



PERBANDINGAN MODEL *MACHINE LEARNING* PADA KLASIFIKASI TUMOR OTAK MENGGUNAKAN FITUR *DISCRETE COSINE TRANSFORM*

Simeon Yuda Prasetyo¹, Ghinaa Zain Nabiilah²

^{1,2} School of Computer Science, Universitas Bina Nusantara
Jakarta Barat, DKI Jakarta, Indonesia 11480

simeon.prasetyo@binus.ac.id, ghinaa.nabiilah@binus.ac.id

Abstract

Brain tumors are abnormal tissue growths characterized by excessive cell growth in certain brain parts. One of the reliable techniques currently available to identify brain tumors is using Magnetic Resonance Imaging (MRI) scans. The scanned MRI images are monitored and examined for tumor detection by a specialist. Developing more effective and efficient tools to help medical professionals identify brain tumors is urgent as the number of people suffering from brain tumors soars, and the death rate will reach 18,600 in 2021. In previous research, machine learning-based models demonstrated the ability to detect brain tumors with a classification accuracy of 92%, and this result is reliable. We computationally tested several hyperparameters using publicly available MRI datasets to obtain the most reliable binary classification accuracy in MRI brain images. A high level of model accuracy is achieved by testing various existing machine-learning model architectures and inserting a feature map extracted from the Discrete Cosine Transform (DCT). Classification of MRI images achieved the highest accuracy on test data at 93% using the Support Vector Machine (SVM) model.

Keywords: Binary Classification, Brain Tumor, DCT, Machine Learning, SVM

Abstrak

Tumor otak adalah pertumbuhan jaringan abnormal yang ditandai dengan pertumbuhan sel yang berlebihan di bagian otak tertentu. Salah satu teknik andal saat ini yang tersedia untuk mengidentifikasi tumor otak adalah penggunaan pemindaian *Magnetic Resonance Imaging* (MRI). Gambar MRI yang dipindai dipantau dan diperiksa untuk deteksi tumor oleh dokter spesialis. Mengembangkan alat yang lebih efektif dan efisien untuk membantu profesional medis mengidentifikasi tumor otak dirasa cukup mendesak karena jumlah orang yang menderita tumor otak melonjak dan tingkat kematian yang mencapai 18.600 pada tahun 2021. Dalam penelitian sebelumnya, model berbasis pembelajaran mesin mampu menunjukkan kemampuan untuk mendeteksi tumor otak dengan akurasi klasifikasi 92% dan hal hasil ini dapat diandalkan. Untuk mendapatkan akurasi klasifikasi biner yang paling andal dalam gambar otak MRI, kami menguji secara komputasi beberapa *hyperparameter* menggunakan kumpulan data MRI yang tersedia untuk umum. Tingkat akurasi model yang tinggi dicapai dengan menguji berbagai arsitektur model *machine learning* yang ada, diikuti dengan memasukkan *feature map* yang diekstraksi dari *Discrete Cosine Transform* (DCT). Klasifikasi gambar MRI mencapai akurasi pada data *test* tertinggi sebesar 93% dengan menggunakan model *Support Vector Machine* (SVM).

Kata kunci: DCT, Klasifikasi Biner, *Machine Learning*, SVM, Tumor Otak

1. PENDAHULUAN

Tumor adalah sel yang tumbuh secara tidak normal (proliferasi sel berlebihan) di bagian tubuh tertentu. Tumor adalah jaringan abnormal yang dapat berbentuk padat ataupun cair[1].

Menurut SEER (2021), kasus kanker dan tumor otak diperkirakan 24.530 kasus baru pada tahun 2021. Kematian akibat kanker otak mencapai 18.600. Selain itu, angka

harapan hidup bagi mereka yang terkena penyakit ini adalah 32,6% dalam 5 tahun[2].

Mengidentifikasi adanya tumor otak bukanlah hal yang mudah karena gejala yang dialami oleh penderita tumor otak dapat menyebabkan gangguan kejiwaan seperti kecemasan dan depresi [3]. Oleh karena itu, gangguan kejiwaan biasanya terdiagnosis ketika pasien memiliki tumor otak. Secara umum dalam diagnostik tumor otak, sebagian dari tumor otak pertama kali dideteksi menggunakan *magnetic*

resonance imaging (MRI) yang merupakan teknologi andal saat ini. 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.

