

Analisis Perbandingan Algoritma Pembelajaran Mesin untuk Meningkatkan Akurasi dan Klasifikasi Tumor Otak

Joy Lawa Rizky¹, Zico Putra Pratama¹

¹Fakultas Teknologi Informasi, Universitas Nusa Mandiri

*Email: 14220035@nusamandiri.ac.id

Info Artikel

Kata Kunci :

tumor otak,
pembelajaran mesin,
jaringan syaraf tiruan

Keywords :

brain tumors,
machine
learning,
artificial neural
network

Tanggal Artikel:

Dikirim:

11 Juli 2024

Direvisi:

5 November
2024

Diterima:

11 November
2024

Abstrak

Klasifikasi tumor otak bertujuan untuk mengevaluasi dan membandingkan kinerja beberapa algoritma pembelajaran mesin dalam klasifikasi tumor otak menggunakan Citra MRI. Dalam penelitian ini, metodologi yang digunakan melibatkan pengujian algoritma tradisional seperti *K-Nearest Neighbors* (KNN), *Naïve Bayes*, *Support Vector Machines* (SVM), dan beberapa arsitektur *Deep Learning* seperti *Neural Network Data* yang digunakan dalam penelitian ini terdiri dari citra MRI otak yang telah dilabeli secara manual oleh ahli radiologi. Kami membandingkan kinerja algoritma berdasarkan beberapa metrik evaluasi, termasuk akurasi, presisi, *recall*, dan *F1-score*. Hasil penelitian menunjukkan bahwa algoritma berbasis *Neural Network* (0.99) secara signifikan mengungguli algoritma tradisional seperti KNN (0.98), *Naïve Bayes* (0.97), dan SVM (0.98) dalam hal akurasi dan ketahanan terhadap variasi data. Namun, algoritma *Neural Network* dan metode *ensemble* menunjukkan kinerja yang kompetitif dengan keuntungan dalam hal interpretabilitas dan kecepatan pelatihan. Studi ini menyoroti keunggulan dan keterbatasan masing-masing algoritma dalam konteks klasifikasi tumor otak dan memberikan panduan praktis untuk memilih algoritma yang paling sesuai berdasarkan kebutuhan klinis dan karakteristik dataset. Penelitian lebih lanjut diperlukan untuk mengoptimalkan integrasi metode-metode ini dalam sistem pendukung keputusan klinis guna meningkatkan hasil diagnosis dan perawatan pasien.

Abstract

Brain tumor classification aims to evaluate and compare the performance of various machine learning algorithms in classifying brain tumors using MRI images. In this study, the methodology involves testing traditional algorithms such as K-Nearest Neighbors (KNN), Naïve Bayes, Support Vector Machines (SVM), and several deep learning architectures, including Neural Networks. The dataset used consists of brain MRI images manually labeled by radiology experts. We compared the performance of these algorithms based on several evaluation metrics, including accuracy, precision, recall, and F1-score. The results show that Neural Network-based algorithms (0.99) significantly outperform traditional algorithms such as KNN (0.98), Naïve Bayes (0.97), and SVM (0.98) in terms of accuracy and robustness to data variation. However, Neural Networks and ensemble methods demonstrated competitive performance with advantages in interpretability and training speed. This study highlights the strengths and limitations of each algorithm in the context of brain tumor classification and provides practical guidance for selecting the most suitable algorithm based on clinical needs and dataset characteristics. Further research is needed to optimize the integration of these methods into clinical decision support systems to enhance diagnosis and treatment outcomes for patients.

1. PENDAHULUAN

1.1 Latar Belakang

Klasifikasi tumor otak merupakan tantangan besar dalam bidang medis, terutama di *neuro-onkologi*, di mana diagnosis yang cepat dan akurat sangat penting untuk perawatan pasien yang efektif. Tumor otak dapat bersifat jinak atau ganas, dan pendekatan yang tidak tepat dalam diagnosis dapat mempengaruhi keberhasilan pengobatan serta prognosis pasien. MRI (*Magnetic Resonance Imaging*) sering digunakan untuk mendeteksi dan menganalisis keberadaan tumor dalam jaringan otak, karena teknik ini menghasilkan gambaran yang jelas antara jaringan sehat dan yang tidak normal. Namun, keterbatasan dalam interpretasi manual oleh tenaga medis menyebabkan adanya risiko kesalahan, khususnya pada kasus yang membutuhkan analisis data gambar yang sangat besar dan kompleks. Di sinilah peran pembelajaran mesin (*machine learning*) muncul sebagai solusi potensial untuk meningkatkan akurasi, konsistensi, dan efisiensi diagnosis. Berbagai algoritma telah dikembangkan dan diterapkan dalam klasifikasi tumor otak, termasuk algoritma tradisional seperti *K-Nearest Neighbors (KNN)*, *Naïve Bayes*, dan *Support Vector Machines (SVM)*, serta arsitektur *Deep Learning* yang lebih canggih seperti *Neural Network*.

Pembelajaran mesin dalam bidang medis telah berkembang pesat, terutama dalam klasifikasi citra medis ini penting yang bertujuan untuk membantu dokter dalam mendiagnosis berbagai penyakit secara otomatis. Kami mengevaluasi kinerja masing-masing algoritma berdasarkan beberapa metrik evaluasi, termasuk akurasi, presisi, *recall*, dan *F1-score*, menggunakan data citra MRI otak yang telah dilabeli secara manual oleh ahli radiologi. Hasil dari penelitian ini diharapkan dapat memberikan panduan praktis bagi peneliti dan praktisi medis dalam memilih algoritma yang paling sesuai untuk aplikasi klinis, serta memberikan wawasan tentang keunggulan dan keterbatasan masing-masing metode dalam menghadapi variasi data dan kebutuhan klinis yang berbeda.

