

# Pengklasifikasian Tumor Otak dengan Analisis Tekstur Citra MRI

Fernaldy (13520112)

Program Studi Teknik Informatika  
Sekolah Teknik Elektro dan Informatika  
Institut Teknologi Bandung, Jalan Ganesha 10 Bandung  
E-mail (gmail): 13520112@std.stei.itb.ac.id

**Abstract**—Tumor otak merupakan salah satu kondisi medis yang cukup langka, tetapi sangat mematikan. Pemindaian otak dengan MRI merupakan salah satu cara yang digunakan oleh para tenaga ahli untuk mendeteksi keberadaan tumor otak. Namun, analisis citra MRI secara manual kurang efisien karena jumlahnya yang banyak. Oleh karena itu, dibutuhkan suatu metode yang mampu mengklasifikasikan citra MRI otak ke dalam kelas-kelas sesuai dengan apakah otak yang dipindai memiliki tumor otak atau tidak. Salah satu metode yang dapat digunakan adalah dengan memanfaatkan analisis tekstur citra dengan GLCM. Dengan membentuk matriks GLCM, dapat diekstraksi properti tekstur dari citra yang kemudian dapat digunakan untuk melakukan klasifikasi. Klasifikasi ke dalam kelas tumor otak berdasarkan properti tekstur citra dilakukan dengan membangun sebuah model jaringan saraf tiruan yang dilatih dengan data properti tekstur citra. Hasil yang diperoleh adalah model mampu melakukan klasifikasi dengan nilai *accuracy* 90.96%, *precision* 90.79%, dan *recall* 90.73%.

**Keywords**—tumor otak; MRI; tekstur; GLCM; jaringan saraf tiruan

## I. PENDAHULUAN

Tumor otak merupakan suatu kondisi medis yang mana terdapat pertumbuhan sel yang abnormal pada otak. Pertumbuhan sel yang tidak normal tersebut dikenal juga dengan istilah neoplasma. Neoplasma dapat dibagi menjadi dua jenis, yaitu yang bersifat jinak (nonkanker) dan yang bersifat ganas (kanker). Beberapa contoh jenis tumor otak yang paling umum dijumpai adalah meningioma, pituitary adenoma, dan glioma [1].

Meskipun tumor otak bukan suatu penyakit yang umum dijumpai, tumor otak merupakan salah satu penyakit paling mematikan. Jumlah kasus tumor otak yang ditemukan hanya sekitar 1.6% dari seluruh kasus tumor yang dijumpai. Namun, perbandingan antara rata-rata jumlah kematian akibat tumor otak jenis glioma per tahun dengan rata-rata jumlah diagnosis baru per tahun di Amerika Serikat mencapai 60.98%. [2]

Pemindaian otak dengan *magnetic resonance imaging* (MRI) guna menghasilkan citra yang menggambarkan struktur di dalam otak merupakan salah satu prosedur yang paling banyak digunakan untuk mendiagnosis tumor otak [3]. MRI mampu menghasilkan citra yang menggambarkan *cross-sectional view* dari bagian tubuh tertentu dengan ketebalan

yang dispesifikasikan, baik berdasarkan bidang *horizontal*, *sagittal*, maupun *coronal*. Bidang *horizontal* merupakan bidang yang membagi tubuh menjadi bagian atas dan bawah, bidang *sagittal* merupakan bidang yang membagi tubuh menjadi bagian kiri dan kanan, serta bidang *coronal* merupakan bidang yang membagi tubuh menjadi bagian depan dan belakang. Sebuah citra hasil pemindaian MRI pada bidang tertentu dikenal juga dengan istilah *MRI slice*. Fig. 1 merupakan contoh citra hasil pemindaian MRI pada otak untuk bidang *sagittal*, *horizontal*, dan *coronal*.

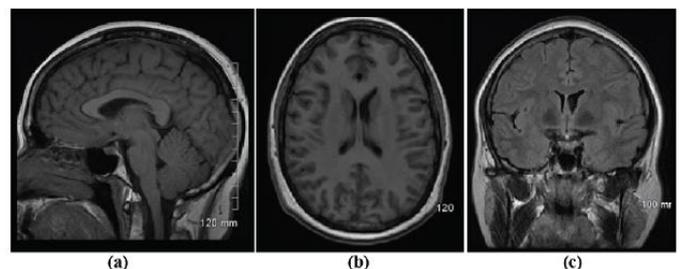


Fig. 1. Hasil pemindaian MRI pada otak untuk bidang (a) *sagittal*, (b) *horizontal*, dan (c) *coronal*. [4]

