap model *MobileNetV2* yang belum dipakai pada penelitian (MUKTI et al., 2024) dan (HUSEN, 2024) serta memperkaya kajian terkait *MobileNetV2* yang belum dipakai pada penelitian (MUKTI et al., 2024), (HUSEN, 2024) dan (FADIYAH ALYA, WIBOWO and PARADISE, 2023). Diharapkan penelitian ini dapat berguna untuk penelitian selanjutnya dengan pemilihan detail model dan *hyperparameter* yang sesuai untuk klasifikasi citra tumor otak.

2. METODE PENELITIAN

Penelitian ini menggunakan metode komparatif seperti yang tervisualisasikan pada gambar 1.

2.1. Study Literature

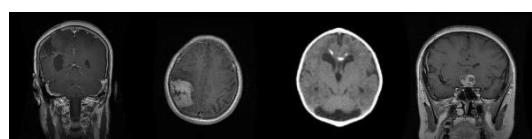
Penulis menggunakan salah satu teknik ini bertujuan untuk menelusuri berbagai konsep dan cara kerja (SALAWAZO et al., 2019) dalam membangun model *deep learning* (KASIM and SATYA NUGRAHA, 2021). Dimulai dari *collect data*, *preprocessing*, *split data*, *custom hyperparameter*, *model process*, *model evaluation*, dan *comparative analysis* merupakan teknik yang penulis adaptasikan dalam penelitian ini untuk menentukan akurasi model terbaik dengan objek identifikasi pada tumor otak.



Gambar 1. Metode Penelitian

2.2. Collect Data

Pada penelitian ini, penulis akuisisi data dari beberapa jurnal seperti (HASTOMO and SUDJIRAN, 2021), (HUSEN, 2024), (MUKTI et al., 2024), dan (WINNARTO, MAILASARI and PURNAMAWATI, 2022) dengan sebanyak empat kategori tumor otak yang meliputi *glioma* dengan jumlah sebesar 1321 data gambar, *meningioma* dengan jumlah sebesar 1339 data gambar, *notumor* dengan jumlah sebesar 1595 data gambar, dan *pituitary* dengan jumlah sebesar 1457 data gambar sehingga total keseluruhan data adalah 5712 data gambar. Gambar dari 4 kategori tumor otak, ditunjukkan pada gambar 2 secara berurut dari kiri.



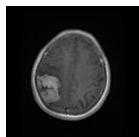
Gambar 2. Tumor Otak *Glioma*, *Meningioma*, *Notumor*, dan *Pituitary*

2.3. Preprocessing Image

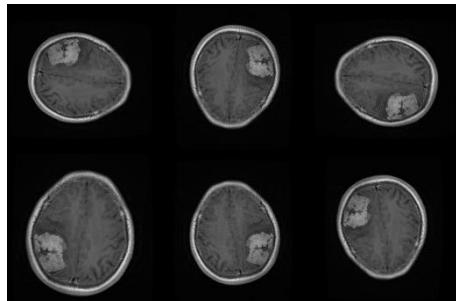
Preprocessing pada objek gambar merupakan langkah yang sangat penting, langkah ini dapat mengatasi *noise image*, *missing value* (WIBOWO and RAHMAWATI, 2023), dan variasi warna, resolusi, serta skala yang tidak konsisten (LARASATI and SETYAWAN, 2021) sehingga dapat meningkatkan kualitas gambar dan mempercepat model dalam memproses gambar (MIRANDA, NOVAMIZANTI and RIZAL, 2020). Dalam prosesnya, dataset berupa gambar dilakukan teknik *resize* yaitu merubah ukuran gambar menjadi 224 x 224 piksel dan menggunakan teknik *rescale* yaitu membagi nilai piksel dengan 225 sehingga nilai piksel berada antara 0 dan 1 agar tidak terjadinya

inkonsistensi ukuran input gambar (MIRANDA, NOVAMIZANTI and RIZAL, 2020), dan penghematan memori serta sumber daya komputasi (NUR CAHYO et al., 2023), (MICHAEL and RUSMAN, 2023) sehingga stabilitas proses pembuatan model tetap terjaga, dan mencegah masalah gradien yang menghilang (SUSANTO and MULYONO, 2022).

Selanjutnya, dilakukan teknik data *augmentation* yaitu teknik yang digunakan untuk mengatasi *overfitting* dan meningkatkan performa model (HENCYA et al., 2023) melalui penambahan salinan dataset guna meningkatkan variasi dataset yang dimanfaatkan untuk *train process* (AHMAD and CHOUDHURY, 2022), (ASIF et al., 2022). Proses data *augmentation* meliputi *image rotation*, *image zoom*, *horizontal flip*, dan *vertical flip* dengan menggunakan *library ImagedataGenerator* yang disediakan oleh subset *framework tensorflow* yaitu *keras*. Berikut adalah gambar dengan jenis tumor otak *meningioma* yang belum dilakukan *preprocessing* seperti pada gambar 3 dan telah dilakukan *preprocessing* seperti pada gambar 4.



Gambar 3. Before Preprocessing



Gambar 4. After Preprocessing

2.4. Split Data

Distribusi persentase dataset dalam proses pembuatan model *deep learning*, sangat mempengaruhi untuk mendapatkan hasil akurasi yang optimal (AULIA ALFARISI HARAHAP et al., 2021), (RIDHOVAN and SUHARSO, 2022). Dalam prosesnya, pembagian dataset untuk data *train*, data *test*, dan data *validation* sangat dibutuhkan (RODIAH, SUSETIANINGTIAS and PATRIYA, 2024). Penulis menentukan sebanyak 75% untuk data *train*, 15% untuk data *validation*, dan 10% untuk data *test* dari jumlah gambar sebanyak 20000 data. Rincian jumlah data dapat dilihat pada tabel 1 berikut.

Tabel 1. Rincian Split Data

| Jenis | Train | Test | Val |
|------------|-------|------|-----|
| Glioma | 3750 | 500 | 750 |
| Meningioma | 3750 | 500 | 750 |
| Notumor | 3750 | 500 | 750 |
| Pituitary | 3750 | 500 | 750 |

2.5. Hyperparameter

Penulis menggunakan empat skenario dengan kustomisasi *hyperparameter* pada penelitian ini, dua diantaranya memanfaatkan *stochastic gradient descent* (sgd) sebagai *optimizer* dan dua lainnya memanfaatkan *adaptive moment estimation* (adam) sebagai *optimizer*. *Optimizer* bekerja dengan menyesuaikan bobot dan parameter lainnya pada model-model *convolutional neural network* selama proses *training* dengan penekanan terhadap nilai *loss function* sehingga performa model dapat menjadi lebih tinggi (SULTONI, JUNAIDI and PUSPANINGRUM, 2024).