Penelitian ini dilakukan oleh Rachelia Dita Anggraini yang berjudul, "Klasifikasi Tipe Kanker Berdasarkan Signature Tumor Dna Menggunakan Metode Xgboost". Hasil penelitian ini dengan akurasi paling tinggi didapatkan percobaan klasifikasi XGBoost *holdout cross-validation* 90:10 900 fitur dengan akurasi sebesar 89,91%, sedangkan nilai akurasi paling kecil diperoleh percobaan XGBoost *10-fold cross-validation* 900 fitur yaitu sebesar 70,01%. Berdasarkan percobaan yang sudah dilakukan, nilai akurasi cenderung lebih tinggi pada percobaan 900 fitur dibandingkan keseluruhan fitur dan akurasi percobaan menggunakan pembagian *holdout cross-validation* mendapat nilai akurasi lebih baik dibandingkan percobaan *10-fold cross-validation*. Untuk *holdout cross-validation* semakin besar persentase data latih semakin tinggi pula akurasi yang diperoleh [1].

Penelitian ini dilakukan oleh Anita Ratnasari yang berjudul, "Klasifikasi Citra Tumor Otak Menggunakan Gaussian Model Berbasis Machine Learning Berdasarkan MRI Dataset". Hasil penelitian ini dengan menggunakan dataset citra berbasis *magnetic resonance imaging (MRI)* berjumlah 3.079 data. Secara keseluruhan, hasil akurasi algoritma *support vector machine (SVM)* dan metode *adaptive thresholding* mendapatkan akurasi terbaik sebesar 84,25%, sedangkan metode *gaussian thresholding* mendapatkan akurasi 82,81% dan *global thresholding* mendapatkan akurasi 81,25% [2].

Penelitian ini menawarkan kontribusi unik dengan melakukan analisis perbandingan yang komprehensif terhadap algoritma pembelajaran mesin, baik yang tradisional maupun berbasis *deep learning*, khususnya *Neural Network* yang telah dioptimalkan untuk klasifikasi tumor otak. Data yang digunakan dalam penelitian ini mencakup citra MRI yang telah dilabeli secara manual oleh ahli radiologi, memberikan validitas yang tinggi pada hasil eksperimen. Kemajuan teknologi, terutama di bidang kecerdasan buatan dan pembelajaran mesin, memberikan pengaruh besar pada dunia medis, salah satunya adalah pengenalan citra medis [3].

Tanda-tanda tumor otak sering kali diabaikan. 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 [4]. Tumor otak memiliki 3 jenis yaitu tumor *glioma*, tumor *meningioma*, dan tumor *pituitary* [5]. Deteksi tumor otak dapat dilakukan sebagian dengan menggunakan pendekatan anatomi pada pencitraan medis. Sebagai contoh, pertimbangkan *Computed Tomography scan (CT scan)* dan *Magnetic Resonance Imaging (MRI)*. Jaringan lunak otak tidak dapat dideteksi dengan *CT scan*. *CT scan* cocok untuk melihat struktur tulang. MRI lebih baik dalam menunjukkan perbedaan antara jaringan lunak dan keras otak karena memberikan informasi citra yang lebih dalam. Dokter dapat menggunakan hasil MRI untuk mendapatkan informasi penting untuk evaluasi dan diagnosis [1]. Oleh karena itu, menentukan apakah seorang pasien mengidap tumor otak dapat memakan waktu lama dan memerlukan

analisis menyeluruh oleh tim profesional medis yang dapat membaca dan mencitrakan tumor dari pencitraan MRI [6]. Tumor otak bermula dari berkembangnya sel yang tidak normal pada otak. Terdapat dua jenis tumor otak yaitu primer dan sekunder. Tumor otak primer merupakan pertumbuhan sel yang abnormal yang berawal dari sel otak itu tersebut. Di sisi lain, tumor otak sekunder ialah tumor yang bermula dari kanker tubuh lain ke otak [7].

Modalitas pencitraan medis *Magnetic resonance imaging (MRI)* dan *CT-Scan* kebanyakan bergantung pada teknologi komputer yang menghasilkan atau menampilkan citra digital dari organ dalam tubuh manusia yang membantu dokter dalam memvisualisasikan bagian tubuh. MRI, *CT-scan*, dan *Radiographic* sering digunakan oleh dokter untuk mempermudah mendapatkan analisa dan diagnosa dari penyakit tertentu. Dimana MRI, *CT-scan*, dan *Radiographic* melakukan pengambilan alih citra dengan x-ray konvensional, sehingga memungkinkan dokter dapat melihat visualisasi 3 dimensi dari tubuh [8] Teknologi informasi yang terus berkembang adalah bagian penting dari kemajuan dunia medis saat ini. Dunia kedokteran yang mulai menggunakan teknologi sangat berkaitan dengan perkembangan ini. Salah satu teknologi yang digunakan adalah teknologi pengolahan citra digital [9].

Pemilihan Subset fitur, bersama dengan pengaturan parameter dalam prosedur pelatihan SVM secara signifikan mempengaruhi akurasi klasifikasi. Jumlah fitur yang banyak (*high dimensional*) akan memberikan masukan yang berbeda-beda. Masih sedikit penelitian yang berfokus pada pemilihan fitur untuk memprediksi *customer churn* telekomunikasi. Untuk mencapai kinerja yang baik dan akurasi yang tinggi. Tujuan pemilihan masukan membantu menghapus masukan yang tidak relevan, menghapus masukan yang bergantung dengan masukan lainnya, sehingga pembuatan model lebih ringkas, transparan dan mengurangi waktu untuk pembentukan model [10]

Magnetic Resonance Imaging (MRI) merupakan alat kedokteran yang berprinsip pada resonansi *magnetic* inti atom *hydrogen*. Dan merupakan alat diagnostik radiologi, MRI menghasilkan rekaman gambar dari tubuh atau organ manusia dengan menggunakan benda magnet [11]. Gambar MRI yang dipindai dipantau dan diperiksa oleh ahli radiologi dan profesional medis atau dokter spesialis untuk menentukan apakah ada tumor. Oleh karena itu, menentukan apakah seorang pasien mengidap tumor otak dapat memakan waktu lama dan memerlukan analisis menyeluruh oleh tim profesional medis yang dapat membaca dan mencitrakan tumor dari pencitraan MRI. Selain itu, kompleksitas gambar MRI dapat menyebabkan penentuan negatif palsu saat mendeteksi keberadaan tumor otak. Oleh karena itu, untuk mengatasi kelemahan yang signifikan ini, pengembangan perangkat medis menggunakan pembelajaran mesin untuk tidak hanya mempercepat seluruh proses identifikasi, tetapi juga untuk membuat keputusan yang lebih tepat tentang mendeteksi adanya tumor otak [4].