Penelitian sebelumnya [4] menggunakan teknik pengolahan citra biner dan morfologi citra. Klasifikasi tumor diterapkan setelah segmentasi dilakukan dengan proses ekstraksi ciri bentuk. Hasil klasifikasi tumor yang dicapai adalah 89,5%, yang dapat memberikan informasi yang lebih jelas dan spesifik untuk deteksi tumor. Hasil ini diperoleh dengan menggunakan klasifikasi *K-Nearest Neighbor*. Studi lain dalam proses klasifikasi [5] menganalisis sifat statistik dari gambar masukan, mengklasifikasikan data secara sistematis ke dalam kategori yang berbeda, dan kemudian membandingkan tiga algoritma klasifikasi: JST, *random forest*, dan SVM. Menggunakan SVM memberikan akurasi terbaik yakni 90%.

Di sisi lain, percobaan [6] membandingkan dua algoritma yang berbeda untuk fase segmentasi: segmentasi *U-network* dan segmentasi berbasis CNN. Di sisi lain, tumor *grading* membandingkan algoritma VGG-16 dan CNN. Berdasarkan percobaan yang dilakukan untuk hasil terbaik menggunakan segmentasi U-Net, algoritma deteksi tumor menggunakan *random forest classifier*, dan tumor *grading level* menggunakan algoritma VGG-16. Eksperimen ini menggunakan spektroskop MR dan *dataset* FLAIR berhasil mencapai akurasi eksperimen tertinggi sebesar 92%.

Studi lain mengklasifikasikan citra otak MRI menjadi tiga kelas tumor: glioma, meningioma, dan hipofisis. Algoritma untuk mengekstrak peta fitur tingkat tinggi dari model berbasis VGG16 menggunakan Fast R-CNN sebagai pengklasifikasi. Studi ini mencapai akurasi rata-rata 77,6% di semua kelas [7]

Ayesha Samreen, dkk [8] juga melakukan penelitian terkait dengan klasifikasi citra otak MRI. *Dataset* yang digunakan senada dengan *dataset* pada penelitian ini yaitu berasal dari *kaggle* dan mengklasifikasikan citra menjadi dua jenis, yaitu tumor otak dan normal. Akurasi optimalnya adalah menggunakan CNN dengan hasil akurasi 0.9290.

Selain itu, penggunaan CNN untuk mengklasifikasi citra otak MRI, juga dilakukan oleh Nyoman Abiwinanda, dkk [9]. Penelitian ini menggunakan CNN untuk mengenali tiga

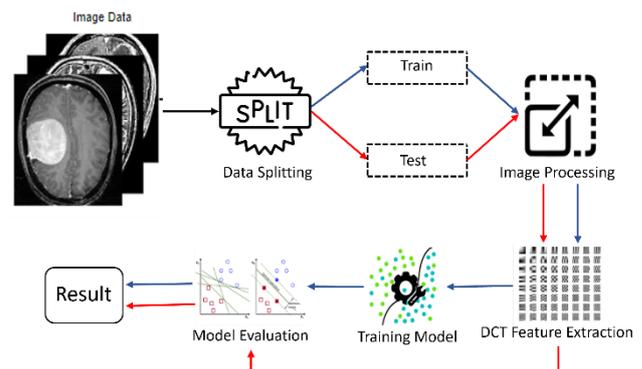
jenis tumor otak, yaitu Glioma, Meningioma, dan Pituitari. Hasil optimal penelitian ini adalah dengan nilai akurasi 84.19% pada data validasi.

Ekstraksi fitur DCT digunakan dalam penelitian ini karena masih sedikit penelitian yang memanfaatkan fitur DCT ini, sehingga masih perlu dilakukan eksplorasi lebih lanjut, terutama pada tugas klasifikasi tumor otak. DCT mencari koefisien yang memiliki kemampuan lebih untuk membedakan kelas yang berbeda secara lebih baik daripada koefisien lainnya. Selain itu, DCT juga memiliki rentang koefisien yang luas [10].