MRI *sequence* merupakan kumpulan karakteristik atau parameter gelombang radio yang mengatur bagaimana gelombang radio pada MRI dihasilkan dan ditangkap dalam pembentukan citra MRI. Contoh dari karakteristik gelombang radio yang diatur adalah *repetition time* (RT) dan *echo time* (TE). Dengan MRI *sequence* yang berbeda, citra MRI otak yang dihasilkan mampu memberikan gambaran terhadap jaringan yang berbeda pula. Dengan karakteristik dari tumor otak yang beragam, satu MRI *sequence* tidak cukup untuk memberikan gambaran komprehensif terhadap tumor otak. Oleh karena itu, umumnya digunakan berbagai MRI *sequence* yang berbeda sehingga menghasilkan citra MRI yang berbeda yang mampu memberi gambaran yang lebih jelas terhadap tumor otak. Jenis MRI *sequence* yang paling umum digunakan adalah T1-*weighted* dan T2-*weighted*. [5]

Fig. 2 merupakan contoh citra hasil pemindaian MRI pada otak untuk bidang *horizontal* dengan MRI *sequence* T1-*weighted* dan T2-*weighted*.

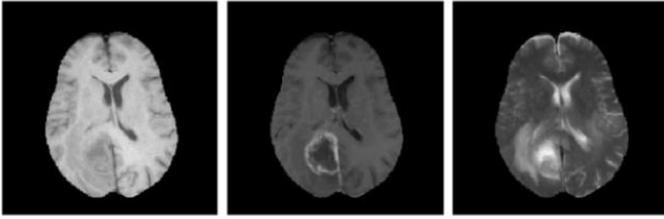


Fig. 2. Hasil pemindaian MRI pada otak untuk bidang *horizontal* berturut-turut dari kiri ke kanan dengan MRI *sequence* T1-weighted, T1-weighted dengan *contrast enhancement*, dan T2-weighted. [5]

Dengan berbagai parameter yang perlu dispesifikasikan dalam pemindaian MRI, seperti bidang pemindaian dan MRI *sequence*, maka jumlah citra yang dihasilkan dalam pemindaian MRI tidaklah sedikit. Analisis citra MRI yang dilakukan pada hasil pemindaian dalam jumlah banyak secara manual mengakibatkan proses analisis menjadi kurang efisien. Oleh karena itu, dibutuhkan suatu cara untuk membantu proses analisis citra MRI tersebut, salah satunya dalam proses pengklasifikasian tumor otak.

Dengan kemajuan dalam berbagai bidang dalam ranah komputasi, khususnya dalam bidang pengolahan citra, terdapat berbagai metode yang dapat diaplikasikan untuk membantu proses klasifikasi tumor otak sehingga tahap analisis citra MRI otak menjadi lebih efisien. Dalam penulisan *technical report* ini, metode analisis tekstur citra dimanfaatkan untuk mengekstraksi fitur-fitur dalam citra MRI otak. Fitur-fitur tersebut kemudian dijadikan masukan untuk sebuah jaringan saraf tiruan untuk mengklasifikasikan citra MRI otak tersebut, khususnya apakah terdapat tumor otak dalam citra hasil pemindaian dan apabila terdapat tumor otak, apa jenis tumor otak yang terdeteksi.

## II. LANDASAN TEORI

### A. Citra Digital

Citra digital merupakan representasi dari citra yang telah melalui proses digitalisasi sehingga siap untuk diolah oleh komputer. Hasil dari proses digitalisasi adalah kumpulan piksel-piksel yang membentuk suatu matriks berukuran  $M$  baris dan  $N$  kolom dengan setiap elemen dalam matriks menunjukkan intensitas piksel atau nilai keabuan pada posisi yang bersesuaian. Istilah skala keabuan atau derajat keabuan merujuk pada banyaknya nilai intensitas piksel yang mungkin untuk setiap piksel yang ada. [6]

Secara umum, citra digital dapat dibagi menjadi tiga jenis, yaitu citra biner, citra *grayscale*, dan citra berwarna. Citra biner merupakan citra yang setiap pikselnya berukuran 1 bit sehingga hanya terdapat dua kemungkinan nilai keabuan dari piksel dalam citra, yaitu 0 dan 1. Sementara itu, setiap piksel dalam citra *grayscale* umumnya direpresentasikan dalam 8 bit sehingga terdapat 256 kemungkinan nilai keabuan pada setiap piksel dalam citra, yaitu 0 hingga 255. Namun, skala keabuan dari citra *grayscale* dapat bervariasi. Citra biner merupakan representasi khusus dari citra *grayscale* dengan setiap piksel memiliki skala keabuan 2. [6]