Stochastic gradient descent hanya membutuhkan satu data *train* pada setiap iterasi yang berfungsi untuk memaksimalkan fungsi tujuan atau meminimalkan fungsi biaya dari model dengan mencari nilai bobot optimal sehingga terjadi penghematan memori. Namun, karena proses stokastik (acak) yang dilakukan dapat mengakibatkan *noise* yang timbul pada *gradient*, hal tersebut merupakan penyebab yang dapat membuat konvergensi menjadi lebih lambat (WARDANI et al., 2023).

Adaptive moment estimation menggabungkan dua *optimizer* yaitu *stochastic gradient descent* dan *root mean square propagation* (RMSProp) (SULTONI, JUNAIDI and PUSPANINGRUM, 2024) yang digunakan untuk memperoleh konvergensi yang cepat dan stabil pada *training process* (WARDANI et al., 2023) secara empiris (PRAMANA, 2024) dengan percepatan dalam mengoptimalkan model dan mengatasi masalah seperti penurunan *learning rate* yang terlalu signifikan atau fluktuasi ekstrem pada *learning rate* (WARDANI et al., 2023).

Sebelum *optimizer* dapat digunakan, penulis menentukan besaran *learning rate* yang akan digunakan. Pada penelitian ini, penulis menggunakan 1e-5 yang merepresentasikan *learning rate*. Semakin kecil *learning rate* yang digunakan, maka dapat membantu untuk mengurangi risiko *overshooting* dan mencapai nilai konvergensi yang lebih stabil terutama pada *loss function* yang kompleks (JULIANTO, SUNYOTO and WIBOWO, 2022). Namun, kecepatan dalam *train process* membutuhkan waktu lebih lama untuk mencapai konvergensi yang stabil (JULIANTO, SUNYOTO and WIBOWO, 2022).

Pada penelitian ini, penulis mengadaptasikan *categorical cross entropy* sebagai *loss function* untuk empat kategori tumor otak, *categorical cross entropy* merupakan *loss function* yang dapat digunakan untuk multi kelas (PRILIANTI, OKTARIYANTO and SETIAWAN, 2024). Dalam empat skenario tersebut, penulis menerapkan *batch size* sebesar 32 sebagai acuan saat memproses data dalam satu *iteration* dan *epoch* sebesar 25 dengan teknik *callback* bermetode *early stopping* dan *ReduceLROnPlateau* menggunakan pendekatan *patience* sebesar 10. Hal tersebut dilakukan guna meningkatkan efisiensi

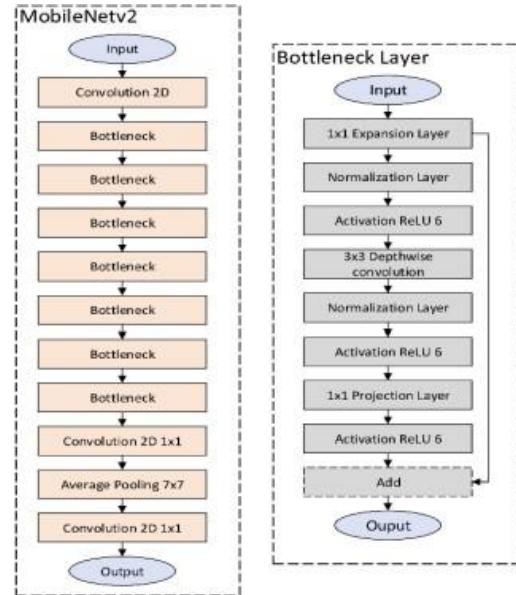
pelatihan, menghindari *overfitting* dan *underfitting* dengan memonitor *validation loss* (BUDIONO and WIRAWAN, 2023), apabila *validation loss* tidak mengalami penurunan selama 10 *epoch*, maka *train process* akan dihentikan pada metode *early stopping* dan jika *validation loss* tidak mengalami penurunan selama 10 *epoch*, maka nilai *learning rate* akan dikurangi *factor* dengan nilai yang ditentukan pada metode *ReduceLROnPlateau* hingga mencapai *epoch* yang ditentukan. Oleh karena itu, kedua metode tersebut membantu model untuk mempertahankan kemampuan generalisasi yang baik dengan menghentikan pelatihan pada waktu yang tepat dan memungkinkan penyesuaian yang lebih halus pada bobotnya saat mendekati konvergensi (PRAMANA, 2024) yang dapat mencegah kehilangan informasi penting selama pelatihan (RAHMAWATI, HIDAYAT and MUBAROK, 2021).

2.6. Model Process

Pada penelitian ini, penulis menggunakan empat skenario yaitu dua diantaranya menggunakan metode *transfer learning* dan dua lainnya tidak. Algoritma yang digunakan adalah *convolutional neural network* dengan model arsitektur *MobileNetV2*. Pada model arsitektur *MobileNetV2*, tidak terdapat perubahan dan pembaharuan *layer-layer* model dan hanya pada model arsitektur *transfer learning* *MobileNetV2* yang membaharui *layer* pada *fully connected layer*.

MobileNetV2 menggunakan teknik *depthwise separable convolution* dengan *depthwise convolution* dan *pointwise convolution* sebagai himpunannya. *Depthwise convolution* menggunakan filter konvolusi untuk setiap saluran pada lapisan *input* dengan menerapkan *stride* sebanyak 1 hingga 2 yang digunakan secara bergantian, sedangkan *pointwise convolution* merupakan lapisan kedua yang memanfaatkan *convolution 1 x 1* untuk menciptakan fitur baru melalui perhitungan kombinasi *linear* (HASTOMO and SUDJIRAN, 2021), (KARNO et al., 2020). Hal ini dapat mengoptimalkan pada kecepatan dan efisiensi klasifikasi gambar dengan mempertahankan akurasi yang baik dan ukuran model yang kecil. Selain itu, *MobileNetV2* mempunyai keunggulan dalam stabilitas model, dan presisi tinggi (JULIANTO, SUNYOTO and WIBOWO, 2022) berkat desainnya yang dapat mengurangi *complexity cost* (JANNATA et al., 2024). Gambar 5 menunjukkan model arsitektur *MobileNetV2*.

Transfer learning memanfaatkan *network architecture* yang telah ada dengan memodifikasi dan memperbarui parameter-parameter pada *network* tersebut sehingga *network architecture* telah mengenali *feature* berupa bentuk, tekstur dan warna serta tidak diperlukan pembelajaran dari awal (AULIA ALFARISI HARAHAP et al., 2021). Tabel 2 menunjukkan *custom fully connected layer*.