Penelitian ini bertujuan untuk mengembangkan alat diagnostik tumor otak berbasis citra MRI menggunakan ekstraksi ciri bentuk *Discrete Cosine Transform* (DCT) yang merupakan algoritma kompresi sinyal, dan melakukan pengujian beberapa model *machine learning* pada beberapa ukuran citra untuk mendapatkan model klasifikasi yang terbaik. Hasil akhir dari penelitian ini adalah penyajian matriks konfusi dari model terbaik yang dibangun dan hasil berupa persentase akurasi pengujian.

2. METODE PENELITIAN

Gambar 1 menyajikan Tahapan penelitian yang digunakan dalam penelitian ini.



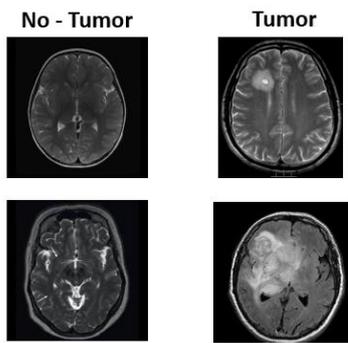
Gambar 1. Tahapan Penelitian

Penjelasan dari proses Tahapan Penelitian dari Gambar 1 yakni:

2.1 Pengumpulan Data

Pada tahap pengumpulan data ini dilakukan pencarian *dataset* yang relevan terhadap penelitian ini. *Dataset* yang dikumpulkan merupakan data citra MRI tumor otak yang terdapat label berupa adanya tumor ataupun tidak ada tumor.

Pada tahapan ini menggunakan *dataset* yang berisikan citra MRI tumor otak yang dapat diakses melalui situs *kaggle* [11] dengan *dataset* bernama *BraTS* 2019. Pada *dataset* ini terdapat citra dengan jumlah total 3000 citra MRI otak, di mana 1500 citra merupakan citra MRI dengan tumor dan 1500 citra lainnya merupakan citra MRI yang tidak terdapat tumor. Beberapa contoh citra dari *dataset BraTS* 2019 dapat dilihat pada Gambar 2.



Gambar 2. Contoh Dataset BraTS 2019

Gambar 2 berisi contoh *dataset* yang berisi citra MRI yang termasuk tumor dan bukan tumor. Karakteristik dari data yang termasuk tumor terdapat area lesi sebagai ilustrasi dari tumor, seperti terlihat pada Gambar 2 bagian kanan. Sedangkan untuk kondisi normal yang bukan tumor terlihat pada Gambar 2 bagian kiri.

2.2 Pembagian Data

Data dilakukan pembagian menjadi 2 bagian secara merata untuk proses *training* dan testing atau pengujian. Data dibagi menjadi data *training* sejumlah 2800 data (1400 citra MRI dengan tumor, dan 1400 Citra MRI tanpa tumor) dan 200 data untuk testing (100 merupakan citra MRI dengan tumor, dan 100 merupakan citra MRI otak tanpa tumor).

2.3 Pra-Pemrosesan Data

Pada tahapan ini citra diubah menjadi aras keabuan (*single channel color*) yang mana semula citra memiliki 3 *channel* RGB. Selanjutnya, pada tahapan pra pemrosesan ini juga melakukan perubahan citra yang semula memiliki ukuran yang tidak sama menjadi berukuran 150x150 piksel ataupun 224 x 224 *pixel* (ukuran piksel ini nantinya juga akan dibandingkan).

2.4 Ekstraksi Fitur DCT

Pada klasifikasi citra memerlukan pemrosesan ekstraksi fitur untuk dapat mengubah citra yang semula memiliki fitur sangat banyak dan tidak memiliki signifikansi yang tinggi (memiliki korelasi yang rendah terhadap *output*) menjadi fitur yang lebih ringkas namun berarti atau tingkat signifikansi yang lebih tinggi. Dalam penelitian ini, DCT (*Discrete Cosine Transform*) digunakan sebagai ekstraksi fitur dari citra MRI tumor otak yang ada.