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 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 terbaik dan mengidentifikasi faktor-faktor yang mempengaruhi kinerja tersebut [5].

1.2 Tujuan Penelitian

Penelitian ini bertujuan untuk mengevaluasi dan membandingkan kinerja berbagai algoritma pembelajaran mesin guna meningkatkan akurasi klasifikasi tumor otak. Melalui analisis perbandingan, penelitian ini mengidentifikasi algoritma yang paling akurat dan efisien untuk membantu deteksi dan manajemen tumor otak. Hasilnya diharapkan memberikan wawasan praktis bagi aplikasi klinis dan panduan untuk penelitian lanjutan.

1.3 Manfaat Penelitian

Manfaat dari penelitian Analisis Perbandingan Algoritma Pembelajaran Mesin Untuk Meningkatkan Akurasi dan Klasifikasi Tumor Otak adalah Peningkatan Akurasi Diagnostik, Mengidentifikasi algoritma paling akurat untuk klasifikasi tumor otak guna mengurangi kesalahan diagnosis.. Optimalisasi Pemilihan Algoritma, Menyediakan wawasan algoritma terbaik untuk aplikasi klinis, meningkatkan efisiensi sumber daya. Peningkatan Manajemen Penyakit, Mendukung deteksi dini dan pengelolaan tumor untuk intervensi medis yang cepat. Pengembangan Teknologi Medis, Menyempurnakan teknologi AI untuk aplikasi klinis. Panduan untuk Penelitian Lanjutan, Memberikan dasar kuat untuk riset lebih lanjut di bidang klasifikasi tumor otak. Perbaikan Perawatan Pasien, Meningkatkan perawatan melalui akurasi yang lebih baik dalam perencanaan dan prognosis. Pengetahuan tentang Kinerja Algoritma, Memberikan pemahaman tentang efektivitas algoritma yang dapat diaplikasikan ke bidang medis lainnya.

1.4 Metode Pengembangan

1.4.1 Metode Pengembangan Pengumpulan Data

Mengumpulkan dataset gambar tumor otak dari sumber yang terpercaya, seperti basis data medis atau institusi kesehatan. Dataset ini harus mencakup berbagai jenis tumor otak yang telah diberi label dengan benar.

1.4.2 Pra-pemrosesan Data

Melakukan pembersihan data untuk menghapus data yang tidak lengkap atau anomali. Mengonversi gambar ke format yang seragam, seperti mengubah ukuran gambar atau melakukan normalisasi *pixel*. Mengubah fitur kategorikal menjadi bentuk numerik, jika diperlukan. Pembagian Dataset Membagi dataset yang telah diproses menjadi tiga bagian: set pelatihan (60%), set validasi (20%), dan set pengujian (20%) untuk memastikan model dievaluasi dengan data yang tidak pernah dilihat sebelumnya.

1.4.3 Pemilihan Algoritma

Memilih beberapa algoritma pembelajaran mesin yang umum digunakan untuk klasifikasi, seperti *K-Nearest Neighbors (KNN)*, *Naïve Bayes*, *Support Vector Machine (SVM)*, dan *Neural Network*.

1.4.4 Pelatihan Model

Melatih setiap algoritma menggunakan set pelatihan. Melakukan penyesuaian hyperparameter menggunakan set validasi untuk setiap algoritma untuk mengoptimalkan kinerja.

1.4.5 Evaluasi Model

Menggunakan set pengujian untuk mengevaluasi kinerja setiap model dengan metrik seperti akurasi, presisi, *recall*, dan *F1-Score*. Membandingkan hasil dari setiap model untuk menentukan algoritma yang paling efektif.

1.4.6 Analisis Hasil

Menganalisis kinerja masing-masing algoritma untuk memahami kekuatan dan kelemahan dalam klasifikasi tumor otak. Membuat tabel atau grafik untuk menyajikan perbandingan kinerja secara visual.

1.5 Definisi dan Istilah

K-Nearest Neighbor (KNN) adalah metode klasifikasi suatu objek berdasarkan data pembelajaran yang jaraknya paling dekat dengan objek tersebut. Metode ini bertujuan untuk mengklasifikasikan objek baru berdasarkan atribut dan training sample. Berikut tahapan pada KNN [6]. *Support Vector Machine (SVM)*. SVM adalah pengklasifikasi margin maksimum yang didefinisikan sebagai masalah optimasi. Dalam praktiknya, pendekatan umum untuk klasifikasi multi-kelas adalah metode satu-lawan-semua dan metode satu-lawan-satu. Untuk tugas klasifikasi c-kelas, pendekatan pertama membutuhkan c pengklasifikasi SVM biner. Persyaratannya adalah $c(c-1)/2$ pengklasifikasi biner, ketika pendekatan yang terakhir diikuti. Penelitian yang diusulkan menggunakan model pengklasifikasi 3-kelas dengan tiga pengklasifikasi biner SVM, mengikuti pendekatan satu-lawan-semua [1].

Computed Tomography Scan (CT scan) Jaringan lunak otak tidak dapat dideteksi dengan *CT scan*. *CT scan* cocok untuk melihat struktur tulang. MRI lebih baik dalam menunjukkan perbedaan antara jaringan lunak dan keras otak karena memberikan informasi citra yang lebih dalam. Dokter dapat menggunakan hasil MRI untuk mendapatkan informasi penting untuk evaluasi dan diagnosis [1]. *Magnetic Resonance Imaging (MRI)* dan *CT-Scan* kebanyakan bergantung pada teknologi komputer yang menghasilkan atau menampilkan citra digital dari organ dalam tubuh manusia yang membantu dokter dalam memvisualisasikan bagian tubuh. MRI, *CT-scan*, dan *Radiographic* sering digunakan oleh dokter untuk mempermudah mendapatkan analisa dan diagnosa dari penyakit tertentu. Dimana MRI, *CT-scan*, dan *Radiographic* melakukan pengambilan alih citra dengan x-ray konvensional, sehingga memungkinkan

dokter dapat melihat visualisasi 3 dimensi dari tubuh (Sharma, Diwakar, & Choudhary, 2012) [8]. *true positive (TP)*, *true negative (TN)*, *false positive (FP)*, dan *false negative (FN)* 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 (Wulandari et al., 2020). [12]

