

## Klasifikasi Tumor Otak Menggunakan Local Binary Pattern dan SVM Classifier

\*<sup>1</sup> Wahyu Ardiantito S, <sup>2</sup> Stacyana Jesika Surianto, <sup>3</sup> Suci Ramadhani, <sup>4</sup> Willy Pramudia Ananta

<sup>1-4</sup> Universitas Negeri Medan

Alamat: Jl. William Iskandar Ps. V, Kenangan Baru, Kec. Percut Sei Tuan, Kabupaten Deli Serdang, Sumatera Utara 20221

\*Korespondensi penulis: [ardiantitowahyu@gmail.com](mailto:ardiantitowahyu@gmail.com)

**Abstract** Brain tumors are abnormal cell growths in brain tissue that can be life-threatening. This study aims to classify brain tumors to help early diagnosis. The method used is to extract features from brain MRI images using Local Binary Pattern (LBP) and then classified with Support Vector Machine (SVM). The data used were 2044 brain MRI images consisting of 3 classes namely meningioma, no tumor, and pituitary. The best results were obtained using LBP with a radius of 1 and the number of neighbors 8, while the best SVM model used the RBF kernel with a C value of 50, resulting in 88% accuracy, 86% precision, and 87% recall. It can be concluded that the combination of LBP and SVM methods is effective enough to classify brain tumor types to support early diagnosis.

**Keywords:** Brain Tumor, SVM, Local Binary Pattern.

**Abstrak.** Tumor otak merupakan pertumbuhan sel abnormal di jaringan otak yang dapat mengancam jiwa. Penelitian ini bertujuan melakukan klasifikasi tumor otak untuk membantu diagnosis dini. Metode yang digunakan adalah dengan mengekstraksi fitur dari citra MRI otak menggunakan Local Binary Pattern (LBP) dan kemudian diklasifikasikan dengan Support Vector Machine (SVM). Data yang digunakan sebanyak 2044 citra MRI otak yang terdiri dari 3 kelas yaitu meningioma, tidak ada tumor, dan pituitary. Hasil terbaik diperoleh dengan menggunakan LBP dengan radius 1 dan jumlah tetangga 8, sedangkan model SVM terbaik menggunakan kernel RBF dengan nilai C 50, menghasilkan akurasi 88%, presisi 86%, dan recall 87%. Dapat disimpulkan bahwa kombinasi metode LBP dan SVM cukup efektif untuk mengklasifikasikan jenis tumor otak guna mendukung diagnosis dini.

**Kata kunci:** Tumor Otak, SVM, Local Binary Pattern.

### LATAR BELAKANG

Otak adalah Komponen dari sistem saraf pusat yang berada di kepala manusia. Sebagai bagian dari sistem saraf pusat, otak memainkan peran vital dalam mengendalikan semua aktivitas dan organ tubuh lainnya. Tumor otak adalah pertumbuhan sel yang tidak normal yang terjadi dalam wilayah otak (Malkin & Shapiro, 1988). Menurut data dari Global Cancer Observatory tahun 2020, tumor otak menduduki peringkat ke-15 dalam hal jumlah kasus di Indonesia, menjadikannya salah satu penyakit dengan jumlah penderita terbanyak. Selama lima tahun terakhir, rata-rata terdapat 15.310 kasus kematian akibat tumor otak (Hungerford & Plowman, 2014).

Pada umumnya tumor otak diidentifikasi dengan melakukan pemeriksaan gambaran resonansi magnetik (MRI) melibatkan penggunaan perangkat medis khusus. Setelah pasien menjalani pemeriksaan, seorang dokter radiologi akan mengevaluasi dan membuat kesimpulan berdasarkan gambar yang dihasilkan oleh peralatan tersebut. Salah satu keunggulan

penggunaan MRI adalah kemampuannya untuk mengamati perbedaan antara berbagai jenis jaringan lunak, seperti "substantia alba" dan "substantia grisea," yang dapat terlihat dengan jelas dalam gambar MRI. (Ainani Shabrina Febrianti et al., 2020). Klasifikasi tumor memiliki peran penting dalam membantu dokter dalam menentukan jenis tumor yang terjadi pada pasien. Biopsi dan pengamatan langsung adalah dua metode yang paling umum digunakan, tetapi biopsi memerlukan waktu yang cukup lama, sekitar sepuluh hingga lima belas hari, untuk mendapatkan hasil uji laboratorium, sementara pengamatan langsung oleh dokter memiliki risiko kesalahan. Oleh karena itu, deep learning dengan convolutional neural network telah membantu dokter mengidentifikasi dan mendiagnosa tumor otak pada pasien mereka (Suta et al., 2019).