Dibandingkan dengan citra biner dan citra *grayscale*, citra berwarna direpresentasikan dalam bentuk yang sedikit berbeda. Dalam citra berwarna, dikenal kanal warna yang merepresentasikan setiap komponen warna dalam citra. Jenis citra berwarna yang paling umum ditemukan direpresentasikan dalam tiga kanal warna, yaitu kanal R (*red*), G (*green*), dan B (*blue*) dengan setiap piksel dalam masing-masing kanal warna berukuran 8 bit sehingga setiap piksel dalam citra berwarna berukuran 24 bit. Citra berwarna yang setiap pikselnya berukuran 24 bit dikenal juga sebagai *true colour image*. Selain *true colour image*, terdapat jenis citra berwarna lainnya, yaitu *basic colour image* yang setiap pikselnya berukuran 8 bit, *high colour image* yang setiap pikselnya berukuran 16 bit, dan *deep colour image* yang setiap pikselnya berukuran 24 bit. Jumlah bit yang merepresentasikan setiap piksel menentukan jumlah warna yang mungkin pada setiap piksel. Untuk *true colour image*, terdapat 16,777,216 jumlah warna berbeda yang dapat direpresentasikan pada setiap pikselnya. [7]

Citra hasil pemindaian MRI umumnya berupa citra *grayscale* dengan 256 skala keabuan atau citra *true colour image* dengan tiga kanal warna yang mana setiap kanal memiliki nilai intensitas piksel yang sama untuk posisi yang bersesuaian sehingga menghasilkan warna keabuan.

### B. Gray Level Co-occurrence Matrix

*Gray Level Co-occurrence Matrix* (GLCM) merupakan salah satu metode ekstraksi tekstur citra yang didasarkan pada statistik orde dua. Untuk sebuah citra *grayscale*, matriks *co-occurrence* yang dibentuk berukuran  $N \times N$  dengan  $N$  adalah skala keabuan dari citra *grayscale*. Elemen dalam matriks *co-occurrence* ditentukan berdasarkan kombinasi nilai keabuan dalam citra *grayscale*. Elemen matriks *co-occurrence* pada posisi  $(x, y)$  menunjukkan jumlah piksel pada citra *grayscale* yang memiliki nilai intensitas  $x$  dan pada posisi yang berjarak  $\Delta i$  dan  $\Delta j$  dari piksel tersebut, terdapat piksel bernilai  $y$ . Persamaan (1) merupakan persamaan yang digunakan untuk membentuk matriks GLCM  $G$  dari citra *grayscale*  $M$ . [8]

$$G(x, y) = \sum_i \sum_j \begin{cases} 1 & \text{if } M(i, j) = x \text{ and } M(i + \Delta i, j + \Delta j) = y \\ 0 & \text{otherwise} \end{cases} \quad (1)$$

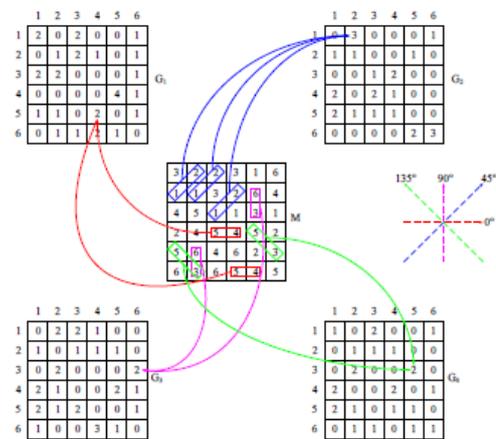


Fig. 3. Pembentukan matriks GLCM berdasarkan kombinasi piksel berjarak satu pada arah vertikal, arah horizontal, dan dua arah diagonal. [8]

Fig. 3 merupakan contoh pembentukan matriks GLCM untuk kombinasi piksel berjarak satu pada arah vertikal, arah horizontal, dan dua arah diagonal.

Hubungan spasial  $\Delta i$  dan  $\Delta j$  juga sering kali direpresentasikan dalam bentuk  $d$  dan  $\theta$  dengan  $d$  adalah jarak piksel dan  $\theta$  menunjukkan arah. Dalam pembentukan matriks GLCM pada Fig. 3, nilai  $d$  yang digunakan adalah 1 dan nilai  $\theta$  yang digunakan mencakup  $0^\circ, 45^\circ, 90^\circ,$  dan  $135^\circ$ .