1.6 Referensi


Berikut ini beberapa hasil penelitian yang penulis gunakan sebagai referensi, Penelitian ini dilakukan oleh Indra Maulana, Amril Mutoi Siregar, Rahmat, Ahmad Fauzi yang berjudul, "Optimasi Akurasi Model Pembelajaran Mesin Untuk Klasifikasi Tumor Otak Dengan Analisis Komponen Utama". Hasil penelitian ini menunjukkan bahwa penggunaan PCA memiliki dampak berbeda pada setiap algoritma. PCA meningkatkan akurasi SVM dari 81% menjadi 83% dan KNN dari 68% menjadi 71%, tetapi menurunkan akurasi Logistic Regression dari 77% menjadi 69% dan Naive Bayes dari 49% menjadi 42%. Evaluasi dilakukan menggunakan Confusion Matrix dan AUC-ROC untuk mengukur kinerja model. Kesimpulannya, pemilihan algoritma dan metode preprocessing yang tepat sangat penting dalam klasifikasi citra medis, dan penggunaan PCA harus dipertimbangkan berdasarkan karakteristik data dan algoritma yang digunakan. Penelitian ini juga mendorong eksplorasi metode reduksi dimensi alternatif untuk analisis citra medis [1].

Penelitian ini dilakukan oleh Puji Laksono, Harliana, Tito Prabowo yang berjudul, "Deteksi Tumor Otak Melalui Penerapan GLCM dan Naïve Bayes Classification". penelitian ini adalah mengetahui nilai akurasi yang dihasilkan oleh "GLCM dan Naïve Bayes Classification" dalam memprediksi citra tumor otak yang didapatkan. Berdasarkan hasil uji yang telah dilakukan terhadap 253 dataset pasien diketahui bahwa nilai akurasi yang dihasilkan oleh Naïve Bayes dalam melakukan klasifikasi ternyata cukup tinggi yaitu 80% dengan perbandingan data testing dan data trainingnya adalah 20% : 80%, selain itu rata-rata dari nilai presisi dan *recall* yang dihasilkan pun sama yaitu 85% [13]

Penelitian ini dilakukan oleh Rachmad Andre R, Baghas Wahyu P, dan Rani Purbaningtyas yang berjudul, "Klasifikasi Tumor Otak Menggunakan Convolutional Neural Network Dengan Arsitektur Efficientnet-B3". Hasil penelitian ini dengan beberapa skenario dari *learning rate* serta kombinasi dari jumlah neuron pada *dense layer*. Hasil dari pengujian model dengan *confusion matrix*, mendapatkan akurasi tertinggi pada eksperimen dengan skenario *learning rate* 0.02 dan neuron pada *dense layer* berjumlah 256 yang menghasilkan akurasi mencapai 99.7% dan mendapatkan nilai F1-Score tertinggi mencapai 99.6%. Penerapan model terbaik yang dirancang dalam bentuk sistem berhasil melakukan prediksi terhadap jenis tumor glioma [14].

2. METODE PENELITIAN

Dataset yang digunakan dalam penelitian ini berisi gambar MRI dari pasien dengan dan tanpa tumor otak. Dataset ini biasanya bersumber dari *database* publik atau institusi medis yang menyimpan data MRI yang telah diidentifikasi secara manual oleh para ahli. Pra-pemrosesan data, tahap ini bertujuan untuk memastikan kualitas data dan meningkatkan akurasi model dalam mengenali pola pada gambar. Pembagian dataset dibagi menjadi tiga subset utama: *training*, *validation*, dan *testing*, dengan rasio umum seperti 60% untuk *training*, 20% untuk *validation*, dan 20% untuk *testing*, *training set*. Pemilihan algoritma *machine learning*. Algoritma yang diuji dalam penelitian ini mencakup metode tradisional (KNN, *Naive Bayes*, SVM) dan metode berbasis *deep learning* seperti *neural network*. Pemilihan algoritma didasarkan pada kemampuan masing-masing untuk menangani kompleksitas gambar MRI. Algoritma tradisional dipilih untuk perbandingan *baseline*, sedangkan *neural network* dipilih karena keunggulannya dalam mengenali pola kompleks pada data gambar. *Tuning Hyperparameter* dilakukan untuk mengoptimalkan performa model. Untuk algoritma tradisional seperti SVM, tuning dilakukan pada parameter seperti kernel, gamma, dan C. untuk *neural network*, *hyperparameter* seperti jumlah lapisan, jumlah neuron, dan laju pembelajaran disesuaikan. Setelah tuning hyperparameter dan evaluasi model selesai, hasil akhir dari masing-masing model dibandingkan untuk mengidentifikasi algoritma yang memberikan kinerja terbaik. Diskusi ini mencakup analisis kelebihan dan kekurangan dari setiap algoritma, termasuk pertimbangan waktu komputasi, interpretabilitas, dan keakuratan. Tahapan penelitian ditunjukkan pada Gambar 1



Gambar 1. Tahapan Penelitian

2.1 Dataset dan Pre-processing

2.1.1 Dataset

Penelitian ini menggunakan *dataset* dari Kaggle dengan 3762 baris dan 13 fitur (Tabel 2). Fitur-fitur mencakup *Mean*, dan variabel target utama, yaitu apakah subjek memiliki kanker paru-paru atau tidak.