Oleh karena itu Pada tahap awal penyakit ini, penting untuk melakukan proses klasifikasi yang tepat, mengingat deteksi tumor otak oleh tenaga medis berdasarkan citra MRI hanya dengan pengamatan visual dapat menghasilkan akurasi yang rendah. (Amalia et al., 2022).

Dalam sebuah penelitian, dilakukan perbandingan antara dua metode klasifikasi, yaitu Convolutional Neural Network (CNN) dan SVM dengan dua jenis SVM, yaitu Linear SVM dan Polynomial SVM. Penelitian ini menggunakan 3064 citra MRI yang diambil dari 233 pasien Rumah Sakit Nanfang dan Universitas Kedokteran Tianjing. Tujuan penelitian ini adalah untuk mengklasifikasikan citra tumor otak ke dalam tiga kelas, yaitu meningioma, glioma, dan pituitary. Hasil penelitian menunjukkan bahwa metode CNN mencapai tingkat akurasi sebesar 98.85%, sedangkan Linear SVM dan Polynomial SVM mencapai tingkat akurasi masing-masing 95.27% dan 95.43% (Baranwal et al., 2020).

Selanjutnya penelitian lain juga pernah dilakukan untuk klasifikasi tumor otak dengan menggunakan dua tipe SVM yaitu C-SVM, dan Nu-SVM. Pada penelitian ini menggunakan metode GLCM sebagai ekstraksi fitur pada gambar menghasilkan akurasi 72% untuk Nu-SVM dan 76% untuk C-SVM (Ainani Shabrina Febrianti et al., 2020).

Berdasarkan dari penelitian sebelumnya pada artikel ini akan dilakukan deteksi tumor otak dengan mengekstraksi fitur citra mri untuk kemudian di klasifikasikan menggunakan algoritma svm. Hal ini bertujuan untuk melihat bagaimana performa kedua metode ini apabila di kombinasikan pada data citra MRI.

## **KAJIAN TEORITIS**

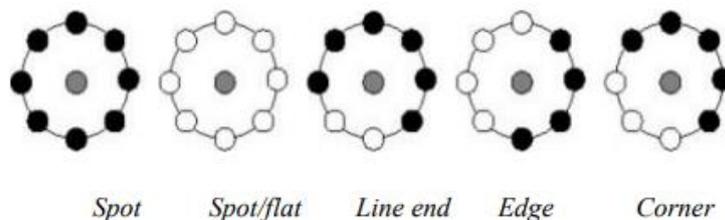
### **1. Tumor Otak**

Tumor adalah hasil dari pertumbuhan sel yang tidak normal, yang merupakan komponen dasar jaringan dan organ tubuh. Tumor di otak adalah hasil dari pertumbuhan sel yang tidak normal yang membentuk massa di sekitar otak. Kondisi ini dapat mengganggu fungsi otak

secara keseluruhan. diperkirakan terjadi sekitar 18.500 kasus tumor otak setiap tahun, dengan tingkat kematian sekitar 3 persen. Tumor otak dapat dibagi menjadi tumor otak primer dan tumor otak sekunder. Tumor otak primer adalah tumor yang pertama kali tumbuh dan berkembang di dalam otak, memiliki kemampuan untuk metastasis ke bagian lain dari sistem saraf, meskipun jarang ditemukan tumbuh di tempat lain di tubuh. Namun, tumor otak termasuk dalam kelompok sekunder, yang berarti tumor tersebut pertama kali tumbuh di tempat lain di tubuh dan kemudian menyebar melalui sistem saraf. Kanker paru-paru, melanoma, kanker ginjal, kanker payudara, dan kanker usus adalah beberapa jenis kanker yang dapat menyebar ke otak (Andre et al., 2021).

