

# Simeon Yuda Prasetyo

*anonymous marking enabled*

---

**Submission date:** 26-Dec-2022 06:04PM (UTC-0500)

**Submission ID:** 1983651407

**File name:** 5230-13776-1-SM.docx (2.4M)

**Word count:** 2788

**Character count:** 17091

## DETEKSI TUMOR OTAK DARI CITRA MRI MENGGUNAKAN FITUR DISCRETE COSINE TRANSFORM DAN EXTREME LEARNING MACHINE

Simeon Yuda Prasetyo<sup>1</sup>

<sup>1</sup>Universitas Bina Nusantara  
 Email: <sup>1</sup>simeon.prasetyo@binus.ac.id

(Naskah masuk: 21 Oktober 2022, diterima untuk diterbitkan: dd mmm yyyy)

### Abstrak

Tumor otak merupakan pertumbuhan jaringan secara abnormal dan ditandai dengan proliferasi sel yang berlebihan di bagian otak tertentu. Salah satu teknologi andal saat ini yang dapat digunakan untuk mengidentifikasi tumor otak adalah dengan menerapkan pemindaian *Magnetic Resonance Imaging* (MRI). Gambar MRI yang dipindai kemudian dipantau dan diperiksa secara konvensional oleh dokter spesialis untuk mengamati keberadaan tumor. Karena jumlah orang yang menderita tumor otak sangat meningkat dan angka kematian mereka yang sesuai telah mencapai 18.600 pada tahun 2021, penelitian tentang merancang alat yang lebih efektif dan efisien untuk membantu spesialis medis dalam mengidentifikasi tumor otak dianggap sangat penting. Dalam studi sebelumnya, model berbasis machine learning mampu menunjukkan kemampuannya untuk mendeteksi tumor otak dengan akurasi klasifikasi 92% dan hal ini dapat dikatakan andal. Dalam upaya untuk mendapatkan akurasi deteksi / klasifikasi biner yang paling andal pada citra otak MRI, beberapa hyperparameter diuji secara komputasi menggunakan set data MRI yang terbuka untuk umum. Keakuratan model yang canggih dicapai dengan mencoba berbagai kemungkinan unit neuron dan fungsi aktivasi ELM yang diikuti dengan memasukkan *feature map* yang diekstraksi dari Discrete Cosine Transform (DCT). Klasifikasi citra MRI didapatkan akurasi test tertinggi sebesar 95% dengan jumlah unit neuron ELM sejumlah 20 dan fungsi aktivasi tanh.

**Kata kunci:** Deteksi Tumor Otak, MRI, DCT, ELM

## BRAIN TUMOR DETECTION FROM MRI IMAGES USING DISCRETE COSINE TRANSFORM FEATURES AND EXTREME LEARNING MACHINE

### Abstract

Brain tumor is an abnormal growth of brain tissue and characterized by excessive cell proliferation in certain parts of the brain. One of the current reliable technologies that can be used to identify brain tumors is Magnetic Resonance Imaging (MRI) scans. The scanned MRI images are then conventionally monitored and examined by a specialist for the presence of tumors. As the number of people suffering from brain tumors is greatly increasing and their corresponding mortality rate has reached 18,600 by 2021, research on designing more effective and efficient tools to assist medical specialists in identifying brain tumors is considered of great importance. In a previous study, a machine learning-based model was able to demonstrate its ability to detect brain tumors with a classification accuracy of 92%. In an effort to obtain the most reliable detection/binary classification accuracy on MRI brain images, several hyperparameters were computationally tested using public MRI datasets. Sophisticated model accuracy was achieved by testing various neuronal units and ELM activation functions followed by inserting a feature map extracted from the Discrete Cosine Transform (DCT). The model obtained the highest testing accuracy of 95% with a number of 20 ELM neuron units with a tanh activation function.