Tabel 2. Dataset

Atribut	Deskripsi
<i>Mean</i>	Rata-rata ini membantu dalam menganalisis dan memahami distribusi data
<i>Variance</i>	membantu dalam memahami seberapa homogen atau heterogen
<i>Standard Deviation</i>	digunakan untuk memahami distribusi serta variasi dalam dataset
<i>Entropy</i>	pengambilan keputusan yang lebih baik dalam analisis data
<i>Skewness</i>	membantu memahami distribusi data yang tidak simetris
<i>Kurtosis</i>	memahami distribusi data, khususnya dalam hal outlier atau nilai ekstrem
<i>Contrast</i>	meningkatkan perbedaan intensitas antara jaringan sehat dan tumor, membuat tumor lebih terlihat dan lebih mudah diukur serta dianalisis
<i>Energy</i>	membantu dalam identifikasi, analisis, dan pengobatan tumor otak.
<i>ASM</i>	analisis citra medis, khususnya dalam identifikasi, analisis, dan pengobatan tumor otak, membantu dalam memahami tekstur dan distribusi intensitas dalam citra.
<i>Homogeneity</i>	memberikan wawasan tentang keseragaman atau variasi dalam tekstur jaringan
<i>Dissimilarity</i>	memberikan wawasan tentang perbedaan intensitas antara piksel-piksel dalam gambar
<i>Correlation</i>	memberikan wawasan tentang hubungan spasial antara intensitas piksel dalam citra
<i>Coarseness</i>	implikasi penting dalam identifikasi, analisis, dan pengobatan tumor otak

2.1.2 Data Preparation

Mempersiapkan *dataset*. Tahap awal melibatkan memuat dataset ke dalam lingkungan pemrograman seperti Python. Di sana, peneliti menggunakan *pandas* untuk mengimpor dan mengelola data. Setelah proses pengimporan selesai, langkah berikutnya adalah melakukan pemeriksaan terhadap *dataset* guna memastikan tidak ada nilai yang hilang atau anomali yang dapat mempengaruhi analisis. Jika ada fitur kategorikal, langkah selanjutnya adalah

mengubahnya menjadi format numerik agar dapat diproses oleh algoritma pembelajaran mesin. Untuk memastikan konsistensi dalam skala, biasanya dilakukan normalisasi atau standarisasi terhadap data numerik.

2.1.3 Pembagian *Dataset*

Dalam penelitian ini, *dataset* yang digunakan dipecah menjadi tiga bagian utama untuk tujuan analisis dan evaluasi. Pertama, *dataset* awal dimuat ke dalam lingkungan pemrograman seperti Python menggunakan library *pandas* untuk pengelolaan data. Setelah pemrosesan awal, *dataset* dibagi menjadi tiga subset dengan rasio 60:20:20. Set pelatihan (60%) digunakan untuk melatih berbagai model pembelajaran mesin yang dipertimbangkan dalam studi, seperti *Support Vector Machine* (SVM), *Random Forest*, dan *Neural Networks*. Setelah pelatihan, set training (20%) digunakan untuk mengoptimalkan *hyperparameter* dari masing-masing model dan meminimalkan *overfitting*. Proses ini membantu dalam menyesuaikan model agar dapat menggeneralisasi dengan baik pada data baru. Terakhir, set validasi (20%) digunakan untuk mengevaluasi kinerja akhir dari masing-masing model, memberikan ukuran yang andal tentang kemampuan prediksi dan klasifikasi model terhadap tumor otak. Dengan menggunakan pendekatan ini, penelitian bertujuan untuk menyediakan perbandingan yang komprehensif antara berbagai algoritma pembelajaran mesin dalam konteks klasifikasi tumor otak.

2.2 Model Machine Learning

Bagian ini menjelaskan penggunaan berbagai model pembelajaran mesin untuk melakukan klasifikasi biner pada *dataset Lung Cancer*. Model-model ini mencakup algoritma tradisional seperti *Support Vector Machines* (SVM), *Logistic Regression*, *k-Nearest Neighbours* (KNN), dan *Naive Bayes*, serta *Neural Network*. Evaluasi dilakukan terhadap setiap model untuk menilai kemampuannya dalam membedakan antara lalu lintas jaringan yang normal dan serangan.

2.2.1 K-Nearest Neighbor

K-Nearest Neighbor (KNN) adalah metode klasifikasi suatu objek berdasarkan data pembelajaran yang jaraknya paling dekat dengan objek tersebut. Metode ini bertujuan untuk mengklasifikasikan objek baru berdasarkan atribut dan *training sample*. Berikut tahapan pada KNN [11]

- Menentukan nilai K
- Menyiapkan *Data Training*
- Menyiapkan *Data Testing*
- Menghitung Jarak *Data Training*
- Mencari Nilai Terdekat sebanyak K
- Mencari label modus terbanyak.

Terhadap *Data Testing* dengan Menggunakan Rumus *Euclidean Distance*, dengan persamaan sebagai berikut :

$$d_{ij} = \sqrt{\sum_{k=1}^n (x_{ik} - x_{kj})^2} \quad (1)$$

2.2.2 Naive Bayes Classifier

Dengan menggunakan metode *naive bayes*, memunculkan peluang munculnya setiap kelas citra otak dan menghitung setiap peluang setiap fitur yang ada. Sehingga memunculkan nilai baru untuk menghitung tingkat akurasi datanya. Namun, untuk memaksimalkan penghitungannya, dioptimalkan dengan *laplace correction* yang berguna untuk menangani nilai probabilitas 0 (nol) dengan persamaan [8]

$$P_i = \frac{m_i + 1}{n + k} \quad (2)$$

2.2.3 Logistic Regresion

Probabilitas dapat diartikan sebagai pengetahuan akan seberapa besar kemungkinan sesuatu akan terjadi [9]. Dengan menggunakan nilai eksponensial dari nilai logit, nilai probabilitas keadaan pasien (misalnya, probabilitas keberadaan penyakit jantung) dapat dihitung [10]

$$P(X) = \frac{e^x}{1+e^x} \quad (3)$$

2.2.4 Support Vector Machine (SVM)


SVM adalah pengklasifikasi margin maksimum yang didefinisikan sebagai masalah optimasi seperti yang diberikan di bawah ini. Dengan vektor fitur x_i , vektor bobot w , dan label kelas y , SVM dapat dengan mudah diperluas ke masalah multi-kelas. Dalam praktiknya, pendekatan umum untuk klasifikasi multi-kelas adalah metode satu-lawan-semua dan metode satu-lawan-satu. Untuk tugas klasifikasi c -kelas, pendekatan pertama membutuhkan c pengklasifikasi SVM biner. Persyaratannya adalah $c(c-1)/2$ pengklasifikasi biner, ketika pendekatan yang terakhir diikuti. Penelitian yang diusulkan menggunakan model pengklasifikasi 3-kelas dengan tiga pengklasifikasi biner SVM, mengikuti pendekatan satu-lawan-semua [15].

$$F(X) = \text{sign} \left(\sum_{i=1}^n a_i y_i K(x_i, x) + b \right) \quad (4)$$

2.2.5 Neural Network

Neural Network 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 [16].