## 2. Local Binary Pattern (LBP)

Metode Local Binary Pattern (LBP) Diperkenalkan untuk pertama kalinya pada tahun 1992. oleh David Harwood dan Timo Ojala di Universitas Maryland. LBP dapat didefinisikan sebagai suatu teknik untuk membandingkan nilai biner antara piksel pusat dengan delapan piksel di sekitarnya. Dengan kata lain, LBP adalah deskriptor yang digunakan untuk mengklasifikasikan citra berdasarkan tekstur. Sebuah citra berukuran 3x3 akan dibandingkan nilai intensitas piksel di tengah dengan 8 tetangga di sekitarnya. Jika nilai piksel tengah lebih besar maka diberi nilai 1, jika lebih kecil diberi 0. Karena terdapat 8 piksel tetangga, maka total ada 256 kemungkinan kombinasi kode biner dari LBP di area 3x3 tersebut. (Purwati & Ariyanto, 2017).



**Gambar 1.** Tekstur Uniform Pattern

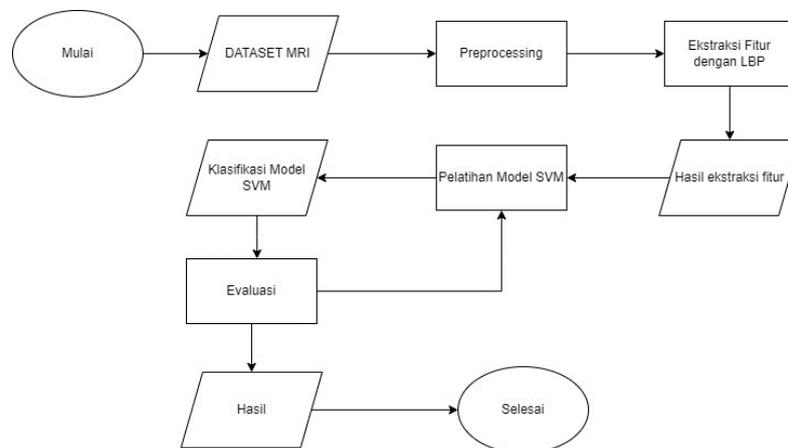
Dalam pengamatan, terdapat beberapa pola LBP (Local Binary Patterns) yang memiliki informasi penting dari suatu tekstur. Pola-pola ini dikenal sebagai pola seragam (uniform patterns). Suatu pola LBP dikatakan seragam jika jumlah perubahan atau transisi antara bit 0 dan 1 dalam pola tersebut paling banyak dua kali. Sebagai contoh, pola 00000000 (tidak ada transisi), 11001111 (2 transisi), dan 11001111 (2 transisi) merupakan pola seragam, sementara pola 11001001 (4 transisi) dan 10101001 (6 transisi) bukan pola seragam. Pola-pola seragam ini berfungsi dalam mengidentifikasi noda (spot), area datar dengan intensitas rendah (dark spot), sudut, dan tepi dalam suatu tekstur. Sekitar 90 persen dari tekstur umumnya terdiri dari pola seragam. (T. Ojala, M. Pietikäinen, n.d.).

### 3. Support Vector Machine (SVM)

Support Vector Machine (SVM), atau Mesin Vektor Dukungan, adalah metode pembelajaran mesin yang terawasi yang digunakan untuk tugas seperti klasifikasi dan regresi. SVM pada dasarnya adalah sebuah pendekatan klasifikasi biner yang membagi titik-titik data ke dalam dua kelas. Saat melatih SVM, tujuannya adalah menemukan hiperplane margin maksimum yang dapat memisahkan kedua kelas dengan jarak terbesar dari titik data pelatihan terdekat.(McCartney, 2015).

SVM adalah algoritma yang beroperasi dengan menggunakan pemetaan non-linear untuk mengubah data train awal ke dimensi yang lebih besar. SVM mencari hiperplane pemisah linear yang ideal (juga disebut sebagai "batas keputusan") yang membedakan tuple dari satu kelas dengan yang lain di dimensi baru tersebut. Pemetaan non-linear yang sesuai ke dimensi yang cukup tinggi memungkinkan hiperplane selalu membedakan data dari dua kelas. SVM mengidentifikasi hiperplane ini dengan memanfaatkan vektor dukungan (yang merupakan tuple pelatihan yang sangat penting) dan margin (yang ditentukan oleh vektor dukungan).(Han et al., 2012).

### METODE PENELITIAN



**Gambar 2.** Alur Penelitian

Pada bagian ini berisi tahapan-tahapan yang dilakukan selama penelitian. Tahapan-tahapan ini berisi tiga bagian yaitu: Melakukan preprocessing citra, kemudian melakukan ekstraksi fitur citra menggunakan metode Local Binary Pattern, mengklasifikasikan hasil fitur ekstraksi dengan algoritma Support Vector Machine dan terakhir Mengevaluasi performa untuk setiap percobaan yang dilakukan.