**Keywords:** Brain Tumor Detection, MRI, DCT, ELM

### 1. PENDAHULUAN

Tumor merupakan sel yang tumbuh secara tidak normal (proliferasi sel secara berlebihan) yang berada pada bagian tubuh tertentu. Tumor merupakan

jaringan abnormal yang mungkin bersifat padat atau juga dapat berwujudkan cairan [1]

Menurut SEER (2021) kasus kanker dan tumor otak pada tahun 2021 diestimasikan sejumlah 24.530 kasus baru, sedangkan angka kematian pengidap

tumor otak mencapai 18.600 kasus kematian. Selain itu, angka harapan hidup orang yang terkena penyakit ini hingga 5 tahun adalah 32,6% [2] Selain angka harapan hidup pengidap penyakit ini tergolong rendah, untuk mendeteksi tumor otak tergolong cukup sulit karena gejala yang dialami terkadang tidak begitu jelas, atau bahkan cenderung mengarah ke penyakit psikis atau penyakit kejiwaan seperti kegelisahan dan depresi [3].

Identifikasi keberadaan tumor otak bukanlah tugas yang mudah karena gejala yang dialami oleh penderita tumor otak cenderung mengarah pada penyakit mental seperti kecemasan dan depresi. Karena itu, pada stadium awal biasanya mereka akan terdiagnosis sebagai penderita gangguan jiwa padahal seharusnya pasien tersebut menderita tumor otak. Sebelum langkah diagnosa, dengan menggunakan salah satu teknologi yang dapat diandalkan saat ini, bagian tumor otak pertama kali ditangkap dengan bantuan pemindaian magnetic resonance imaging (MRI). Gambar MRI yang dipindai kemudian dipantau dan diperiksa oleh ahli radiologi dan spesialis medis lainnya untuk memeriksa apakah tumor itu ada. Oleh karena itu, untuk mengambil keputusan apakah pasien terindikasi tumor otak atau tidak, mungkin membutuhkan waktu yang lama karena memerlukan analisis yang mendalam dari tim ahli medis yang mampu membaca dan mengidentifikasi tumor dari kumpulan gambar MRI. Selain itu, karena sifat kompleksitas gambar MRI, deteksi keberadaan tumor otak terkadang dapat menyebabkan keputusan negatif palsu. Oleh karena itu, untuk mengatasi kelemahan kritis tersebut, komputer berkecepatan tinggi dengan paradigma *machine learning* mungkin diperlukan oleh tim medis tidak hanya untuk mempercepat seluruh proses identifikasi tetapi juga untuk membuat keputusan yang lebih tepat tentang deteksi dan lokalisasi tumor otak.

Penelitian baru-baru ini, metode identifikasi atau deteksi tumor otak menggunakan pengenalan pola pada citra digital telah banyak dilakukan. Dari sejumlah jurnal yang telah dikumpulkan berdasarkan sejumlah kriteria inklusi berupa membahas machine learning atau deep learning yang digunakan dalam deteksi tumor dengan menggunakan citra MRI (Magnetic Resonance Imaging) otak dan rentang waktu jurnal pada tahun 2018 hingga tahun 2022 didapatkan hasil yang cukup beragam.

Penelitian sebelumnya, dalam [4] menggunakan teknik pemrosesan binerisasi citra, dan morfologi citra. Klasifikasi tumor diterapkan setelah segmentasi dilakukan proses Shape Feature Extraction. Hasil klasifikasi tumor yang diperoleh adalah 89,5 persen, yang mampu untuk memberikan informasi mengenai deteksi tumor lebih jelas dan secara khusus. Hasil ini didapatkan dengan menggunakan klasifikasi K-Nearest Neighbor. Penelitian lainnya, [5] pada proses klasifikasi, sifat statistik dari gambar input dianalisis dan data secara sistematis dibagi ke dalam berbagai

kategori, kemudian membandingkan tiga algoritma klasifikasi yakni KNN, Random Forest dan SVM. Didapatkan akurasi tertinggi sebesar 90% dengan menggunakan SVM.


Penelitian lainnya mengklasifikasikan citra otak MRI yang terdiri dari 3 kelas tumor, yaitu glioma, meningioma dan hipofisis. Algoritma mereka yang mengekstrak peta fitur tingkat tinggi dari model dasar VGG16 menggunakan Fast R-CNN sebagai pengklasifikasi. Penelitian ini mencapai rata-rata presisi 77,6% untuk semua kelas [6].