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 [16].



Gambar 2. Transfer Learning

2.2.6 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* (FN) (Wulandari et al., 2020). [12]

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

Gambar 3. *Confusion Matrix*

Presisi, perolehan, dan skor F1 merupakan metrik penting untuk mengevaluasi performa model klasifikasi. Berikut penjelasan singkat tentang cara setiap metrik dihitung. Presisi mengukur keakuratan prediksi positif yang dibuat oleh model. Ini dihitung sebagai rasio prediksi *true positive* (TP) terhadap jumlah total prediksi positif (*true positives* + *false positives* (FP)

$$Precision = \frac{TP}{TP + FP} \quad (5)$$

Penarikan kembali mengukur kemampuan model untuk mengidentifikasi semua kejadian positif dengan benar. Ini dihitung sebagai rasio prediksi *true positives* (TP) dengan jumlah total positif aktual (*true positives* + *false negatives* (FN).

$$Recall = \frac{TP}{TP + FN} \quad (6)$$

F1 Score adalah rata-rata harmonis antara presisi dan perolehan, memberikan metrik tunggal yang menyeimbangkan keduanya. Hal ini sangat berguna ketika distribusi kelas tidak seimbang.

$$F1\ Score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (7)$$

3. HASIL DAN PEMBAHASAN

3.1 *Accuracy Machine Learnings*

Kinerja model *Machine Learning* pada tugas klasifikasi biner untuk dataset Tumor Otak dirangkum dalam Tabel 2 berikut ini. Setiap model dievaluasi menggunakan metrik akurasi, presisi, recall, dan F1-Score untuk memberikan

gambaran yang lengkap tentang performa model. Akurasi mengukur proporsi prediksi yang benar dari semua prediksi yang dibuat oleh model, memberikan pandangan umum tentang seberapa sering model membuat keputusan yang tepat. Presisi mengukur proporsi prediksi positif yang benar dari semua prediksi positif yang dibuat oleh model, menunjukkan bahwa model memiliki sedikit prediksi positif palsu, yang penting dalam diagnosis penyakit serius di mana kesalahan positif dapat berdampak besar.

Recall mengukur proporsi kasus positif yang berhasil diidentifikasi dengan benar oleh model, yang sangat penting dalam deteksi kanker untuk menghindari melewatkan kasus positif yang penting. *F1-Score* adalah rata-rata harmonik dari presisi dan recall, memberikan evaluasi yang seimbang tentang kinerja model klasifikasi, terutama ketika menghadapi ketidakseimbangan kelas. Dengan menggabungkan kedua metrik tersebut, *F1-Score* memberikan gambaran yang lebih holistik tentang kinerja model dibandingkan hanya menggunakan presisi atau recall saja. Dengan akurasi tinggi dan presisi yang baik untuk kelas tumor otak, *Neural Network* efektif dalam mengidentifikasi tumor otak dengan sedikit kesalahan positif, sementara presisi untuk kelas normal menunjukkan potensi untuk ditingkatkan dalam membedakan kasus normal secara spesifik.

Tabel 3. Performa *Machine Learning* Klasifikasi Biner Kumpulan data Tumor Otak

Metrik	k-NN	Naïve Bayes	Logistic Regression	SVM	Neural Network
Precision (0)	0.97	0.95	0.98	0.98	0.98
Precision (1)	0.99	0.99	0.99	0.99	1.00
Recall (0)	1.00	0.99	0.99	0.99	0.98
Recall (1)	0.96	0.94	0.97	0.97	0.99
F1-Score (0)	0.98	0.97	0.98	0.98	0.99
F1-Score (1)	0.98	0.96	0.98	0.98	0.99
Accuracy	0.98	0.97	0.98	0.98	0.99
Macro Avg (P)	0.98	0.97	0.98	0.98	0.99
Macro Avg (R)	0.98	0.96	0.98	0.98	0.99
Macro Avg (F1)	0.98	0.97	0.98	0.98	0.99
Weighted Avg (P)	0.98	0.97	0.98	0.98	0.99
Weighted Avg (R)	0.98	0.97	0.98	0.98	0.99
Weighted Avg (F1)	0.98	0.97	0.98	0.98	0.99
Support (0)	407	407	407	407	407
Support (1)	346	346	346	346	346

3.2 Hasil *Hyperparameter Tuning of The Neural Network*


Selama proses penyetelan *hyperparameter* untuk Jaringan Neural, berbagai konfigurasi diuji untuk menemukan kombinasi parameter yang memberikan kinerja optimal. Konfigurasi yang diuji meliputi variasi dalam jumlah node, tingkat dropout, tingkat pembelajaran, dan ukuran batch. Hasil dari percobaan ini disajikan dalam Tabel 4.

Tabel 4. Penyetelan konfigurasi *Hyperparameter* pada data Tumor Otak

<i>Nodes</i>	<i>Dropout</i>	<i>Learning Rate</i>	<i>Batch Size</i>	<i>Loss</i>
16	0	0.01	32	0.047
			64	0.049
			128	0.052
		0.005	32	0.048
			64	0.050
			128	0.050
		0.001	32	0.048
			64	0.050
			128	0.054
		0.01	32	0.049
			64	0.048
			128	0.050
	0.2	0.005	32	0.048
			64	0.049
			128	0.051
		0.001	32	0.050
			64	0.048
			128	0.053
		0.01	32	0.048
			64	0.048
			128	0.050
	0	0.005	32	0.049
			64	0.050
			128	0.050
		0.001	32	0.049
			64	0.048
			128	0.050
32	0.2	0.01	32	0.046
			64	0.049
			128	0.049
		0.005	32	0.047
			64	0.045
			128	0.049
		0.001	32	0.046
			64	0.048
			128	0.049
	0	0.01	32	0.045
			64	0.048
			128	0.049
		0.005	32	0.043
			64	0.048
			128	0.048