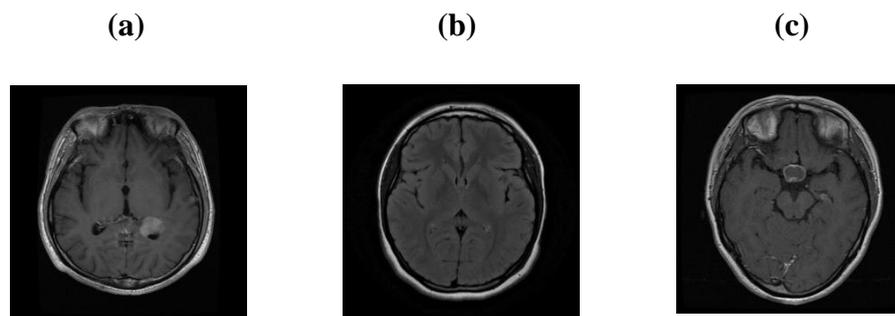
## 1. Dataset Citra

Dataset citra pada penelitian ini merupakan dataset citra MRI (Magnetic Resonance Image) yang diperoleh dari situs Kaggle.com berjumlah sebanyak 2338 citra yang terdiri dari 4 kelas: glioma-meningioma-no tumor- dan pituitary. Berdasarkan website Kaggle data ini merupakan tiga kombinasi dari data figshare SARTAJ dataset, dan Br35H. Jika melihat catatan sumber dataset untuk kelas glioma tidak dikategorikan dengan baik oleh sebab itu pada penelitian ini kelas glioma tidak akan digunakan. Data yang digunakan pada penelitian ini adalah sebagai berikut:

**Tabel 1. Jumlah Dataset Citra**

Kelas	Data Latih	Data Uji	Total
Tumor Meningioma	316	164	480
Tidak ada tumor	658	79	737
Tumor pituitary	661	166	827
Total	1635	409	2044

Dibawah ini merukan contoh gambar citra MRI untuk setiap kelas yang terdapat dari dataset



**Gambar 3. a) Tumor Meningioma, b) Tidak ada Tumor, c) Tumor pituitary**

## 2. Preprocessing Citra

Tahap preprocessing ialah proses awal yang dilakukan pada citra sebelum masuk ke proses atau tahap berikutnya. Tahap ini merupakan bagian penting karena pada tahap ini akan dilakukan proses-proses pada citra agar dapat di model kan dengan baik. Pada penelitian ini tahapan preprocessing yaitu adalah pengubahan ukuran citra, konversi warna ke greyscale, dan normalisasi agar citra memiliki rentang 0-1.

## 3. Ekstraksi Fitur dengan LBP

Pada penelitian ini pengekstrasian menggunakan LBP uniform. LBP uniform lebih sering digunakan karena menghasilkan ekstraksi yang lebih baik dibandingkan dengan metode-metode lainnya. Penelitian ini akan melakukan uji ekstraksi menggunakan berbagai kombinasi radius dan jumlah ketetanggan. Kombinasi yang digunakan adalah :

Radius = 1, Ketetangaan = 8

Radius = 2, Ketetangaan = 8

Radius = 3, Ketetangaan = 8

Radius = 1, Ketetangaan = 16

Radius = 2, Ketetangaan = 16

Hasil yang diperoleh untuk setiap kombinasi ini merupakan hasil ekstraksi fitur yang diperoleh. Fitur ini akan berebentuk array matriks 1 dimensi atau disebut sebagai vector. Vektor-vektor kemudian akan disimpan kedalam bentuk csv (comma separated values) dan disimpan kedalam database fitur.

#### **4. Klasifikasi SVM**

Setelah memperoleh hasil ekstraksi fitur yang berupa array selanjutnya dilakukan klasifikasi dengan model SVM. Pada penelitian ini klasifikasi svm menggunakan beberapa kombinasi untuk menemukan hasil terbaik. Kombinasi ini meliputi pemilihan kernel dan pengaturan nilai C atau parameter regulasi. Berikut ini merupakan kombinasi yang akan digunakan:

Kernel = poly, C = 10

Kernel = poly, C = 50

Kernel = poly, C = 100

Kernel = rbf, C = 10

Kernel = rbf, C = 50

Kernel = rbf, C = 100

#### **5. Evaluasi model**

Pada tahap ini dilakukan perbandingan antara model-model svm yang diuji. Perbandingan dilakukan dengan melihat akurasi, presisi, dan recall terhadap model yang diuji. Model dengan nilai akurasi, presisi, dan recall tertinggi merupakan model terbaik yang akan dijadikan hasil dari penelitian ini.