Algoritma DCT (*Discrete Cosine Transform*) merupakan algoritma yang biasa digunakan dalam kompresi sinyal (gambar merupakan salah satu bentuk dari sinyal digital). Algoritma ini melakukan perubahan data spasial menjadi bentuk frekuensi, kemudian dilakukan pengolahan data frekuensi yang kemudian dikonversi ke bentuk spasial kembali dengan inversi metode tersebut. Di mana, domain frekuensi merupakan sinyal yang memiliki wujud berupa amplitudo terhadap waktu (spektrum terhadap suatu sinyal waktu), domain frekuensi merujuk pada sinyal yang

berhubungan dengan frekuensi dalam suatu waktu. Sedangkan, domain spasial merujuk pada dasar pada manipulasi piksel secara langsung pada citra [12] [13]

Discrete cosine transform dirumuskan seperti pada persamaan (1).

$$v(k) = \alpha(k) \sum_{n=0}^{N-1} U(n) \cdot \text{Cos} \left[\frac{\pi(2n+1)k}{2N} \right] \quad (1)$$

$$\text{Untuk } 0 \leq k \leq N - 1$$

$$a(w) \left\{ \begin{array}{l} \sqrt{\frac{1}{N}} \text{ untuk } w = 0 \\ \sqrt{\frac{2}{N}} \text{ untuk lainnya} \end{array} \right\}$$

Di mana $v(k)$ merupakan hasil ekstraksi fitur DCT, dengan k yang menyatakan indeks baris atau kolom hasil ekstraksi. N merupakan ukuran baris atau kolom blok citra yang hendak dilakukan ekstraksi fitur DCT. Sedangkan $U(n)$ menyatakan blok citra dengan aras keabuan.

Pada ekstraksi fitur DCT biasanya dapat dilakukan dengan sejumlah tahapan. Tahap pertama adalah mendapatkan citra atau gambar sebagai matriks warna citra (biasanya, perhitungan matriks pada satu komponen warna baik *red* atau *green* atau *blue* ataupun citra keabuan $[red+green+blue] / 3$). Selanjutnya, citra dibagi ke dalam blok berukuran 8 x 8 piksel, urut dari ujung kiri ke kanan, dan dari atas ke bawah.

2.5 Pembentukan Model Machine Learning

Dalam penelitian ini terdapat beberapa model yang akan digunakan untuk diuji dan dipilih berdasarkan akurasi *test* terbaiknya. Beberapa model klasifikasi yang akan digunakan antara lain :

- *Naive Bayes*

Naive Bayes merupakan salah satu algoritma yang biasa digunakan untuk tugas klasifikasi, baik klasifikasi citra ataupun teks. *Naive Bayes* menggunakan pendekatan *probabilistic* yang menggunakan teorema probabilitas *bayes*. Algoritma *Naive Bayes* membuat asumsi kemunculan fitur yang tidak saling bergantung. Sehingga cocok digunakan untuk mendeteksi tumor otak dari berbagai lokasi berbeda dengan fitur berbeda [14]. Penelitian ini menggunakan *Gaussian Naive Bayes*, pada persamaan 2 merupakan bentuk rumus dari *Gaussian Naive Bayes*.

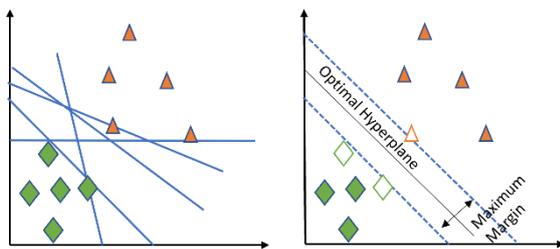
$$P(x_i|y) = \frac{1}{\sqrt{2\pi\sigma^2y}} \exp \left(-\frac{(x_i-\mu_y)^2}{2\sigma^2y} \right) \quad (2)$$

- *Decision Tree*

Decision Tree adalah salah satu metode yang biasanya digunakan dalam berbagai bidang, seperti klasifikasi citra, pengenalan pola, regresi, dan

klasifikasi teks. Algoritma *Decision Tree* bekerja dengan menggunakan beberapa aturan untuk membuat keputusan yang terstruktur seperti pohon [15].

- *K-Nearest Neighbor* (KNN)
KNN merupakan algoritma klasifikasi yang bekerja dengan menggunakan sejumlah nilai k tetangga atau data terdekat [16]. Perhitungan jarak tetangga terdekat dapat dihitung berdasarkan rumus *Euclidean distance*, *Manhattan distance*, atau *Minkowsky distance*. Algoritma ini bekerja berdasarkan kedekatan atau kemiripan terhadap data lainnya. Jumlah K pada KNN bisa ditentukan sesuai kebutuhan. Pada penelitian ini jumlah K yang digunakan adalah 1, 3, dan 5.
- *Support Vector Machine* (SVM)
SVM adalah salah satu algoritma *supervised learning* yang digunakan untuk klasifikasi ataupun regresi. Cara kerja SVM adalah dengan mencari *hyperplane* atau fungsi pemisah antar kelas terbaik dan memaksimalkan jarak antar kelas [17]. SVM digunakan untuk memaksimalkan margin dalam mencari *hyperplane* yang optimal. Gambar 3 berisi ilustrasi untuk mencari *hyperplane* optimal.