Gambar 5. Model Arsitektur *MobileNetV2*

Tabel 2. *Custom Fully Connected Layer*

| Layer | Output Shape |
|------------------------|---------------------|
| Global Average Pooling | (None, 1280) |
| Dropout Layer | (None, 1280) |
| Dense Layer | (None, 128) |
| Dropout Layer_1 | (None, 128) |
| Dense Layer_1 | (None, 4) |

Global average pooling digunakan untuk mencegah *overfitting* dengan mengurangi jumlah dimensi spasial secara efisien dan menggunakan jumlah parameter yang lebih rendah yang mendukung stabilitas dalam generalisasi dan menjaga informasi penting (ARYA et al., 2023), (HAFEEZ et al., 2023). Hal ini disebabkan dengan menghitung *mean* dari seluruh nilai pada setiap *feature map* atau *channel* sehingga menghasilkan *output tensor* satu dimensi (RASHEED et al., 2023), (DOMINIC et al., 2021). Misalnya, jika pada *convolution layer* memiliki ukuran 7 x 7 x 1280, *global average pooling* akan menghitung rata-rata nilai untuk setiap *feature map* 7 x 7, dan menghasilkan *vector* dengan panjang 1280.

Dropout layer dengan *dropout rate* sebesar 0.4 atau 40% digunakan untuk mengurangi risiko *overfitting* dan meningkatkan generalisasi dengan cara pada setiap *iteration* yang dilakukan, *dropout* secara *random* memilih *neuron-neuron* untuk dinonaktifkan berdasarkan probabilitas yang telah ditentukan. Kemudian, *output* dari proses tersebut dilakukan *normalize* agar sesuai dengan skala yang sama seperti *output* dari *layer* sebelumnya, sehingga dapat menjaga konsistensi dalam distribusi data saat *train* model (ZHANG et al., 2021), (ALMASLUKH, 2021). Hal ini sangat membantu dalam menjaga stabilitas dan meningkatkan efektivitas pembelajaran model secara keseluruhan (AMOU et al., 2022), (CHANDRASEKARAN et al., 2022).

Dense layer digunakan untuk menghubungkan semua *neuron* dari *layer* sebelumnya yang memungkinkan untuk memanfaatkan semua fitur

yang telah diekstraksi dengan mengombinasikan dan mengekstraksi fitur-fitur yang relevan dari data *input* agar model dapat belajar pola yang lebih kompleks melalui *activation function* yang telah ditentukan, dalam hal ini *softmax activation function* yang dapat mengatur bobot dan *bias* pada *dense layer* sehingga bobot dapat mengatur kekuatan antar *neuron* dan *bias* dapat membantu menyesuaikan *output neuron* (ARYA et al., 2023), (S M et al., 2023).

Softmax activation function digunakan dalam *fully connected layer* yang dikombinasikan pada *dense layer* sebagai *output layer* menjadi probabilitas untuk setiap kelas, sehingga mengoptimalkan hasil yang belum terstandarisasi pada setiap kelasnya dan dapat memudahkan dalam klasifikasi (GIANZURRIELL et al., 2023).

2.7. Model Evaluation

Dalam melakukan evaluasi model, penulis menggunakan metode *confusion matrix* sebagai metode untuk mengukur *accuracy*, *precision*, *recall*, dan *f1-score* dari skenario-skenario yang telah dicanangkan dengan dapat melihat pada persamaan berikut:

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

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

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

$$\text{F1 Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (4)$$

dengan TP merupakan *true positive*, TN adalah *true negative*, FP merupakan *false positive*, dan FN adalah *false negative* (AULIA ALFARISI HARAHAP et al., 2021).

2.8. Comparative Analysis

Pada penelitian ini, dilakukan analisis komparasi terkait empat skenario yang berbeda. Keempat skenario ini dirancang untuk mengevaluasi performa model arsitektur *MobileNetV2* dalam konteks identifikasi tumor otak berdasarkan penggunaan *transfer learning* dan pemilihan *optimizer* yang berbeda. Penggunaan *transfer learning* untuk mengatasi rendahnya akurasi pada penelitian yang dilakukan oleh (AULIA ALFARISI HARAHAP et al., 2021) dan penggunaan *optimizer* diterapkan untuk mengatasi rendahnya akurasi pada penelitian yang dilakukan oleh (MUKTI et al., 2024) sehingga penelitian ini dapat menjadi kombinasi dari kedua penelitian tersebut dengan optimal. Skenario penelitian dapat dilihat pada tabel 3 berikut.

Tabel 3. Skenario Penelitian

| Skenario | Optimizer | Model Architecture |
|----------|-----------|-------------------------------|
| 1 | Adam | Transfer Learning MobileNetV2 |
| 2 | SGD | Transfer Learning MobileNetV2 |
| 3 | Adam | MobileNetV2 |
| 4 | SGD | MobileNetV2 |

3. HASIL DAN PEMBAHASAN

Pada penelitian ini bertujuan untuk mencari akurasi model terbaik dan optimal dengan metode *confusion matrix* pada identifikasi tumor otak menggunakan 4 skenario dengan *optimizer* dan *transfer learning* sebagai pembeda dari tiap skenario yang diujikan.

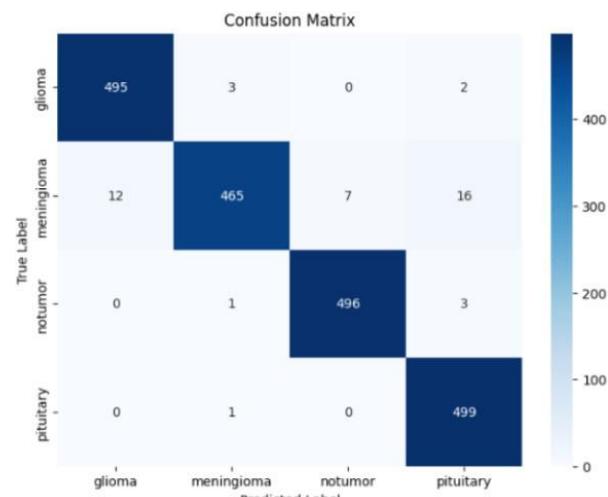
3.1. Skenario 1

Dari pengujian yang telah dilakukan pada skenario 1 yaitu dengan menggunakan *adam optimizer* dan *transfer learning*, didapatkan persentase *accuracy* sebesar 98%, *precision* sebesar 98%, *recall* sebesar 97.75%, dan *f1-score* sebesar 97.75%. Tabel 4 menunjukkan persentase *confusion matrix*.