Berdasarkan matriks GLCM yang telah dibentuk, terdapat beberapa properti tekstur citra yang dapat dikalkulasi. Beberapa contoh properti yang dapat diukur adalah *contrast*, *dissimilarity*, *homogeneity*, *ASM*, *energy*, dan *correlation* yang berturut-turut dapat dihitung dengan persamaan (2), (3), (4), (5), (6), dan (7). [9]

$$contrast = \sum_i \sum_j G_{i,j} (i - j)^2 \quad (2)$$

$$dissimilarity = \sum_i \sum_j G_{i,j} |i - j| \quad (3)$$

$$homogeneity = \sum_i \sum_j \frac{G_{i,j}}{1 + (i - j)^2} \quad (4)$$

$$ASM = \sum_i \sum_j G_{i,j}^2 \quad (5)$$

$$energy = \sqrt{ASM} \quad (6)$$

$$correlation = \sum_i \sum_j G_{i,j} \frac{(i - \mu_x)(j - \mu_y)}{\sqrt{(\sigma_x^2)(\sigma_y^2)}} \quad (7)$$

Nilai  $N$  merupakan skala keabuan citra *grayscale* dan  $G$  merupakan matriks *co-occurrence*. Nilai  $\mu_x, \mu_y, \sigma_x^2,$  dan  $\sigma_y^2$  dapat dihitung berturut-turut dengan persamaan (8), (9), (10), dan (11).

$$\mu_x = \sum_i \sum_j i \cdot G_{i,j} \quad (8)$$

$$\mu_y = \sum_i \sum_j j \cdot G_{i,j} \quad (9)$$

$$\sigma_x = \sum_i \sum_j (i - \mu_x)^2 G_{i,j} \quad (10)$$

$$\sigma_y = \sum_i \sum_j (j - \mu_y)^2 G_{i,j} \quad (11)$$

### C. Jaringan Saraf Tiruan

Jaringan saraf tiruan atau *artificial neural network* (ANN) merupakan suatu model komputasi dalam bidang pembelajaran machine (*machine learning*) yang meniru cara kerja otak manusia. Jaringan saraf tiruan terbentuk atas beberapa lapisan (*layer*). Konfigurasi lapisan penyusun jaringan saraf tiruan dapat beragam. Umumnya, terdapat satu lapisan masukan, satu lapisan keluaran, dan satu atau lebih lapisan tersembunyi di antara keduanya. Namun, pada jaringan saraf yang landai, mungkin tidak terdapat lapisan tersembunyi sama sekali. [10]

Setiap lapisan dalam jaringan saraf tiruan tersusun atas satu atau lebih simpul atau neuron. Setiap neuron terhubung dengan neuron yang berada di lapisan sebelumnya dan di lapisan

sesudahnya. Dalam setiap hubungan antarneuron, terdapat bobot yang diasosiasikan dengan hubungan tersebut. Neuron bertugas untuk memproses masukan yang diterima dari neuron di lapisan sebelumnya dan menghasilkan keluaran yang akan diterima oleh neuron pada lapisan selanjutnya. Hal tersebut mirip dengan neuron pada otak manusia yang terhubung satu sama lain. Setiap neuron bertugas untuk melakukan suatu *task* sederhana, yang mana secara akumulatif kumpulan neuron yang terhubung satu sama lain dapat menyelesaikan *task* yang lebih kompleks, seperti pengenalan objek atau suara. [10]

Proses yang dilakukan pada setiap neuron adalah mengalkulasi kombinasi linier masukan-masukan yang diterimanya. Bobot untuk setiap komponen diambil sesuai dengan bobot hubungan neuron tersebut dengan neuron yang meneruskan komponen yang bersesuaian. Persamaan (12) menunjukkan perhitungan yang dilakukan pada setiap neuron.

$$y = f \left( \sum_{i=0}^n w_i x_i + b \right) \quad (12)$$

$y$  merupakan keluaran neuron,  $w_i$  merupakan bobot yang diasosiasikan dengan masukan  $x_i$ ,  $n$  adalah jumlah masukan, dan  $b$  adalah bias. Fungsi  $f$  merupakan sebuah fungsi aktivasi nonlinier yang bertujuan agar model mampu mempelajari hubungan kompleks antardata. Contoh dari fungsi aktivasi adalah *exponential linear unit* (ELU) dan softmax. Formula untuk fungsi aktivasi ELU dan softmax berturut-turut dapat dilihat pada persamaan (13) dan (14).

$$ELU(x) = \begin{cases} x, & x \geq 0 \\ \alpha(e^x - 1), & x < 0 \end{cases} \quad (13)$$

$$softmax(z_i) = \frac{e^{z_i}}{\sum_{k=1}^K e^{z_k}} \quad (14)$$

Fungsi aktivasi ELU merupakan fungsi yang mirip dengan fungsi *rectified linear unit* (ReLU). Fungsi aktivasi ReLU mengembalikan nilai masukan apabila masukan nonnegatif, sedangkan untuk masukan negatif, fungsi aktivasi ELU mengembalikan nilai 0. Baik fungsi aktivasi ELU, maupun ReLU merupakan fungsi identitas untuk masukan nonnegatif. Namun, untuk masukan negatif, fungsi aktivasi ReLU memiliki lonjakan nilai gradien di sekitar nilai 0, sedangkan fungsi aktivasi ELU tidak. [11]

Fungsi aktivasi softmax merupakan fungsi aktivasi yang umum digunakan pada lapisan keluaran jaringan saraf tiruan yang melakukan *multi-class classification*. Nilai  $z_i$  merupakan nilai keluaran yang *unnormalized* yang diasosiasikan dengan kelas ke- $i$ . Keluaran fungsi softmax untuk masukan  $z_i$  merupakan probabilitas untuk kelas ke- $i$ .