Sedangkan, dalam percobaan [7] melakukan perbandingan dua macam algoritma untuk tahap segmentasi yakni memanfaatkan segmentasi U-net dan segmentasi berbasis CNN. Sedangkan, pada tahapan tumor grading membandingkan algoritma VGG-16 dan CNN. Berdasarkan percobaan yang dilakukan mendapatkan hasil terbaik menggunakan segmentasi U-Net, dengan algoritma deteksi tumor menggunakan random forest classifier serta tahapan grading tumor menggunakan algoritma VGG-16. Percobaan ini menggunakan data MR Spectroscopy dan FLAIR mendapatkan akurasi percobaan tertinggi yakni 72 persen.

Tujuan dari penelitian ini adalah merancang alat bantu diagnostik tumor otak menggunakan basis citra MRI menggunakan ekstraksi fitur berupa Discrete Cosine Transform (DCT) yang merupakan algoritma dalam kompresi signal dan menggunakan Extreme Learning Machine (ELM) sebagai pembentuk model klasifikasinya. Hasil akhir dari penelitian ini diperoleh confusion matrix dan persentase akurasi testing dari konfigurasi yang dibangun.

## 2. METODE PENELITIAN

Tahapan penelitian yang digunakan dalam penelitian ini tersaji pada Gambar 1.




Gambar 1. Tahapan Penelitian

Penjelasan dari proses Tahapan Penelitian dari Gambar 1 yakni:

### a. Pengumpulan Data

Pada tahapan ini dilakukan pencarian set data yang sesuai dengan penelitian ini. Dataset yang dikumpulkan harus merupakan data citra MRI tumor otak yang terdapat label berupa adanya tumor ataupun tidak ada tumor.

Pada tahapan ini digunakan dataset citra MRI tumor otak yang dapat diakses melalui situs *kaggle* [8] dengan dataset bernama BraTS 2019. Pada dataset ini terdapat secara total 3000 citra MRI otak, dimana 1500 citra terdapat tumor dan 1500 citra lainnya tidak terdapat tumor. Beberapa contoh citra dari dataset BraTS 2019 dapat dilihat pada gambar 2.



Gambar 2. Contoh Dataset BraTS 2019

#### b. Pembagian Data

Data dilakukan pembagian menjadi 2 bagian secara *stratified* yakni data untuk training sejumlah 2800 data (1400 tumor, 1400 sehat) dan 200 data untuk testing (100 tumor, 100 sehat).

#### c. Pra-Pemrosesan Data

Pada tahapan ini dilakukan perubahan citra ke aras keabuan sehingga citra yang awalnya memiliki 3 *channel* warna menjadi hanya memiliki 1 *channel* warna. Selain itu, pada tahapan ini juga melakukan perubahan citra yang semula memiliki ukuran yang tidak sama menjadi berukuran 150x150 piksel.

#### d. Ekstraksi Fitur DCT

Pada klasifikasi citra memerlukan pemrosesan ekstraksi fitur untuk dapat mengubah citra yang semula memiliki fitur sangat banyak yang mungkin memiliki nilai yang tidak signifikan (korelasi rendah) menjadi fitur yang lebih sederhana namun berarti. Dalam penelitian ini, DCT digunakan sebagai ekstraksi fitur citra MRI yang ada.

Algoritma DCT (Discrete Cosine Transform) merupakan algoritma yang biasa digunakan dalam kompresi gambar ataupun sinyal. Algoritma ini melakukan perubahan data spasial menjadi bentuk frekuensi, kemudian pengolahan data frekuensi, dan dikonversi ke bentuk spasial kembali dengan inversi

metode tersebut. Dimana, domain frekuensi merupakan sinyal dalam wujud amplitudo terhadap waktu (spektrum pada satu sinyal waktu), domain frekuensi merujuk pada analisis fungsi matematis atau sinyal yang berhubungan dengan frekuensi dalam waktu. Sedangkan, domain spasial merujuk pada dasar pada manipulasi piksel secara langsung pada gambar [9], [10].

Discrete cosine transform dirumuskan seperti pada persamaan (1).