Tabel 4. Persentase *Confusion Matrix* Skenario 1

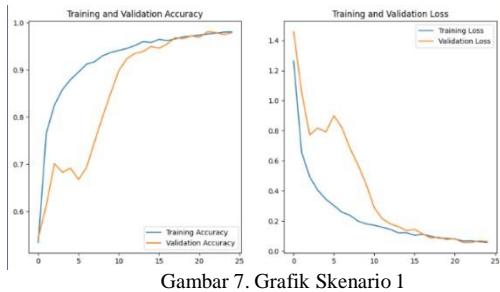
| Tumor Otak | Precision | Recall | F1-Score |
|------------|-----------|--------|----------|
| Glioma | 98% | 99% | 98% |
| Meningioma | 99% | 93% | 96% |
| Notumor | 99% | 99% | 99% |
| Pituitary | 96% | 100% | 98% |

Model klasifikasi ini menunjukkan performa tinggi dalam mendekripsi keempat kategori tumor otak dengan tingkat akurasi yang sangat baik yang dibuktikan oleh prediksi benar yang mendominasi tiap kelas pada *confusion matrix*. Gambar 6 menunjukkan *confusion matrix* skenario 1.

Gambar 6. *Confusion Matrix* Skenario 1

Grafik menunjukkan proses pelatihan yang stabil tanpa tanda-tanda *overfitting* dan *underfitting*, akurasi pelatihan dan validasi meningkat hampir bersamaan hingga mendekati 100% dan *loss* pada keduanya menurun mendekati nol di akhir pelatihan.

Hal ini menunjukkan bahwa model mampu belajar secara optimal, menggeneralisasi dengan baik, dan memiliki performa yang kuat baik pada data pelatihan maupun validasi. Gambar 7 menunjukkan grafik skenario 1.



Gambar 7. Grafik Skenario 1

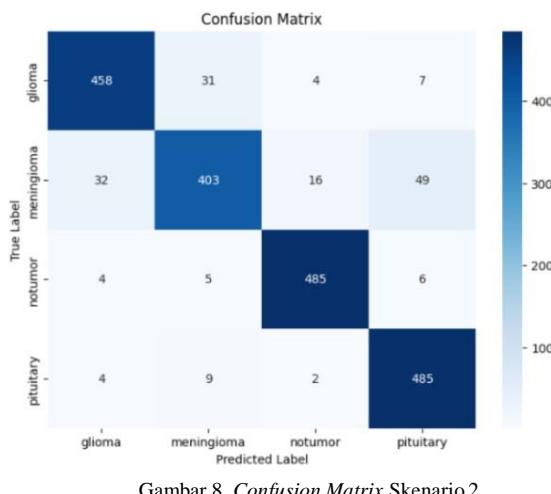
3.2. Skenario 2

Dari pengujian yang telah dilakukan pada skenario 2 yaitu dengan menggunakan *SGD optimizer* dan *transfer learning*, didapatkan persentase *accuracy* sebesar 92%, *precision* sebesar 91.75%, *recall* sebesar 91.75%, dan *f1-score* sebesar 91.5%. Tabel 5 menunjukkan persentase *confusion matrix*.

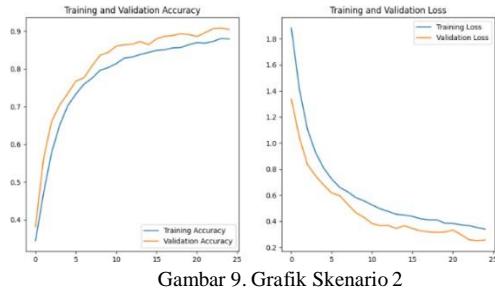
Tabel 5. Persentase *Confusion Matrix* Skenario 2

| Tumor Otak | Precision | Recall | F1-Score |
|------------|-----------|--------|----------|
| Glioma | 92% | 92% | 92% |
| Meningioma | 90% | 81% | 85% |
| Notumor | 96% | 97% | 96% |
| Pituitary | 89% | 97% | 93% |

Model ini menunjukkan bahwa model berhasil mengklasifikasikan tiga jenis tumor dengan *mean* pada kelas *pituitary*, *notumor*, dan *glioma* diatas dari 90%. Hasil ini mengindikasikan potensi kuat model dalam mendekripsi jenis tumor secara akurat. Gambar 8 menunjukkan *confusion matrix* skenario 2.

Gambar 8. *Confusion Matrix* Skenario 2

Grafik menunjukkan proses pelatihan optimal tanpa *overfitting* dan *underfitting*, dengan akurasi mendekati 92% dan penurunan *loss* yang konsisten yang mengindikasikan model mampu belajar dan menggeneralisasi pola dengan sangat baik. Gambar 9 menunjukkan grafik skenario 2.



Gambar 9. Grafik Skenario 2

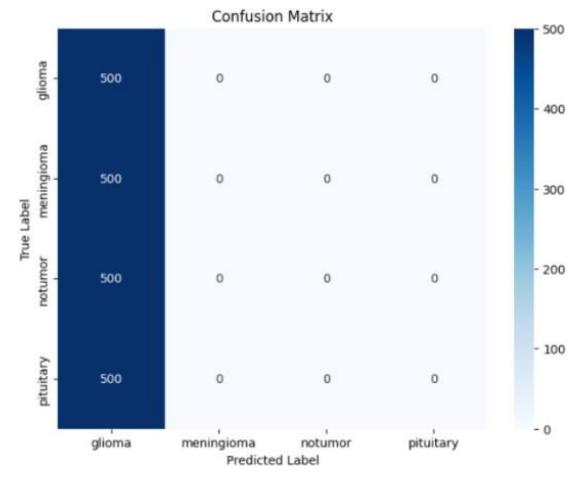
3.3. Skenario 3

Dari pengujian yang telah dilakukan pada skenario 3 yaitu dengan menggunakan *adam optimizer* dan tanpa *transfer learning*, didapatkan persentase *accuracy* sebesar 25%, *precision* sebesar 6.25%, *recall* sebesar 25%, dan *f1-score* sebesar 10%. Tabel 6 menunjukkan persentase *confusion matrix*.

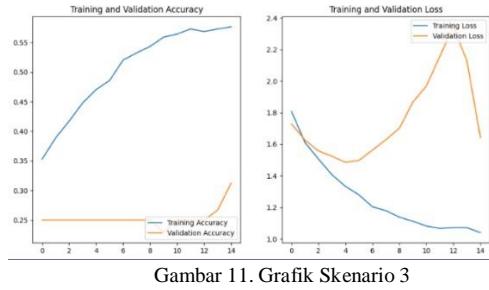
Tabel 6. Persentase *Confusion Matrix* Skenario 3

| Tumor Otak | Precision | Recall | F1-Score |
|------------|-----------|--------|----------|
| Glioma | 25% | 100% | 40% |
| Meningioma | 0% | 0% | 0% |
| Notumor | 0% | 0% | 0% |
| Pituitary | 0% | 0% | 0% |

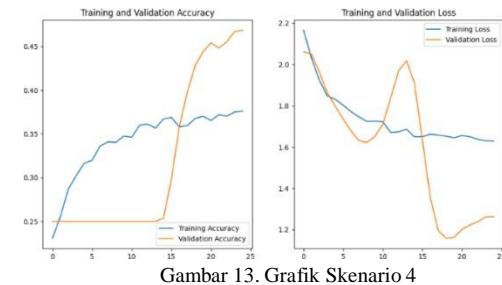
Model ini mengilustrasikan bahwa model tidak dapat belajar dengan baik yang dibuktikan pada prediksi benar bahwa seluruh kelas merupakan kelas *glioma*. Gambar 10 menunjukkan *confusion matrix* skenario 3.