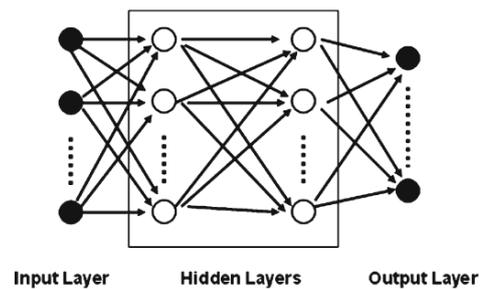


Fig. 4. Arsitektur jaringan saraf tiruan. [10]

Fig. 4 memberikan gambaran terkait arsitektur jaringan saraf tiruan secara umum.

#### D. Metrik Pengukuran Kinerja

Pengukuran kinerja dari model pengklasifikasian umumnya dilakukan berdasarkan nilai-nilai dalam *confusion matrix*. Setiap entri dalam *confusion matrix* mencerminkan jumlah data pada kelas tertentu yang diprediksi memiliki kelas tertentu. *Table I* menunjukkan struktur *confusion matrix* untuk klasifikasi biner.

TABLE I. *CONFUSION MATRIX* UNTUK KLASIFIKASI BINER

<i>Class \ Prediction</i>	<i>Positive</i>	<i>Negative</i>
<i>Positive</i>	<i>true positive (tp)</i>	<i>false negative (fn)</i>
<i>Negative</i>	<i>false positive (fp)</i>	<i>true negative (tn)</i>

Berdasarkan nilai-nilai dalam *confusion matrix*, terdapat beberapa metrik pengukuran kinerja model yang dapat dihitung, seperti *accuracy*, *precision*, dan *recall*. Nilai *accuracy* menunjukkan proporsi jumlah data yang diklasifikasikan dengan tepat oleh model terhadap jumlah keseluruhan data. Nilai *precision* menunjukkan proporsi jumlah data dengan kelas positif yang diklasifikasikan positif terhadap jumlah data yang diklasifikasikan positif. Nilai *recall* menunjukkan proporsi jumlah data dengan kelas positif yang diklasifikasikan positif terhadap jumlah data dengan kelas positif.

Persamaan (15), (16), dan (17) berturut-turut merupakan persamaan yang digunakan untuk menghitung nilai *accuracy*, *precision*, dan *recall* berdasarkan *confusion matrix*.

$$accuracy = \frac{tp + tn}{tp + fp + fn + tn} \quad (15)$$

$$precision = \frac{tp}{tp + fp} \quad (16)$$

$$recall = \frac{tp}{tp + fn} \quad (17)$$

### III. METODOLOGI

#### A. Akuisisi Dataset Citra MRI Otak

Dalam pengembangan model pengklasifikasian tumor otak berbasis analisis tekstur citra MRI, dibutuhkan *dataset* citra MRI otak. Data citra MRI otak tersebut diperoleh dari [12] yang berisi 7,023 citra MRI otak berlabel sesuai jenis tumor otak yang ada dalam citra tersebut. Data citra MRI otak tersebut terbagi menjadi empat kelas. Tiga kelas di antaranya merupakan jenis tumor otak yang umum ditemukan, yaitu glioma, meningioma, dan pituitary serta satu kelas lainnya adalah notumor yang berarti tidak ada tumor di dalam citra MRI otak. Proporsi jumlah citra untuk tiap kelas adalah 1,621 citra dengan kelas glioma, 1,645 citra dengan kelas meningioma, 1,757 citra dengan kelas pituitary, dan 2,000 citra dengan kelas notumor.

Berikut ini adalah contoh citra MRI otak yang terkandung di dalam *dataset*. Fig. 5 merupakan contoh citra dengan kelas glioma. Fig. 6 merupakan contoh citra dengan kelas meningioma. Fig. 7 merupakan contoh citra dengan kelas pituitary. Fig. 8 merupakan contoh citra dengan kelas notumor.