## **HASIL DAN PEMBAHASAN**

Proses pengujian akan dilakukan secara sistematis dengan mempertimbangkan kombinasi parameter yang digunakan. Sebagai contoh parameter terbaik yang diperoleh pada ekstraksi fitur menggunakan lbp yang akan digunakan untuk tahap selanjutnya agar proses penelitian berjalan secara optimal dan efisien. Pada proses ini dataset yang digunakan adalah dataset training yang kemudian dilakukan pembagian sebesar 80% untuk latih dan 20% untuk data uji.

## 1. Analisis pengaruh parameter radius dan ketetanggaan LBP

Pada pengujian pertama, peneliti akan melakukan uji menggunakan parameter radius dan parameter ketetanggaan

**Tabel 2. Pengaruh radius dan ketetanggaan**

Parameter	Akurasi	Presisi	Recall
R= 1, N = 8	76%	74%	70%
R= 2, N = 8	72%	74%	63%
R= 3, N = 8	66%	72%	57%
R= 1, N = 16	74%	71%	67%
R= 2, N = 16	68%	71%	59%

Tabel diatas menunjukkan hasil yang diperoleh dari berbagai kombinasi ukuran radius dan jumlah ketetanggaan. Dari tabel tersebut juga dapat ditarik kesimpulan untuk dataset yang digunakan pada penelitian ini semakin besar nilai ketetanggaan dan nilai radiusnya memiliki pengaruh mengurangi hasil akurasi, presisi, dan recall. Radius yang tinggi menandakan bahwa jarak antar titik tetangga dan titik pusat memiliki jarak yang jauh sedangkan jumlah tetangga adalah banyaknya titik yang dijadikan tetangga dari titik pusat.

Pada percobaan menggunakan dataset citra MRI tumor otak ini parameter terbaik untuk digunakan adalah parameter terkecil yaitu ukuran radius  $R = 1$  dan jumlah ketetanggaan  $N = 8$ . Selanjutnya parameter ini yang akan digunakan pada Langkah berikutnya yaitu klasifikasi dengan metode SVM.

## 2. Analisis pengaruh parameter C dan kernel SVM

Setelah mendapatkan parameter terbaik berikutnya melakukan uji klasifikasi menggunakan algoritma Support Vector Machine untuk klasifikasi. Tabel dibawah ini merupakan hasil yang diperoleh dari beberapa kombinasi parameter dan SVM.

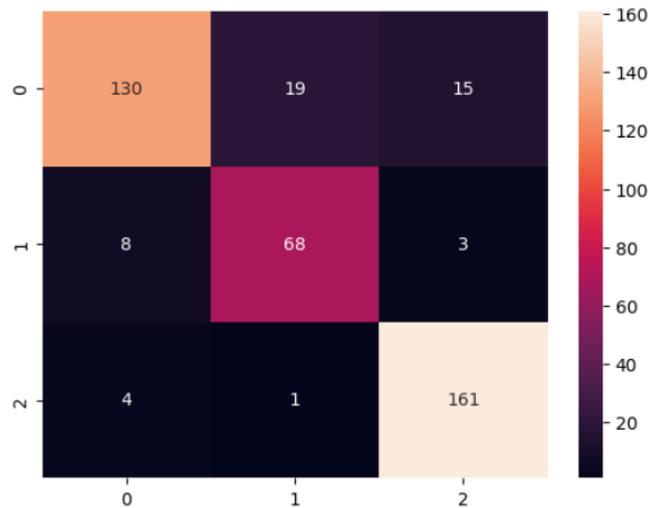
**Tabel 3. Pengaruh Parameter dan Kernel SVM**

Parameter	Akurasi	Presisi	Recall
Kernel = poly, C = 10	85%	83%	84%
Kernel = poly, C = 50	85%	83%	85%
Kernel = poly, C = 100	85%	84%	85%
Kernel = rbf, C = 10	83%	81%	80%
Kernel = rbf, C = 50	88%	86%	87%
Kernel = rbf, C = 100	87%	85%	87%

Tabel tersebut menunjukkan bahwa perbedaan pada parameter pada model SVM mempunyai pengaruh terhadap akurasi model. Dari pengujian didapat bahwa akurasi nilai pada kernel poly terhadap penggunaan C tidak terlalu berpengaruh namun pada kernel rbf penggunaan C mempunyai pengaruh terhadap akurasi yang dihasilkan. Hasil terbaik

diantara 6 pengujian yang dilakukan pada penelitian ini didapat bahwa model SVM terbaik adalah menggunakan parameter  $C = 50$  dan kernel rbf dengan akurasi sebesar 88%.