Gambar 10. *Confusion Matrix* Skenario 3

Grafik menunjukkan model mengalami *overfitting* karena *loss validation* meningkat drastis meskipun *loss train* menurun, dan juga terdapat *underfitting* pada akurasi validasi yang stagnan di level rendah. Hal ini mengindikasikan bahwa model terlalu fokus pada *train* data dan gagal menggeneralisasi pola untuk data baru. Gambar 11 menunjukkan grafik skenario 3.



Gambar 11. Grafik Skenario 3



Gambar 13. Grafik Skenario 4

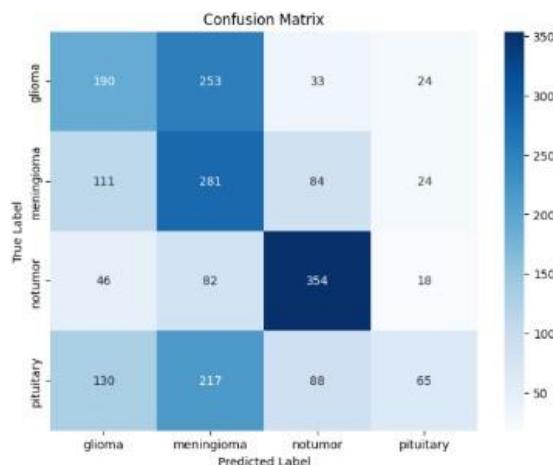
3.4. Skenario 4

Dari pengujian yang telah dilakukan pada skenario 4 yaitu dengan menggunakan *SGD optimizer* dan tanpa *transfer learning*, didapatkan persentase *accuracy* sebesar 45%, *precision* sebesar 46.75%, *recall* sebesar 44.5%, dan *f1-score* sebesar 42.25%. Tabel 7 menunjukkan persentase *confusion matrix*.

Tabel 7. Persentase *Confusion Matrix* Skenario 4

| Tumor Otak | Precision | Recall | F1-Score |
|------------|-----------|--------|----------|
| Glioma | 40% | 38% | 39% |
| Meningioma | 34% | 56% | 42% |
| Notumor | 63% | 71% | 67% |
| Pituitary | 50% | 13% | 21% |

Model ini menunjukkan bahwa dari empat jenis tumor otak, hanya satu jenis tumor otak yang dapat mengklasifikasikan dengan cukup baik yaitu kelas *notumor*. Namun, secara keseluruhan, diperlukan pengembangan untuk meningkatkan akurasi model. Gambar 12 menunjukkan *confusion matrix* skenario 4.

Gambar 12. *Confusion Matrix* Skenario 4

Grafik menunjukkan bahwa model mengalami *underfitting* pada awal pelatihan, terlihat dari akurasi validasi yang rendah dan stabil hingga *epoch* ke-15, lalu terjadi peningkatan tajam pada akurasi validasi setelahnya yang menunjukkan pembelajaran model terhadap data validasi. Namun, peningkatan ini disertai dengan fluktuasi signifikan pada *validation loss*, mengindikasikan *overfitting partial* dimana model mulai mempelajari *noise* pada data sehingga menyebabkan ketidakstabilan dalam generalisasi. Gambar 13 menunjukkan grafik skenario 4.

Analisis komparasi dengan 4 skenario melalui *confusion matrix* sebagai indikator yang dapat dilihat pada tabel 8.

Tabel 8. Analisis Komparasi

| Skenario | Accuracy | Precision | Recall | F1-Score |
|----------|----------|-----------|--------|----------|
| 1 | 98% | 98% | 97.75% | 97.75% |
| 2 | 92% | 91.75% | 91.75% | 91.5% |
| 3 | 25% | 6.25% | 25% | 10% |
| 4 | 45% | 46.75% | 44.5% | 42.25% |

Ringkasan dari penelitian-penelitian sebelumnya dan saat ini dapat dilihat pada tabel 9.

Tabel 9. *Literature Review*

| Author | Optimizer | Model Arsitektur | Akurasi |
|---|-----------|-------------------------------|---------|
| (MUKTI et al., 2024) | Adam | CNN | 79% |
| (HUSEN, 2024) | - | CNN | 93% |
| (FADIYAH ALYA, WIBOWO and PARADISE, 2023) | Adam | Transfer Learning VGG-16 | 89% |
| Penelitian yang dilakukan | Adam | Transfer Learning MobileNetV2 | 98% |

Setelah penulis meneliti 4 skenario diperoleh skenario 1 yaitu penggunaan *adam optimizer* dan *transfer learning* merupakan skenario terbaik diantara 3 skenario lainnya yang di uji dan merupakan hasil akurasi terbaik dari penelitian-penelitian sebelumnya sehingga skenario 1 yaitu penggunaan *adam optimizer* dan *transfer learning* dapat dijadikan sebagai pembaharuan serta peningkatan performa model dari penelitian-penelitian sebelumnya.

4. KESIMPULAN

Penelitian ini bertujuan untuk membandingkan performa antara *adam* dan *SGD optimizer* serta mengevaluasi perbedaan kinerja model arsitektur *transfer learning MobileNetV2* dan model tanpa *transfer learning* dalam mengidentifikasi jenis tumor otak melalui citra MRI. Dengan menggunakan data sebanyak 20.000 citra yang dibagi menjadi 75% untuk data *train*, 15% untuk data *validation*, dan 10% untuk data *test*, penelitian ini memberikan hasil yang signifikan dalam meningkatkan akurasi identifikasi tumor otak.

Berdasarkan hasil evaluasi pada 4 skenario yang diuji, skenario 1 yang menggunakan *adam optimizer* dan model *transfer learning MobileNetV2* menunjukkan hasil terbaik dengan *accuracy* mencapai 98%, *precision* 98%, *recall* 97.75%, *f1-score* 97.75%. Temuan ini mengindikasikan bahwa *transfer learning* memiliki pengaruh yang sangat signifikan dalam meningkatkan performa model, khususnya dengan penggunaan arsitektur *MobileNetV2* yang lebih efisien dalam hal komputasi.