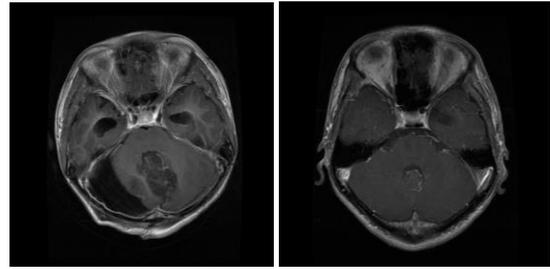


Fig. 5. Citra MRI otak dengan kelas glioma. [12]

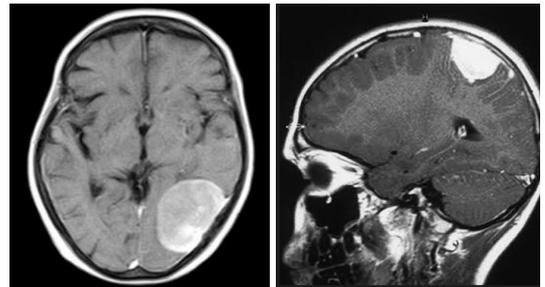


Fig. 6. Citra MRI otak dengan kelas meningioma. [12]

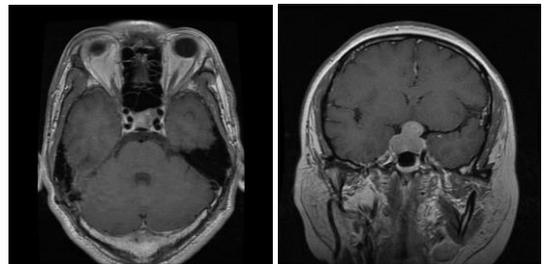


Fig. 7. Citra MRI otak dengan kelas pituitary. [12]

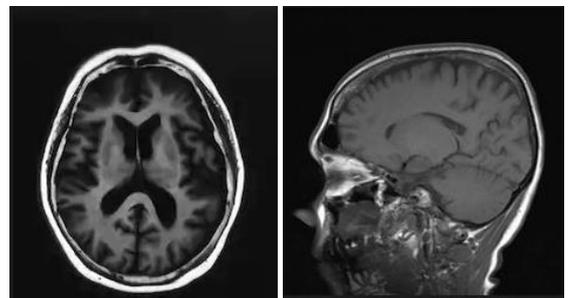


Fig. 8. Citra MRI otak dengan kelas notumor. [12]

#### B. Pembentukan Matriks GLCM dan Kalkulasi Properti Tekstur Citra

Setelah data citra MRI otak diperoleh, matriks GLCM untuk setiap citra dalam *dataset* dibentuk. Dalam pembentukan matriks GLCM, nilai parameter *d* yang digunakan adalah 1 dan

nilai  $\theta$  yang digunakan adalah  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$ , dan  $135^\circ$ . Dengan demikian, untuk setiap citra MRI otak, dibentuk empat matriks GLCM, yaitu satu matriks GLCM untuk masing-masing nilai  $\theta$ . Dari masing-masing matriks GLCM, dikalkulasi enam properti tekstur, yaitu *contrast*, *dissimilarity*, *homogeneity*, *ASM*, *energy*, dan *correlation*. Oleh karena itu, untuk setiap citra MRI otak, akan dihasilkan 24 nilai properti tekstur sebagai hasil kombinasi nilai  $\theta$  dan properti tekstur yang dikalkulasi. Fig. 9 merupakan contoh hasil ekstraksi properti tekstur dari salah satu citra MRI otak. Penamaan untuk masing-masing fitur adalah nama properti tekstur diikuti dengan karakter garis bawah ( $\_$ ), dan diakhiri dengan nilai  $\theta$  yang menunjukkan matriks GLCM yang digunakan untuk mengalkulasi nilai properti tekstur.

contrast_0	43.502783	ASM_0	0.10779
contrast_45	74.696888	ASM_45	0.104657
contrast_90	41.759892	ASM_90	0.108917
contrast_135	83.532922	ASM_135	0.104631
dissimilarity_0	2.76428	energy_0	0.328315
dissimilarity_45	3.743881	energy_45	0.323507
dissimilarity_90	2.790125	energy_90	0.330025
dissimilarity_135	3.883602	energy_135	0.323468
homogeneity_0	0.620115	correlation_0	0.986142
homogeneity_45	0.574687	correlation_45	0.976224
homogeneity_90	0.61638	correlation_90	0.986697
homogeneity_135	0.570742	correlation_135	0.973412

Fig. 9. Hasil ekstraksi properti tekstur citra.

#### C. Desain Arsitektur dan Pelatihan Jaringan Saraf Tiruan

Sebuah jaringan saraf tiruan dibentuk untuk memprediksi kelas citra MRI otak berdasarkan hasil ekstraksi properti tekstur. Arsitektur jaringan saraf yang dibentuk terdiri dari satu lapisan masukan, lima lapisan tersembunyi, dan satu lapisan keluaran. Berikut adalah deskripsi arsitektur jaringan saraf yang dibentuk.