Gambar 3. Ilustrasi Optimal *Hyperplane* SVM

2.6 Evaluasi Model

Pada tahapan evaluasi model, dilakukan perhitungan menggunakan *Confusion Matrix* untuk memperoleh nilai Akurasi, Presisi, *Recall*, dan *F1 Score*. Perhitungan dalam *Confusion Matrix* memperhatikan nilai *true positive* (TP), *true negative* (TN), *false positive* (FP) dan *false negative* (FN).

Akurasi menggambarkan persentase seluruh data yang diklasifikasikan benar pada kelas positif dan negatif. Sehingga proses perhitungan yang dilakukan adalah dengan membagi seluruh data prediksi yang bernilai benar dengan seluruh data yang tersedia. Sehingga jika dirumuskan akan menjadi persamaan (3).

$$Accuracy = \frac{(TP+TN)}{(TP+TN+FN+FP)} \quad (3)$$

Di mana seluruh nilai pada persamaan tersebut bisa dilihat berdasarkan *confusion matrix* untuk memperoleh nilai pada setiap bagian [18]

Precision menggambarkan seberapa tepat atau akurat model yang dibuat. Dengan mengukur prediksi positif (berapa banyak yang benar-benar positif). Sehingga *precision* dapat dirumuskan dalam persamaan (4).

$$Precision = \frac{(TP)}{(TP+FP)} \quad (4)$$

Recall atau *sensitivity* menggambarkan berapa banyak *Actual Positive* yang diprediksi oleh model dengan pelabelan sebenarnya adalah positif. Sehingga *recall* dapat dirumuskan seperti persamaan (5).

$$Recall = \frac{(TP)}{(TP+FN)} \quad (5)$$

F1-score merupakan metrik yang mempertimbangkan keseimbangan rerata secara harmonik antara *precision* dan *recall*. Pada *f1-score* nilai negatif aktual (*true negative*) diabaikan. Metrik ini menggambarkan kekokohan tugas dalam klasifikasi [18]. *F1 score* dapat dirumuskan seperti persamaan (6).

$$F1 - Score = \frac{(2 \times Precision \times Recall)}{(Precision + Recall)} \quad (6)$$

3 HASIL DAN PEMBAHASAN

Dalam penelitian ini evaluasi kinerja model diuji coba di lingkungan Python Google Colab Pro yang dipercepat oleh Unit Pemrosesan Grafis (GPU) dan RAM 25 GB. Menggunakan ekstraksi fitur DCT yang dilanjutkan dengan klasifikasi menggunakan beberapa model menunjukkan hasil yang cukup baik, bahkan terdapat hasil yang sedikit lebih baik dari penelitian sebelumnya yang menggunakan pendekatan *deep learning*.

Percobaan ini dilakukan penentuan parameter untuk sejumlah algoritma. Pada SVM menggunakan *kernel* RBF dengan derajat 3 dengan perhitungan γ seperti pada persamaan (7).

$$\gamma = \frac{1}{(n \text{ features} * X.var())} \quad (7)$$

Sedangkan pada *Decision Tree* menggunakan *Gini index* untuk penentuan *split* kemudian batas *node* diperluas sampai seluruh *leaf* pada *tree* menjadi murni.

Pada *Naive Bayes* perhitungan probabilitas menggunakan pendekatan distribusi normal (*Gaussian*). Sedangkan pada KNN, jarak yang digunakan merupakan jarak *euclidean* dengan jumlah *neighbor* yang diuji adalah 1, 3 dan 5.