Penelitian ini juga menunjukkan bahwa penggunaan *adam optimizer* dapat mempercepat konvergensi model, serta peran *transfer learning* dalam mengatasi kekurangan data yang terbatas dan meningkatkan akurasi prediksi. Dengan demikian, penelitian ini berkontribusi pada pengembangan aplikasi berbasis teknologi *deep learning* dalam bidang medis, khususnya untuk diagnosa tumor otak menggunakan citra MRI.

Secara keseluruhan, penelitian ini memberikan wawasan yang lebih mendalam tentang penggunaan *transfer learning* dan teknik optimasi dalam klasifikasi citra medis, serta memperkaya kajian dalam pemilihan model arsitektur dan *hyperparameter* yang tepat untuk identifikasi tumor otak. Diharapkan, temuan ini dapat menjadi dasar untuk pengembangan sistem diagnosa medis berbasis *deep learning* yang lebih efisien dan akurat di masa depan.

DAFTAR PUSTAKA

- AHMAD, S. and CHOUDHURY, P.K., 2022. On the Performance of Deep Transfer Learning Networks for Brain Tumor Detection Using MR Images. *IEEE Access*, 10, pp.59099–59114.
<https://doi.org/10.1109/ACCESS.2022.3179376>.
- ALMASLUKH, B., 2021. A Lightweight Deep Learning-Based Pneumonia Detection Approach for Energy-Efficient Medical Systems. *Wireless Communications and Mobile Computing*, pp.1–14.
<https://doi.org/10.1155/2021/5556635>.
- AMOU, M.A., XIA, K., KAMHI, S. & MOUHAFID, M., 2022. A Novel MRI Diagnosis Method for Brain Tumor Classification Based on CNN and Bayesian Optimization. *Healthcare (Switzerland)*, 10.
<https://doi.org/10.3390/healthcare10030494>
- ANDRE, R., WAHYU, B. & PURBANINGTYAS, R., 2021. *Klasifikasi Tumor Otak Menggunakan Convolutional Neural Network dengan Arsitektur EfficientNet-B3*. [online] Available at: <<https://jurnal.umj.ac.id/index.php/just-it/index>>.
- ARSYAD, N.P., WULANNINGRUM, R. and SETIAWAN, A.B., 2024. Implementasi Convolutional Neural Network Pada Deteksi Tumor Otak. [online] Agustus, Online. Available at: <<https://proceeding.unpkediri.ac.id/index.php/inote>> [Accessed 30 November 2024].
- ARYA, A.D., VERMA, S.S., CHAKRABARTI, P., CHAKRABARTI, T., ELNGAR, A.A., KAMALI, A.M. and NAMI, M., 2023. A Systematic Review on Machine Learning and Deep Learning Techniques in the Effective Diagnosis of Alzheimer's Disease. *Brain Informatics*, pp.1–15.
<https://doi.org/10.1186/s40708-023-00195-7>.
- ASIF, S., YI, W., AIN, Q.U., HOU, J., YI, T. and SI, J., 2022. Improving Effectiveness of Different Deep Transfer Learning-Based Models for Detecting Brain Tumors From MR Images. *IEEE Access*, 10, pp.34716–34730.
<https://doi.org/10.1109/ACCESS.2022.3153306>.
- BEIKMOHAMMADI, A. and FAEZ, K., 2018. Leaf Classification for Plant Recognition with Deep Transfer Learning. In: *Proceedings - 2018 4th Iranian Conference of Signal Processing and Intelligent Systems, ICSPIS 2018*. Institute of Electrical and Electronics Engineers Inc. pp.21–26.
<https://doi.org/10.1109/ICSPIS.2018.8700547>.
- BUDIONO, G. and WIRAWAN, R., 2023. Classification of Rice Texture Based on Rice Image Used the Convolutional Neural Network Method. *Techno Nusa Mandiri: Journal of Computing and Information Technology*, 20(2), pp.102–107.
<https://doi.org/10.33480/techno.v20i2.4666>.
- CHANDRASEKARAN, G., ANTOANELA, N., ANDREI, G., MONICA, C. and HEMANTH, J., 2022. Visual Sentiment Analysis Using Deep Learning Models with Social Media Data. *Applied Sciences (Switzerland)*, 12.
<https://doi.org/10.3390/app12031030>.
- DEEKSHA, K.N., DEEKSHA, M., GIRISH, A. V., BHAT, A.S. and LAKSHMI, H., 2020. Classification of Brain Tumor and its types using Convolutional Neural Network. In: *2020 IEEE International Conference for Innovation in Technology, INOCON 2020*. Institute of Electrical and Electronics Engineers Inc.
<https://doi.org/10.1109/INOCON50539.2020.9298306>.
- DOMINIC, N., DANIEL, CENGGORO, T.W., BUDIARTO, A. and PARDAMEAN, B., 2021. Transfer Learning Using Inception-Resnet-V2 Model to the Augmented Neuroimages Data for Autism Spectrum Disorder Classification. *Communications in*