1. Lapisan masukan memiliki 24 neuron.
2. Lapisan tersembunyi pertama memiliki 32 neuron dengan fungsi aktivasi ELU.
3. Lapisan tersembunyi kedua memiliki 1024 neuron dengan fungsi aktivasi ELU.
4. Lapisan tersembunyi ketiga memiliki 512 neuron dengan fungsi aktivasi ELU.
5. Lapisan tersembunyi keempat memiliki 256 neuron dengan fungsi aktivasi ELU.
6. Lapisan tersembunyi kelima memiliki 128 neuron dengan fungsi aktivasi ELU.
7. Lapisan keluaran memiliki 4 neuron dengan fungsi aktivasi softmax.

Sebelum digunakan untuk pelatihan, dilakukan *decimal scaling* terhadap setiap atribut hasil ekstraksi properti tekstur. Setelah itu, data dipecah menjadi data latih dan data tes dengan proporsi 80% data latih dan 20% data tes. Pelatihan dilakukan dengan *mini-batch gradient descent* dengan ukuran *batch* 100 dan jumlah *epoch* 1000.

#### D. Evaluasi Kinerja Model

Untuk masukan tertentu, model yang dilatih memberikan keluaran probabilitas dari setiap kelas yang ada. Prediksi kelas diambil dari kelas dengan probabilitas tertinggi. Evaluasi kinerja model dilakukan terhadap data tes dengan menggunakan tiga metrik pengukuran, yaitu *accuracy*, *precision*, dan *recall*.

### IV. HASIL

Berdasarkan hasil evaluasi kinerja, model pengklasifikasian tumor otak berbasis analisis tekstur citra MRI otak mampu memprediksi kelas citra MRI otak dengan *accuracy* 90.96%, *precision* 90.79%, dan *recall* 90.73%.

Fig. 10, Fig. 11, Fig. 12, dan Fig. 13 merupakan contoh prediksi kelas citra MRI otak dengan menggunakan model yang telah dilatih.

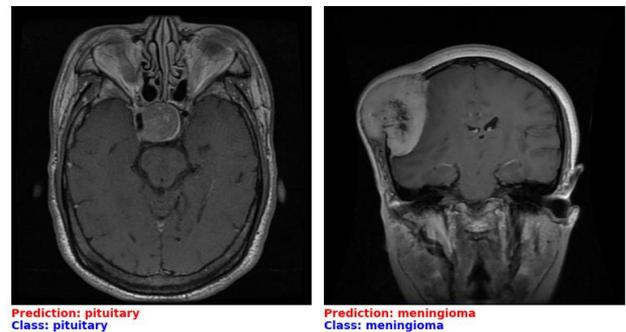


Fig. 10. Prediksi kelas citra MRI otak.

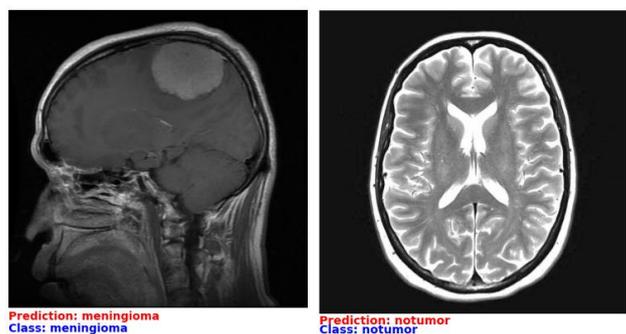


Fig. 11. Prediksi kelas citra MRI otak.



Fig. 12. Prediksi kelas citra MRI otak.

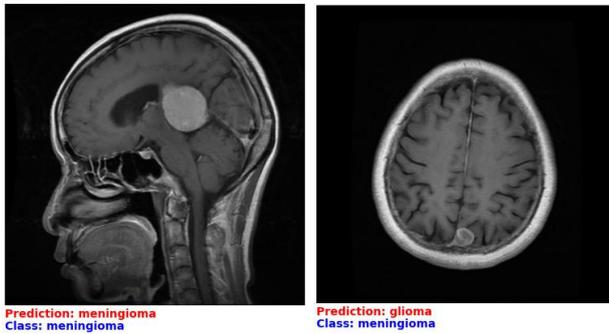


Fig. 13. Prediksi kelas citra MRI otak.