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

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

$$\alpha(w) \begin{cases} \sqrt{\frac{1}{N}} & \text{untuk } w = 0 \\ \sqrt{\frac{2}{N}} & \text{untuk lainnya} \end{cases}$$

dimana  $v(k)$  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 (biasannya, perhitungan matriks pada satu komponen warna baik red atau green atau blue ataupun citra keabuan  $[\text{red} + \text{green} + \text{blue}] / 3$ ). Selanjutnya, citra dibagi kedalam blok berukuran 8 x 8 piksel, urut dari ujung kiri ke kanan, dan dari atas ke bawah.

#### e. Pembentukan Model ELM

ELM (*Extreme Learning Machine*) adalah algoritma dari jaringan syaraf tiruan (JST) yang hanya memiliki satu lapisan tersembunyi dan pembelajarannya berlangsung secara *feedforward* [11], [12].

Pada dasarnya, JST merupakan fungsi model matematis jika yang mendefinisikan  $y = f(x * w)$  [13]–[15] Dimana  $y$  merupakan elemen output,  $f$  merupakan fungsi aktivasi,  $x$  merupakan sinyal masukan input (sensori) dan  $w$  merupakan bobot sinaptik. Istilah jaringan merujuk pada interkoneksi pada neuron pada sejumlah lapisan yang berbeda. Lapisan pada JST dibagi menjadi tiga bagian :

- 1) Input Layer
- 2) Hidden Layer
- 3) Output Layer



Gambar 3. Visualisasi ELM

Dalam penelitian ini, jumlah neuron yang digunakan dalam hidden layer akan diuji mana yang terbaik dari sejumlah 5, 10, 15 dan 20 neuron dengan fungsi aktivasi yang diuji adalah tanh dan relu. Arsitektur ELM dengan jumlah neuron 10 pada hidden layernya apabila divisualisasikan akan menjadi seperti pada Gambar 3.

Secara matematis, neuron merupakan sebuah fungsi yang menerima masukan dari lapisan sebelumnya  $g_i$  (lapisan ke- $i$ ). Fungsi ini pada umumnya mengolah sebuah vektor untuk kemudian diubah ke nilai skalar dengan menghitung nonlinear weighted sum

$$f = K(\sum_i w_i g_i) \quad (2)$$

dimana  $K$  merupakan fungsi khusus yang sering disebut dengan fungsi aktivasi dan  $w_i$  merupakan weight atau bobot.

#### f. Evaluasi Model

Evaluasi yang digunakan dalam penelitian ini adalah Confusion Matrix, Akurasi, Presisi, Recall dan F1 Score. Confusion matrix pada kasus klasifikasi biner menyajikan kasus true positive (TP), true negative (TN), false positive (FP) dan false negative (FN).

Akurasi didefinisikan sebagai persentase seluruh data yang diklasifikasikan secara benar baik pada kelas positif ataupun negatif. Sehingga berarti seluruh data prediksi yang bernilai benar dibagi dengan seluruh data yang tersedia. Apabila dirumuskan akan menjadi persamaan (3).

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

Seluruh value pada persamaan tersebut bisa dilihat dari confusion matrix untuk mendapatkan setiap bagian dari valuenya [16].

Precision atau yang disebut juga dengan confidence merupakan metrik yang membahas tentang seberapa tepat/akurat suatu model yang dibuat. Hal ini diukur dari hasil prediksi yang bernilai positif (berapa banyak yang benar-benar positif). Sehingga precision dapat dirumuskan dalam persamaan (4).

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

Recall atau yang disebut dengan sensitivity merupakan metrik yang menghitung berapa banyak Actual Positive yang ditangkap oleh model melalui pelabelannya sebagai Positif (Benar-Benar Positif). Sehingga recall dapat dirumuskan seperti persamaan (5).

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

F1 score merupakan metrik untuk melakukan pengukuran dengan mempertimbangkan keseimbangan antara precision dan recall sehingga pada f1-score mengabaikan value dari negatif aktual (true negative) [16]. Maka f1 score dapat dirumuskan menjadi 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 ELM menunjukkan hasil yang baik, bahkan berhasil mengalahkan akurasi pada penelitian sebelumnya yang menggunakan pendekatan deep learning.