- Mathematical Biology and Neuroscience.* <https://doi.org/10.28919/cmbn/5565>.
- ESSIANDA, V., INDRASARI, A.D., WIDYASTUTI, P. and SYAHLA, T., 2023. Brain Tumor : Molecular Biology, Pathophysiology, and Clinical Symptoms. *Jurnal Biologi Tropis*, 23(4), pp.260–269. <https://doi.org/10.29303/jbt.v23i4.5585>.
- FADIYAH ALYA, R., WIBOWO, M. and PARADISE, 2023. Classification of Batik Motif Using Transfer Learning on Convolutional Neural Network (CNN). *Jurnal Teknik Informatika (JUTIF)*, [online] 4(1), pp.161–170. <https://doi.org/10.20884/1.jutif.2023.4.1.564>.
- FAUZI JESSAR, H., TOTO WIBOWO, A. and RACHMAWATI, E., 2021. *Klasifikasi Genus Tanaman Sukulen Menggunakan Convolutional Neural Network*.
- GIANZURRIELL, V.B., HUSNAL, F., WIJAYA, F.A., FAUZI, F., PARYUDI, I., VERITAWATI, I. and NURSARI, S.R.C., 2023. Analisis Gambar MRI Otak untuk Mendeteksi Tumor Otak Menggunakan Algoritma CNN. *Journal of Informatics and Advanced Computing (JIAC)*, 4(2).
- HAFEEZ, U., UMER, M., HAMEED, A., MUSTAFA, H., SOHAIB, A., NAPPI, M. and MADNI, H.A., 2023. A CNN Based Coronavirus Disease Prediction System for Chest X-Rays. *Journal of Ambient Intelligence and Humanized Computing*, pp.13179–13193. <https://doi.org/10.1007/s12652-022-03775-3>.
- HANG, J., ZHANG, D., CHEN, P., ZHANG, J. and WANG, B., 2019. Classification of Plant Leaf Diseases Based on Improved Convolutional Neural Network. *Sensors (Switzerland)*, pp.1–14. <https://doi.org/10.3390/s19194161>.
- HAO, R., NAMDAR, K., LIU, L. and KHALVATI, F., 2021. A Transfer Learning-Based Active Learning Framework for Brain Tumor Classification. *Frontiers in Artificial Intelligence*, 4. <https://doi.org/10.3389/frai.2021.635766>.
- HASTOMO, W. and SUDJIRAN, S., 2021. Convolutional Neural Network Arsitektur MobileNet-V2 untuk Mendeteksi Tumor Otak. *Seminar Nasional Teknologi Informatika dan Komunikasi STI&K (SeNTIK)*, 5(1), pp.17–21.
- HENCYA, F.R., MANDALA, S., TANG, T.B. and ZAHID, M.S.M., 2023. A Transfer Learning-Based Model for Brain Tumor Detection in MRI Images. *Jurnal Nasional Teknik Elektro*, 12(2).
- <https://doi.org/10.25077/jnte.v12n2.1123.2023>.
- HUSEN, D., 2024. Klasifikasi Citra MRI Tumor Otak Menggunakan Metode Convolutional Neural Network. *bit-Tech*, 7(1), pp.143–152. <https://doi.org/10.32877/bt.v7i1.1576>.
- JANNATA, N., YANTO, F., HANDAYANI, L. and KURNIA, P.E.C., 2024. Pengaruh Contrast Limited Adaptive Histogram Equalization dalam Klasifikasi CT-Scan Tumor Ginjal Menggunakan Deep Learning. *JURNAL INOVTEK POLBENG*, 9(1), pp.420–433.
- JULIANTO, A., SUNYOTO, A. and WIBOWO, F.W., 2022. *Optimasi Hyperparameter Convolutional Neural Network untuk Klasifikasi Penyakit Tanaman Padi*. <https://doi.org/https://doi.org/10.46764/teknimediac.v3i2.77>.
- KARNO, A.S.B., HASTOMO, W., ARIF, D. and MORETA, E.S., 2020. Optimasi Portofolio dan Prediksi Cryptocurrency Menggunakan Deep Learning dalam Bahasa Python. *Seminar Nasional Teknologi Informatika dan Komunikasi STI&K (SeNTIK)*, 4(1), pp.193–202.
- KASIM, N. and SATYA NUGRAHA, G., 2021. *Pengenalan Pola Tulisan Tangan Aksara Arab Menggunakan Metode Convolution Neural Network*. <https://doi.org/https://doi.org/10.29303/jtika.v3i1.136>.
- MUHAMMAD, F., ARIMURTHY, A.M. and CHAHYATI, D., 2023. Transfer Learning dengan Metode Fine Tuning pada Model Network VGG16 dan ResNet50. *Indonesian Journal of Computer Science Attribution*, 12(1), pp.361–374.
- LARASATI, D.K. and SETYAWAN, I., 2021. Implementation of Template Matching on Detection of Stop Line Violations. *Jurnal Nasional Teknik Elektro*, 10(3).
- SEPTIPALAN, M.L., HIBRIZI, M.S., LATIFAH, N., LINA, R. and BIMANTORO, F., 2024. *Klasifikasi Tumor Otak Menggunakan CNN Dengan Arsitektur Resnet50*. [online] Available at: <<https://www.kaggle.com/datasets/thomasdubail/brain-tumors-256x256>>.
- MICHAEL, A. and RUSMAN, J., 2023. Klasifikasi Cacat Biji Kopi Menggunakan Metode Transfer Learning dengan Hyperparameter Tuning Gridsearch. *Jurnal Teknologi dan Manajemen Informatika*, [online] 9(1), pp.37–45. Available at: <<http://http://jurnal.unmer.ac.id/index.php/jtm>>.
- MIRANDA, N.D., NOVAMIZANTI, L. and RIZAL, S., 2020. Convolutional Neural Network pada Klasifikasi Sidik Jari Menggunakan ResNet-50. *Jurnal Teknik Informatika*