## V. KESIMPULAN

Analisis tekstur citra merupakan salah satu metode yang dapat digunakan untuk mengklasifikasikan citra MRI otak sehingga dapat ditentukan apakah otak yang dipindai memiliki tumor. Dengan membentuk matriks GLCM dan mengekstraksi properti tekstur dari *dataset* citra MRI otak, dapat diperoleh data yang dapat digunakan untuk pelatihan model jaringan saraf tiruan. Jaringan saraf tiruan yang dibentuk terdiri atas satu lapisan masukan, lima lapisan tersembunyi, dan satu lapisan keluaran. Pelatihan model tersebut bertujuan agar model mampu mengklasifikasikan data yang berisi properti tekstur citra ke dalam salah satu kelas dari empat kelas terdefinisi, yaitu glioma, meningioma, pituitary, dan notumor. Berdasarkan hasil evaluasi, model mampu melakukan klasifikasi dengan *accuracy* 90.96%, *precision* 90.79%, dan *recall* 90.73%.

### REPOSITORY GITHUB

<https://github.com/feraldy112/brain-tumor-classification>

### UCAPAN TERIMA KASIH

Penulis memanjatkan puji dan syukur kepada Tuhan Yang Maha Esa karena berkat rahmat dan karunia-Nya penulis dapat menyelesaikan penulisan makalah ini. Penulis juga berterima kasih kepada Bapak Rinaldi Munir sebagai dosen mata kuliah IF4073 Interpretasi dan Pengolahan Citra atas pengetahuan, bimbingan, dan kesempatan yang diberikan sehingga makalah ini dapat terselesaikan dengan baik. Penulis sadar bahwa makalah ini masih jauh dari kata sempurna. Oleh karena itu,

penulis mengharapkan kritik dan saran yang membangun dari pembaca.

## REFERENCES

- [1] Johns Hopkins Medicine, "Brain tumor types," Johns Hopkins Medicine, Available: <https://www.hopkinsmedicine.org/health/conditions-and-diseases/brain-tumor/brain-tumor-types>.
- [2] J. Wahyuhadi, "Tantangan penanganan tumor otak di Indonesia," *Republika*, Available: <https://news.republika.co.id/berita/ryaqbs291/tantangan-penanganan-tumor-otak-di-indonesia>.
- [3] L. M. DeAngelis, "Brain tumors," *The New England Journal of Medicine*, vol. 344, no. 2, pp. 114–123, Jan. 2001. doi: 10.1056/nejm200101113440207.
- [4] P. S. S. Kumar and V. S. Dharum, "A study of MRI segmentation methods in automatic brain tumor detection," *International Journal of Engineering and Technology*, vol. 8, no. 2, pp. 609–614, 2016, ISSN: 0975-4024.
- [5] S. Bauer, R. Wiest, L. Nolte, and M. Reyes, "A survey of MRI-based medical image analysis for brain tumor studies," *Physics in Medicine and Biology*, vol. 58, no. 13, pp. R97–R129, Jun. 2013, doi: 10.1088/0031-9155/58/13/r97.
- [6] R. Munir, "03 – Pembentukan citra dan digitalisasi citra," *Homepage Rinaldi Munir*, Available: <https://informatika.stei.itb.ac.id/~rinaldi.munir/Citra/2022-2023/>.
- [7] C. Saravanan, "Color image to grayscale image conversion," in 2010 Second International Conference on Computer Engineering and Applications, Apr. 2010, Bali, Indonesia [Online], doi: 10.1109/ICCEA.2010.192.
- [8] R. Vyas, T. Kanumuri, G. Sheoran, and P. Dubey, "Co-occurrence features and neural network classification approach for iris recognition," in 2017 Fourth International Conference on Computer Engineering and Applications, Dec. 2017, JUIT, Solan [Online], doi: 2017 Fourth International Conference on Image Information Processing.
- [9] Scikit-Image, "Skimage feature," Scikit-Image, Available: <https://scikit-image.org/docs/stable/api/skimage.feature.html>.
- [10] J. Zou, Y. Han, and S. S. So, "Overview of artificial neural networks," *Artificial Neural Networks*, pp. 14–22, doi: 10.1007/978-1-60327-101-1\_2.
- [11] S. Singh, "ELU as an activation function in neural networks," *Deep Learning University*, Available: <https://deeplearninguniversity.com/elu-as-an-activation-function-in-neural-networks/>.
- [12] M. Nickparvar, "Brain tumor MRI dataset," *Kaggle*, Available: <https://www.kaggle.com/datasets/masoudnickparvar/brain-tumor-mri-dataset>.

## PERNYATAAN

Dengan ini saya menyatakan bahwa makalah yang saya tulis ini adalah tulisan saya sendiri, bukan saduran, atau terjemahan dari makalah orang lain, dan bukan plagiasi.

Bandung, 19 Desember 2023

Fernaldy  
13520112