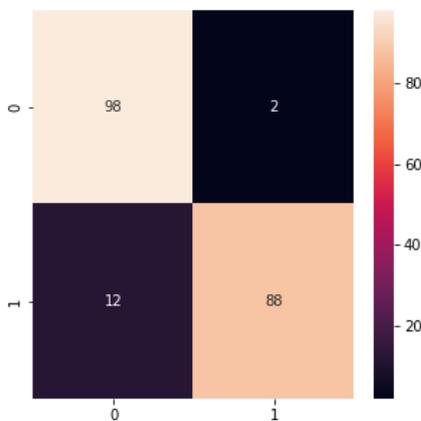
Hasil eksperimen deteksi atau klasifikasi biner tumor otak dengan menggunakan ekstraksi DCT dan klasifikasi *machine learning* dapat dilihat pada tabel 1.

Tabel 1. Hasil Percobaan Model

Model	150 x 150 px		224 x 224 px	
	Training	Testing	Training	Testing
SVM	97.464 %	90.5 %	97.785 %	93.0 %
Tree	100.0 %	79.5 %	100.0 %	83.5 %
Bayes	69.142 %	55.0 %	70.0 %	55.5 %
KNN-1	100.0 %	91.0 %	100.0 %	91.0 %
KNN-3	98.107 %	83.5 %	98.464 %	84.5 %
KNN-5	94.214 %	81.0 %	94.285 %	78.5 %

Berdasarkan hasil pada tabel di atas diketahui bahwa model konfigurasi terbaik diperoleh oleh model SVM dengan ukuran citra 224 x 224 piksel. Pada model tersebut berhasil mendapatkan akurasi *training* sebesar 97.8% dan akurasi *testing* sebesar 93%.

Berdasarkan konfigurasi model terbaik yang dibentuk tersebut mendapatkan *confusion matrix* yang tersaji pada Gambar 4.



Gambar 4. Confusion Matrix

Confusion matrix yang ditampilkan pada Gambar 4, sebelah kiri atas merupakan *True Negative* (TN) sejumlah 98, sebelah kanan atas merupakan *False Positive* (FP) sejumlah 2, sebelah kiri bawah merupakan *False Negative* (FN) sejumlah 12, dan sebelah kanan bawah merupakan *True Positive* (TP) sejumlah 88. Di mana pada sumbu X dan Y terdapat angka nol dan satu, nol merupakan kelas *no-tumor* dan satu merupakan kelas tumor.

Sedangkan hasil perhitungan akurasi berdasarkan nilai *precision*, *recall*, dan *F1 Score* terdapat pada Gambar 5.

	precision	recall	f1-score	support
0	0.89	0.98	0.93	100
1	0.98	0.88	0.93	100
accuracy			0.93	200
macro avg	0.93	0.93	0.93	200
weighted avg	0.93	0.93	0.93	200

Gambar 5. Hasil Perhitungan Evaluasi

Gambar 5 menunjukkan nilai *precision*, *recall*, dan *f1 score* pada metode dengan akurasi *testing* terbaik, yaitu SVM. Dalam gambar tersebut terdapat hasil klasifikasi model pada setiap kelas, yaitu 0 dan 1. Kelas 0 menunjukkan klasifikasi bukan tumor, sedangkan 1 menunjukkan klasifikasi tumor. Sedangkan untuk nilai *F1 Score* dihitung berdasarkan *macro average*. *Macro average* akan menghitung metrik secara independen untuk setiap kelas lalu kemudian mengambil nilai rata-rata. Pada perhitungan *Macro average* semua kelas dihitung secara merata.

4 KESIMPULAN

Telah ditunjukkan bahwa dengan menerapkan ekstraksi fitur menggunakan *Discrete Cosine Transform* (DCT) untuk memperoleh *feature map* dan menggunakan model – model *machine learning* menunjukkan bahwa skor akurasi tertinggi pada data *test* mendapatkan nilai hingga 93%. Akurasi *test* 93% ini didapatkan melalui model SVM (*support vector machine*) dengan ukuran citra sebesar 224 x 224 piksel.

Saran untuk perbaikan model agar ke depannya dapat dioptimalkan dengan mencari *hyperparameter* terbaik dari model tersebut seperti jenis *kernel* yang digunakan dan *kernel degree*. Saran perkembangan selanjutnya, bisa mencoba alternatif model gabungan (konsep *ensemble learning*) yang mungkin bisa meningkatkan performa model.