**Gambar 4.** Confussion Matrix



Gambar dibawah ini menunjukkan matriks konfusi dari model svm terbaik pada pengujian

Matriks konfusi menggambarkan seberapa banyak data yang dapat diprediksi kelas dengan benar. Nilai 0,1, dan 2 merepresentasikan kelas meningioma, tidak ada tumor, dan pituitary. Untuk kelas meningioma sebanyak 130 data berhasil di prediksi dengan benar, 68 data untuk kelas tidak ada tumor, dan 161 data untuk kelas pituitary.

## KESIMPULAN DAN SARAN

Pada penelitian ini, digunakan pendekatan lain untuk mengidentifikasi tumor otak dari citra MRI yaitu dengan metode Local Binary Pattern sebagai ekstraksi fitur dan Support Vector Machine sebagai pengklasifikasinya. Hasil dari penelitian didapatkan parameter terbaik untuk ekstraksi fitur menggunakan lbp adalah radius = 1 dan jumlah ketetanggaan 8. Selanjutnya model SVM terbaik adalah menggunakan parameter  $c = 50$  dan kernel rbf menghasilkan akurasi sebesar 88%, presisi sebesar 86%, dan recall sebesar 87%.

## DAFTAR REFERENSI

- Ainani Shabrina Febrianti, Tri Arief Sardjono, & Atar Fuady Babgei. (2020). Klasifikasi Tumor Otak pada Citra Magnetic Resonance Image dengan Menggunakan Metode Support Vector Machine. *Jurnal Teknik ITS*, Vol. 9, No(1).
- Amalia, K., Magdalena, R., & Saidah, S. (2022). Klasifikasi Penyakit Tumor Otak Pada Citra

- Mri Menggunakan Metode CNN Dengan Arsitektur Alexnet. *E-Proceeding of Engineering*, 8(6), 3247–3254.
- Andre, R., Wahyu, B., & Purbaningtyas, R. (2021). Klasifikasi Tumor Otak Menggunakan Convolutional Neural Network Dengan Arsitektur Efficientnet-B3. *Jurnal IT*, 11(3), 55–59. <https://jurnal.umj.ac.id/index.php/just-it/index>
- Baranwal, S. K., Jaiswal, K., Vaibhav, K., Kumar, A., & Srikantaswamy, R. (2020). Performance analysis of Brain Tumour Image Classification using CNN and SVM. *Proceedings of the 2nd International Conference on Inventive Research in Computing Applications, ICIRCA 2020*, 537–542. <https://doi.org/10.1109/ICIRCA48905.2020.9183023>
- Han, J., Kamber, M., & Pei, J. (2012). Techniques to Improve Classification Accuracy. In *Data Mining, Concepts and Techniques*.
- Hungerford, J. L., & Plowman, P. N. (2014). Central nervous system. *Treatment of Cancer, Sixth Edition*, 33–56. <https://doi.org/10.1201/b17751-2>
- Malkin, M. G., & Shapiro, W. R. (1988). Brain tumors. *Cancer Chemotherapy and Biological Response Modifiers*, 10, 355–375.
- McCartney, P. R. (2015). Big Data Science. In *MCN The American Journal of Maternal/Child Nursing* (Vol. 40, Issue 2). <https://doi.org/10.1097/NMC.0000000000000118>
- Purwati, R., & Ariyanto, G. (2017). Pengenalan Wajah Manusia berbasis Algoritma Local Binary Pattern. *Emitor: Jurnal Teknik Elektro*, 17(2), 70–79. <https://doi.org/10.23917/emitor.v17i2.6232>
- Suta, I. B. L. M., Hartati, R. S., & 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.p01>
- T. Ojala, M. Pietikäinen, and T. M. (n.d.). *Multiresolution gray-scale and rotation invariant texture classification with local binary patterns*. 24.