0.2	0.001	32	0.046
		64	0.050
		128	0.049
	0.01	32	0.044
		64	0.049
		128	0.049
	0.005	32	0.047
		64	0.048
		128	0.049
	0.001	32	0.045
		64	0.048
		128	0.048

Grafik pada Gambar 4 menunjukkan dua grafik yang digunakan untuk memantau kinerja model *machine learning* selama proses pelatihan grafik akurasi model (*Model accuracy*) di sebelah kiri dan grafik kehilangan model (*Model loss*) di sebelah kanan. Berikut penjelasan masing-masing grafik



Gambar 4. Grafik Tuning Hyperparameter Neural Network

Model Accuracy (Akurasi Model), Sumbu Y (Akurasi) Menunjukkan tingkat akurasi model, yaitu persentase prediksi yang benar dari total prediksi. Sumbu X (Epoch) Menunjukkan jumlah epoch atau iterasi pelatihan. Setiap epoch mewakili satu putaran penuh melalui seluruh dataset pelatihan. Garis Biru (*Train*) Menunjukkan akurasi model pada data pelatihan selama epoch berturut-turut. Garis Oranye (*Validation*): Menunjukkan akurasi model pada data validasi selama epoch berturut-turut. Interpretasi, Akurasi pelatihan (biru) meningkat dengan cepat pada awalnya dan mencapai tingkat tinggi, mendekati 98-99%. Akurasi validasi (oranye) juga meningkat, tetapi menunjukkan sedikit fluktuasi, dan mencapai tingkat stabil sekitar 97-98%. Ini menunjukkan bahwa model belajar dengan baik dari data pelatihan dan mempertahankan performa yang baik pada data yang tidak terlihat selama pelatihan (data validasi).

Model Loss (Kehilangan Model), Sumbu Y (*Loss*) Menunjukkan nilai fungsi kehilangan (*loss*), yang mengukur seberapa baik prediksi model dibandingkan dengan nilai sebenarnya. Nilai *loss* yang lebih rendah menunjukkan model yang lebih baik. Sumbu X (Epoch) Menunjukkan jumlah epoch atau iterasi pelatihan. Garis Biru (*Train*) Menunjukkan nilai *loss* model pada data pelatihan selama epoch berturut-turut. Garis Oranye (*Validation*) Menunjukkan nilai *loss* model pada data validasi selama epoch berturut-turut. Interpretasi Nilai *loss* pelatihan (biru) menurun dengan cepat pada awal pelatihan dan kemudian stabil pada nilai yang sangat rendah, menunjukkan bahwa model semakin baik dalam memprediksi data pelatihan. Nilai *loss* validasi (oranye) juga menurun tetapi sedikit lebih tinggi daripada nilai *loss* pelatihan, menunjukkan sedikit perbedaan performa antara data pelatihan dan validasi, yang normal. Namun, perbedaan yang kecil ini menunjukkan bahwa model tidak mengalami *overfitting* yang signifikan. Secara keseluruhan, grafik-grafik ini menunjukkan bahwa model yang dilatih memiliki kinerja yang baik, dengan akurasi tinggi dan nilai *loss* yang rendah pada data pelatihan dan validasi. Secara keseluruhan, keunggulan *neural network* dalam menangkap pola *non-linear* yang kompleks, ketahanan terhadap noise, kapasitas belajar dari data besar, dan fleksibilitas dalam *tuning hyperparameter* membuatnya lebih unggul dibandingkan algoritma tradisional.

dalam klasifikasi tumor otak. Hal ini menunjukkan bahwa *neural network* adalah pilihan yang lebih sesuai untuk aplikasi berbasis gambar medis seperti MRI, di mana detail halus dan variasi pola adalah kunci untuk diagnosis yang akurat.

4. KESIMPULAN

Hasil evaluasi model menunjukkan bahwa *Neural Network* dan *K-Nearest Neighbors* (k-NN) adalah algoritma terbaik untuk memprediksi kanker paru-paru, dengan tingkat akurasi mencapai 0.99. Kedua algoritma ini juga menunjukkan presisi tertinggi untuk kelas tumor otak, mencapai 0.99, yang menunjukkan kemampuan luar biasa dalam mendeteksi kasus tumor otak dengan akurat. Selain itu, *Neural Network* memiliki presisi tertinggi untuk kelas normal dengan nilai 0.99, sedangkan *K-Nearest Neighbors* (k-NN), meskipun memiliki akurasi yang baik (0.95), menunjukkan presisi yang sedikit lebih rendah untuk kelas normal (0.97). Secara keseluruhan, *Neural Network* juga mencatat *recall* tertinggi untuk kelas kanker paru-paru dengan nilai 0.98, menunjukkan kemampuannya dalam mendeteksi sebagian besar kasus tumor otak. Sebaliknya, *Naïve Bayes* memiliki *recall* terendah untuk kelas yang sama dengan nilai 0.94. Evaluasi ini menggambarkan variasi dalam kinerja antar algoritma dalam prediksi tumor otak, memberikan wawasan penting untuk aplikasi klinis dan penelitian. Temuan ini dapat membantu dalam memilih algoritma yang paling sesuai dengan kebutuhan spesifik dalam meningkatkan deteksi tumor otak, manajemen penyakit, dan perawatan yang efektif bagi pasien tumor otak. Secara ilmiah, penelitian ini memberikan kontribusi dalam memahami performa berbagai algoritma pembelajaran mesin pada data gambar medis yang kompleks, khususnya MRI tumor otak. Temuan ini dapat menjadi acuan bagi peneliti lain untuk memilih algoritma yang tepat sesuai dengan karakteristik data yang dimiliki. Dari sisi klinis, penelitian ini memberikan dasar kuat bagi pengembangan alat bantu diagnostik berbasis kecerdasan buatan yang dapat meningkatkan akurasi diagnosis, mengurangi kesalahan, dan mempercepat proses deteksi dini tumor otak, yang sangat penting untuk keberhasilan penanganan medis. Saran untuk penelitian lebih lanjut: penggunaan dataset yang lebih besar dan beragam. Penelitian lebih lanjut sebaiknya menggunakan *dataset* yang lebih besar dan beragam, termasuk gambar dari berbagai jenis tumor otak dan dari populasi yang berbeda, untuk meningkatkan generalisasi model dan memperkuat akurasi diagnostik dalam lingkungan klinis yang lebih luas. Dengan berbagai pengembangan ini, diharapkan teknologi klasifikasi tumor otak berbasis pembelajaran mesin dapat semakin matang dan siap untuk diimplementasikan secara luas dalam dunia medis, memberikan manfaat nyata bagi pasien dan mendukung kemajuan di bidang radiologi serta onkologi.