DAFTAR PUSTAKA

- [1] T. Sinha, "Tumors: Benign and Malignant," *Cancer Ther Oncol Int J*, vol. 10, no. 3, May 2018, doi: 10.19080/ctoj.2018.10.555790.
- [2] SEER, "Surveillance, Epidemiology, and End Results Program," <https://seer.cancer.gov/>.
- [3] S. A. H. S. Javadi and B. Rezaei, "Brain tumors and indications for brain imaging in patients with psychiatric manifestations: a case report," *Middle East Current Psychiatry*, vol. 28, no. 1, Dec. 2021, doi: 10.1186/s43045-021-00136-2.
- [4] Rafi Haidar Ramdlon, Entin Martiana Kusumaningtyas, and Tita Karlita, "Brain Tumor Classification Using Mri Images With K-Nearest Neighbor Method," *2019 International Electronics Symposium (IES)*, pp. 660–667, 2019.

- [5] Göklap Cinarer and Bülent Gürsel Emiroglu, "Classification of Brain Tumors by Machine Learning Algorithms," *2019 3rd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)*, 2019.
- [6] M. A. Naser and M. J. Deen, "Brain tumor segmentation and grading of lower-grade glioma using deep learning in MRI images," *Comput Biol Med*, vol. 121, Jun. 2020, doi: 10.1016/j.compbiomed.2020.103758.
- [7] Yakub Bhanothu, Anandhanarayanan Kamalakannan, and Govindaraj Rajamanickam, "Detection and Classification of Brain Tumor in MRI Images using Deep Convolutional Network," *2020 6th International Conference on Advanced Computing & Communication Systems (ICACCS)*, pp. 248–252, 2020.
- [8] A. Samreen, A. M. Taha, Y. V. Reddy, and P. Sathish, "Brain Tumor Detection by Using Convolution Neural Network," *International journal of online and biomedical engineering*, vol. 16, no. 13, pp. 58–69, 2020, doi: 10.3991/ijoe.v16i13.18545.
- [9] N. Abiwinanda, M. Hanif, S. T. Hesaputra, A. Handayani, and T. R. Mengko, "Brain tumor classification using convolutional neural network," in *IFMBE Proceedings*, 2019, vol. 68, no. 1, pp. 183–189. doi: 10.1007/978-981-10-9035-6_33.
- [10] S. Dabbaghchian, A. Aghagolzadeh, and M. S. Moin, "Feature extraction using discrete cosine transform for face recognition," in *2007 9th International Symposium on Signal Processing and its Applications, ISSPA 2007, Proceedings*, 2007. doi: 10.1109/ISSPA.2007.4555358.
- [11] Aryan Felix, "BraTS 2019 (Train/Test/Valid)," 2020.
- [12] P. Verma and G. Verma, "Brain Tumor Detection using Hybrid Model of DCT DWT and Thresholding," *International Research Journal of Engineering and Technology (IRJET), Certified Journal | Page*, vol. 9001, 2008.
- [13] "Discrete Cosine Transform; Second Edition"
- [14] Hein Tun Zaw, Noppadol Maneerat, and Khin Yadanar Win, "Brain tumor detection based on Naïve Bayes Classification," *2019 5th International Conference on Engineering, Applied Sciences and Technology (ICEAST)*, 2019.
- [15] B. Charbuty and A. Abdulazeez, "Classification Based on Decision Tree Algorithm for Machine Learning," *Journal of Applied Science and Technology Trends*, vol. 2, no. 01, pp. 20–28, Mar. 2021, doi: 10.38094/jastt20165.
- [16] B. Tu, J. Wang, X. Kang, G. Zhang, X. Ou, and L. Guo, "KNN-Based Representation of Superpixels for Hyperspectral Image Classification," *IEEE J Sel Top Appl Earth Obs Remote Sens*, vol. 11, no. 11, pp. 4032–4047, Nov. 2018, doi: 10.1109/JSTARS.2018.2872969.
- [17] E. García-Gonzalo, Z. Fernández-Muñoz, P. J. G. Nieto, A. B. Sánchez, and M. M. Fernández, "Hard-rock stability analysis for span design in entry-type excavations with learning classifiers," *Materials*, vol. 9, no. 7, Jul. 2016, doi: 10.3390/ma9070531.
- [18] D. M. W. Powers and Ailab, "Evaluation: From Precision, Recall And F-Measure To Roc, Informedness, Markedness & Correlation."