- (Jutif), 1(2), pp.61–68.
[https://doi.org/10.20884/1.jutif.2020.1.2.18.](https://doi.org/10.20884/1.jutif.2020.1.2.18)
- MUCHTAR, K., CHAIRUMAN, NURDIN, Y. and AFDHAL, 2021. Pendekripsi Septoria pada Tanaman Tomat dengan Metode Deep Learning berbasis Raspberry Pi. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 5(1).
<https://doi.org/https://doi.org/10.29207/resti.v5i1.2831>.
- MUKTI, M.A., KURNIAWAN, A.T., BAHRI, S., HUSIN, N., YANTO, B. and ASMEN, F., 2024. Akurasi 12 Layer Convolutional Neural Network (CNN) Untuk Jenis Tumor Otak Dari Hasil Citra MRI Dengan Google Colab Dan Dataset Kaggle. *Riau Journal of Computer Science*, .
- AULIA ALFARISI HARAHAP, F., NADA NAFISA, A., NIA DEVINA BR PURBA, E. and ADAWIYAH PUTRI, N., 2021. Implementasi Algoritma Convolutional Neural Network Arsitektur Model MobileNetV2 dalam Klasifikasi Penyakit Tumor Otak Glioma, Pituitary dan Meningioma. [online] Available at: <http://jtika.if.unram.ac.id/index.php/JTIK_A/>.
- NUR CAHYO, D.D., ANWAR FAUZI, M., TRI NUGROHO, J. and KUSRINI, K., 2023. Analisis Perbandingan Optimizer pada Arsitektur NASNetMobile Convolutional Neural Network untuk Klasifikasi Ras Kucing. *Jurnal Teknologi*, 15(2), pp.171–177.
<https://doi.org/10.34151/jurtek.v15i2.4025>.
- NURLIANI, ULFI M, SAUDAH, AYU TENGKU and ADYANATALUBIS, 2024. Implementasi Deep Learning dengan Convolutional Neural Network untuk Tingkat Akurasi Citra Image Hama Sawi Hijau Menggunakan Google Colab. *Riau Journal of Computer Science*, .
- PASSA, R.S., NURMAINI, S. and RINI, D.P., 2023. Deteksi Tumor Otak pada Magnetic Resonance Imaging Menggunakan YOLOv7. *Jurnal Ilmiah MATRIK*, 25(2).
- PRAMANA, A.L., 2024. Analisis Perbandingan Evaluasi Metode Deep Learning pada Klasifikasi Jenis Kendaraan. *Jurnal Ilmu Komputer dan Desain Komunikasi Visual*, 9(1), pp.451–465.
- PRILIANTI, R.K., OKTARIYANTO, V.V. and SETIAWAN, H., 2024. Ornamental Plant Identification System Using Transfer Learning on Convolutional Neural Network. *Jurnal Teknik Informatika (JUTIF)*, 5(4), pp.1015–1023.
<https://doi.org/10.52436/1.jutif.2024.5.4.1964>.
- RAHMAN SYA'BANI, D., HAMZAH, A. and SUSANTI, E., 2022. *Klasifikasi Buah Segar dan Busuk Menggunakan Algoritma Convolutional Neural Network dengan TFLite sebagai Media Penerapan Model Machine Learning*.
- RAHMAWATI, S.N., HIDAYAT, E.W. and MUBAROK, H., 2021. Implementasi Deep Learning pada Pengenalan Aksara Sunda Menggunakan Metode Convolutional Neural Network. *INSERT: Information System and Emerging Technology Journal*, 2(1), pp.46–58.
- RASHEED, Z., MA, Y.K., ULLAH, I., AL SHLOUL, T., TUFAIL, A. BIN, GHADI, Y.Y., KHAN, M.Z. and MOHAMED, H.G., 2023. Automated Classification of Brain Tumors From Magnetic Resonance Imaging Using Deep Learning. *Brain Sciences*.
<https://doi.org/10.3390/brainsci13040602>.
- RIDHOVAN, A. and SUHARSO, A., 2022. Penerapan Metode Residual Network (ResNet) dalam Klasifikasi Penyakit pada Daun Gandum.
- RODIAH, SUSETIANINGTIAS, D.T. and PATRIYA, E., 2024. Identifikasi Fitur Suara Menggunakan Model Convolutional Neural Network (CNN) pada Speech-to-Text (STT). *DECODE: Jurnal Pendidikan Teknologi Informasi*, 4(3), pp.809–820.
<https://doi.org/10.51454/decode.v4i3.631>.
- S M, J., P, M., ARAVINDAN, C. and APPAVU, R., 2023. Classification of Skin Cancer From Dermoscopic Images Using Deep Neural Network Architectures. *Multimedia Tools and Applications*, 82, pp.15763–15778.
<https://doi.org/10.1007/s11042-022-13847-3>.
- SALAWAZO, V.M.P., GEA, D.P.J., GEA, R.F. and AZMI, F., 2019. Implementasi Metode Convolutional Neural Network (CNN) pada Penegalan Objek Video CCTV. *Jurnal Mantik Penusa*, 3(1), pp.74–79.
- SETIAWAN, W., 2020. *Deep Learning Menggunakan Convolutional Neural Network: Teori dan Aplikasi*. Malang: Media Nusa Creative.
- SULTONI, R.F., JUNAIDI, A. and PUSPANINGRUM, E.Y., 2024. Analisa Komparasi Algoritma Machine Learning dan Deep Learning Dalam Klasifikasi Citra Ras Kucing. *Neptunus : Jurnal Ilmu Komputer Dan Teknologi Informasi*, 2(3), pp.328–357.
<https://doi.org/10.61132/neptunus.v2i3.251>.
- SUSANTO, A. and MULYONO, I.U.W., 2022. A Good Accuracy in Apple Fruits Quality Based on Back Propagation Neural Network and Feature Extraction. *JITE (Journal of Informatics and Telecommunication*

- Engineering), 6(1), pp.38–48.
<https://doi.org/10.31289/jite.v6i1.6938>.
- SUTA, I.B.L.M., HARTATI, R.S. and 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.v18i02.001>.
- TSALSABILA RHAMADIYANTI, D., 2024. Analisa Performa Convolutional Neural Network dalam Klasifikasi Citra Apel dengan Data Augmentasi. *KLIK: Kajian Ilmiah Informatika dan Komputer*, 5(1), pp.154–162.
<https://doi.org/10.30865/klik.v5i1.2023>.
- WARDANI, K.R.R., SURYALIM, H., ENGEL, V.J.L. and CHRISTIAN, H., 2023. Analisis Pemilihan Optimizer dalam Arsitektur Convolution Neural Network VGG16 dan Inception untuk Sistem Pengenalan Wajah. *JEPIN (Jurnal Edukasi dan Penelitian Informatika)*, 9(2), pp.186–194.
- WIBOWO, A. and RAHMAWATI, S., 2023. *Evaluasi Model Klasifikasi Algoritma Terbimbing Kuantitatif terhadap Penyakit Diabetes*.
- WINNARTO, M.N., MAILASARI, M. and PURNAMAWATI, A., 2022. Klasifikasi Jenis Tumor Otak Menggunakan Arsitektur MobileNet V2. *Jurnal SIMETRIS*, 13(2), pp.1–12.
- YANTO, B., FIMAWAHIB, L., SUPRIYANTO, A., HERAWAN HAYADI, B. and RIZKI PRATAMA, R., 2021a. Klasifikasi Tekstur Kematangan Buah Jeruk Manis Berdasarkan Tingkat Kecerahan Warna dengan Metode Deep Learning Convolutional Neural Network. *JURNAL INOVTEK POLBENG*, 6(2).
- YANTO, B. and HERAWAN HAYADI, B., 2020. Identifikasi Pola Aksara Arab Melayu dengan Jaringan Syaraf Tiruan Convolutional Neural Network (CNN). *JSAI : Journal Scientific and Applied Informatics*, 3(3), pp.106–114.
<https://doi.org/10.36085>.
- YANTO, B., JUFRI, LUBIS, A., HAYADI, B.S. and NST, E.A., 2021b. Klarifikasi Kematangan Buah Nanas Dengan Ruang Warna Hue Saturation Intensity. *JURNAL INOVTEK POLBENG*, 6(1).
- YANTO, B., ROUZA, E., FIMAWAHIB, L., HAYADI, B.H. and PRATAMA, R.R., 2023. Penerapan Algoritma Deep Learning Convolutional Neural Network dalam Menentukan Kematangan Buah Jeruk Manis Berdasarkan Citra Red Green Blue (RGB). *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, 10(1), pp.59–66.
<https://doi.org/10.25126/jtiik.2023105695>.
- ZHANG, Y.D., SATAPATHY, S.C., LIU, S. and LI, G.R., 2021. A Five-Layer Deep Convolutional Neural Network with Stochastic Pooling for Chest CT-Based COVID-19 Diagnosis. In: *Machine Vision and Applications*. Springer Science and Business Media Deutschland GmbH.
<https://doi.org/10.1007/s00138-020-01128-8>.