DAFTAR PUSTAKA

- [1] R. D. Anggraini, "CLASSIFICATION OF CANCER TYPES BASED ON TUMOR SIGNATURE DNA USING XGBOOST METHOD," 2021.
- [2] A. Ratnasari, "Klasifikasi Citra Tumor Otak Menggunakan Gaussian Model Berbasis Machine Learning Berdasarkan MRI Dataset Article Info ABSTRAK," *JSAI: Journal Scientific and Applied Informatics*, vol. 7, no. 2, hlm. 203–207, 2024, doi: 10.36085.
- [3] K. N. Qodri, "Analisis Perbandingan Klasifikasi Tumor Otak Menggunakan Deep Learning," *INDONESIAN JOURNAL OF INFORMATION TECHNOLOGY*, vol. 2, no. 1, hlm. 1–6, 2024, doi: <https://doi.org/10.25077/>.
- [4] F. Citra R, F. Indriyani, dan I. R. Rahadjeng, "Klasifikasi Tumor Otak Berbasis Magnetic Resonance Imaging Menggunakan Algoritma Convolutional Neural Network," *Digital Transformation Technology*, vol. 3, no. 2, hlm. 918–924, Jan 2024, doi: 10.47709/digitech.v3i2.3469.
- [5] B. S. E. Dwi dan D. R. I. M. Setiadi, "Deteksi Tumor Otak dengan Metode Convolutional Neural Network," *JURNAL EKSPLORA INFORMATIKA*, hlm. 188–197, 2023, doi: 10.30864/eksplora.v13i2.971.
- [6] S. Y. Prasetyo dan G. Z. Nabiilah, "PERBANDINGAN MODEL MACHINE LEARNING PADA KLASIFIKASI TUMOR OTAK MENGGUNAKAN FITUR DISCRETE COSINE TRANSFORM," *Jurnal Teknologi Terpadu*, vol. 9, no. 1, hlm. 29–34, 2023.
- [7] V. B. Gianzurriell, F. Husnal, F. A. Wijaya, F. Fauzi, I. Paryudi, dan I. Veritawati, "Analisis Gambar MRI Otak Untuk Mendeteksi Tumor Otak Menggunakan Algoritma CNN," *Journal of Informatics and Advanced Computing (JIAC)*, vol. 4, no. 2, hlm. 14–18, 2023.

- [8] F. Akbar, A. N. Rais, I. A. Sobari, R. A. Zuama, dan B. Rudiarto, "Analisis Performa Algoritma Naive Bayes Pada Deteksi Otomatis Citra Mri," *JITK (Jurnal Ilmu Pengetahuan dan Teknologi Komputer)*, vol. 5, no. 1, hlm. 37–42, Agu 2019, doi: 10.33480/jitk.v5i1.586.
- [9] N. Puspitasari, K. Nugroho, dan K. Hadiono, "Usability of Brain Tumor Detection Using the DNN (Deep Neural Network) Method Based on Medical Image on DICOM," *CESS (Journal of Computer Engineering, System and Science)*, vol. 8, no. 2, hlm. 619, 2023, doi: 10.24114/cess.v8i2.48727.
- [10] D. K. Saputro, M. F. R. Ajie, S. Azizah, dan D. Hartanti, "Penerapan Logistic Regression untuk Mendeteksi Penyakit Jantung pada Pasien," *Prosiding Seminar Nasional Teknologi Informasi dan Bisnis (SENATIB)*, hlm. 666–671, 2023.
- [11] J. Sofian dan R. H. Laluma, "KLASIFIKASI HASIL CITRA MRI OTAK UNTUK MEMPREDIKSI JENIS TUMOR OTAK DENGAN METODE IMAGE THRESHOLD DAN GLCM MENGGUNAKAN ALGORITMA K-NN (NEAREST NEIGHBOR) CLASSIFIER BERBASIS WEB," *Jurnal Infotronik*, vol. 4, no. 2, hlm. 51–56, 2019.
- [12] F. Citra R, F. Indriyani, dan I. R. Rahadjeng, "Klasifikasi Tumor Otak Berbasis Magnetic Resonance Imaging Menggunakan Algoritma Convolutional Neural Network," *Digital Transformation Technology*, vol. 3, no. 2, hlm. 918–924, Jan 2024, doi: 10.47709/digitech.v3i2.3469.
- [13] P. Laksono dan T. Prabowo, "Deteksi Tumor Otak Melalui Penerapan GLCM dan Naïve Bayes Classification Brain Tumor Detection Based On GLCM Algorithm and Naïve Bayes Classification," *Jurnal Ilmiah Intech: Information Technology Journal of UMUS*, vol. 41, no. 48, hlm. 41–48, 2023.
- [14] R. Andre, B. Wahyu, dan R. Purbaningtyas, "KLASIFIKASI TUMOR OTAK MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK DENGAN ARSITEKTUR EFFICIENTNET-B3," 2021. [Daring]. Tersedia pada: <https://jurnal.umj.ac.id/index.php/just-it/index>
- [15] I. Maulana, A. Mutoi Siregar, dan A. Fauzi, "OPTIMIZATION OF MACHINE LEARNING MODEL ACCURACY FOR BRAIN TUMOR CLASSIFICATION WITH PRINCIPAL COMPONENT ANALYSIS," *Jurnal Teknik Informatika (JUTIF)*, vol. 5, no. 3, hlm. 903–915, 2024, doi: 10.52436/1.jutif.2024.5.3.2058.
- [16] N. Pratama dkk., "Perbandingan Model Klasifikasi Transfer Learning Convolutional Neural Network Tumor Otak Menggunakan Citra Magnetic Resonance Imaging," *Jurnal Sehat Indonesia*, vol. 6, no. 1, 2024.