Eksperimen ini dilakukan dengan optimizers *lbfgs*, *learning rate* sebesar 0.001 dan jumlah iterasi sejumlah 500. Hasil eksperimen deteksi atau klasifikasi biner tumor otak dengan DCT dan ELM dengan hyperparameter yang diuji berupa jumlah neuron dan fungsi aktivasi dapat dilihat pada tabel 1.


Tabel 1. Hasil Eksperimen DCT + ELM

Number of Neuron	Activation Function	Metrics		
		Name	Value	Average
5	Relu	Accuracy	0.90	0.8975
		Precision	1.00	
		Recall	0.80	
	Tanh	F1-Score	0.89	0.88125
		Accuracy	0.885	
		Precision	1.00	
10	Relu	Recall	0.77	0.8975
		F1-Score	0.87	
		Accuracy	0.90	
	Tanh	Precision	0.99	0.9275
		Recall	0.81	
		F1-Score	0.89	
15	Relu	Accuracy	0.93	0.9375
		Precision	1.00	
		Recall	0.87	
	Tanh	F1-Score	0.93	0.9175
		Accuracy	0.92	
		Precision	0.98	
20	Relu	Recall	0.86	0.8975
		F1-Score	0.91	
		Accuracy	0.90	
	Tanh	Precision	1.00	0.95
		Recall	0.80	
		F1-Score	0.89	
		Accuracy	0.95	
		Precision	0.99	
		Recall	0.91	
		F1-Score	0.95	


14

Berdasarkan hasil pada tabel diatas diketahui bahwa model konfigurasi ELM terbaik dapat diperoleh dengan jumlah neuron pada hidden layer sejumlah 20 dengan fungsi aktivasi tanh (Tan Hiperbolik). Pada konfigurasi tersebut berhasil mendapatkan akurasi training sebesar 100% dan akurasi testing sebesar 95%, dengan rerata dari akurasi, presisi, recall dan F1-Score bernilai 95% pula.

Berdasarkan konfigurasi model terbaik yang dibentuk tersebut (dengan jumlah neuron 20 dan aktivasi tanh) mendapatkan *confusion matrix* yang tersaji pada Gambar 4. Pada Gambar 5 juga menyajikan *learning curve* dari konfigurasi model ini.



Gambar 4. Confusion Matrix



Gambar 4. Learning Curve

*Confusion matrix* yang ditampilkan pada Gambar 4, sebelah kiri atas merupakan True Negative (TN) sejumlah 99, sebelah kanan atas merupakan False Positive (FP) sejumlah 1, sebelah kiri bawah merupakan False Negative (FN) sejumlah 9, dan sebelah kanan bawah merupakan True Positive (TP) sejumlah 91. Dimana pada sumbu X dan Y terdapat angka nol dan satu, nol merupakan kelas no-tumor dan satu merupakan kelas tumor.

*Learning Curve* yang ditampilkan menjelaskan bahwa apabila menggunakan data yang lebih sedikit mengakibatkan nilai validasi yang lebih rendah serta menunjukkan apabila data yang digunakan kurang dari 1000 menunjukkan hasil yang *overfitting* (hal ini ditunjukkan pada akurasi training yang tinggi namun validasi yang rendah). Sedangkan setelah mencapai 2000 data model menghasilkan klasifikasi dengan baik dan tidak terjadi *overfitting* karena selisih antara nilai pada training berhimpitan (tidak ada beda yang signifikan) dengan validasinya.

#### 4. KESIMPULAN

Telah ditunjukkan bahwa penerapan ekstraksi fitur menggunakan *Discrete Cosine Transform* (DCT) untuk mendapatkan *feature map* dengan menggunakan model klasifikasi *Extreme Learning Machine* (ELM) mampu mencapai skor akurasi test klasifikasi yang tinggi pada tugas deteksi atau klasifikasi biner. Skor akurasi training mencapai 100% dan akurasi testing sebesar 95,0% diperoleh dengan menerapkan jumlah neuron pada hidden layer sejumlah 20 unit dan menggunakan fungsi aktivasi *Tan Hiperbolik* (Tanh).

Sebagai saran untuk memperbaiki model, kedepannya bisa dilakukan optimalisasi dengan mencari hyperparameter terbaik dari model seperti jumlah unit neuron pada hidden layer, jenis fungsi aktivasi, *learning rate*, dan jenis pengoptimal yang digunakan.

## 5. 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] R. H. Ramdlon, E. M. Kusumaningtyas, and T. Karlita, "BRAIN TUMOR CLASSIFICATION USING MRI IMAGES WITH K-NEAREST NEIGHBOR METHOD."
- [5] G. Cinarere and B. G. Emiroglu, "Classificatin of Brain Tumors by Machine Learning Algorithms."
- [6] Y. Bhanotu, A. Kamalakannan, and G. Rajamainickam, "Detection and Classification of Brain Tumor in MRI Images using Deep Convolutional Network."
- [7] 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.combiomed.2020.103758.
- [8] "Kaggle," <https://www.kaggle.com/>.
- [9] Rubbina, P. Verma, and G. Verma, "Brain Tumor Detection using Hybrid Model of DCT DWT and Thresholding," *Certified Journal / Page*, vol. 9001, 2008.
- [10] "Discrete Cosine Transform; Second Edition."
- [11] J. Wang, S. Lu, S. H. Wang, and Y. D. Zhang, "A review on extreme learning machine," *Multimed Tools Appl*, 2021, doi: 10.1007/s11042-021-11007-7.
- [12] S. Ding, X. Xu, and R. Nie, "Extreme learning machine and its applications," *Neural Computing and Applications*, vol. 25, no. 3–4, pp. 549–556, 2014, doi: 10.1007/s00521-013-1522-8.
- [13] P. P. Widodo and R. T. Handayanto, *Penerapan Soft Computing dengan Matlab : Edisi Revisi*. Bandung: Rekayasa Sains, 2012.
- [14] W. Budiharto and D. Suhartono, *Artificial Intelligence Konsep dan Penerapannya*. Yogyakarta: Penerbit Andi, 2014.
- [15] I. Robandi, *Artificial Intelligence : Mengupas Rekayasa Kecerdasan Tiruan*. Yogyakarta: Penerbit Andi, 2019.
- [16] D. M. W. Powers and Ailab, "EVALUATION: FROM PRECISION,

RECALL AND F-MEASURE TO ROC, INFORMEDNESS, MARKEDNESS & CORRELATION."

# Simeon Yuda Prasetyo

## ORIGINALITY REPORT

17%

SIMILARITY INDEX

11%

INTERNET SOURCES

5%

PUBLICATIONS

10%

STUDENT PAPERS

## PRIMARY SOURCES

1	Submitted to Surabaya University Student Paper	7%
2	ijisae.org Internet Source	3%
3	Submitted to Universitas Islam Lamongan Student Paper	1%
4	Astika Wulansari, Aulia Tegar Rahman. "Analisa gambar citra MRI otak dengan watershed dan ekstraksi fitur GLCM", JNANALOKA, 2022 Publication	1%
5	Submitted to Coventry University Student Paper	1%
6	media.neliti.com Internet Source	1%
7	123dok.com Internet Source	1%
8	doku.pub Internet Source	1%

9	<a href="http://core.ac.uk">core.ac.uk</a> Internet Source	1 %
10	<a href="http://ejurnal.teknokrat.ac.id">ejurnal.teknokrat.ac.id</a> Internet Source	<1 %
11	<a href="http://www.afriliautami.com">www.afriliautami.com</a> Internet Source	<1 %
12	Submitted to Sriwijaya University Student Paper	<1 %
13	<a href="http://medium.com">medium.com</a> Internet Source	<1 %
14	<a href="http://repository.radenintan.ac.id">repository.radenintan.ac.id</a> Internet Source	<1 %
15	<a href="http://waveletlab.cn">waveletlab.cn</a> Internet Source	<1 %

Exclude quotes On

Exclude matches Off

Exclude bibliography On

# Simeon Yuda Prasetyo

---

PAGE 1

---

PAGE 2

---

PAGE 3

---

PAGE 4

---

PAGE 5

---

PAGE 6

---