

Perbandingan Ekstraksi Fitur Untuk Klasifikasi COVID-19, MERS, dan SARS Menggunakan Algoritma *Extreme Learning Machine*

Khofifah Auliyatuz Zahroh¹, Dian Candra Rini Novitasari², Lutfi Hakim³

¹²³*Program Studi Matematika, Fakultas Sains dan Teknologi, UIN Sunan Ampel
Jl. Ahmad Yani No.117 Surabaya, Jawa Timur, Indonesia*

Korespondensi; Khofifah Auliyatuz Zahroh, Email: khofifahauliya12@gmail.com

Abstrak

Pada tahun 2019, terjadi kemunculan suatu wabah penyakit COVID-19. Wabah penyakit tersebut telah mengguncang dunia sehingga menyebabkan pandemi secara global. Selain COVID-19, terdapat dua wabah penyakit lain juga diakibatkan oleh virus *corona* yaitu MERS (*Middle East Respiratory Syndrome*) dan SARS (*Severe Acute Respiratory Syndrome*) yang sudah menjadi ancaman serius pada beberapa dekade terakhir. Ketiga wabah penyakit tersebut menyebabkan jutaan kasus serta ribuan orang yang meninggal di seluruh dunia. Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk melakukan klasifikasi penyakit COVID-19, MERS, dan SARS berdasarkan hasil pemeriksaan *X-ray* menggunakan perbandingan ekstraksi fitur GLCM (*Gray Level Co-occurrence Matrix*) dan GLDM (*Gray Level Difference Matrix*) serta klasifikasi ELM (*Extreme Learning Machine*). Pada penelitian ini menggunakan beberapa parameter uji coba diantaranya yaitu arah sudut, jumlah *k* pada *k-fold*, serta jumlah *hidden node*. Hasil terbaik pada penelitian ini diperoleh menggunakan metode ekstraksi fitur GLDM dengan uji coba pada sudut 135°, *k-fold* 10, serta *hidden node* 25 yang menghasilkan akurasi, sensitivitas, dan spesifisitas masing-masing sebesar 100% dengan waktu yang dibutuhkan yaitu 0.00042 detik. Sehingga, dapat disimpulkan bahwa hasil ekstraksi fitur GLDM lebih unggul daripada ekstraksi fitur GLCM.

Kata Kunci: ELM, GLCM, GLDM, Virus *Corona*

Abstract

In 2019, there was an outbreak of the COVID-19 disease. The disease outbreak has shaken the world, causing a global pandemic. In addition to COVID-19, there are two other disease outbreaks also caused by the coronavirus, namely MERS (*Middle East Respiratory Syndrome*) and SARS (*Severe Acute Respiratory Syndrome*) which have become serious threats in recent decades. These three disease outbreaks have caused millions of cases and thousands of deaths around the world. Based on these problems, this study aims to classify COVID-19, MERS, and SARS diseases based on *X-ray* examination results using a comparison of GLCM (*Gray Level Co-occurrence Matrix*) and GLDM (*Gray Level Difference Matrix*) feature extraction and ELM (*Extreme Learning Machine*) classification. In this study using several test parameters including the direction of the angle, the number of *k* in *k-fold*, and the number of hidden nodes. The best results in this study were obtained using the GLDM feature extraction method with a trial at an angle of 135°, *k-fold* 10, and hidden node 25 which resulted in accuracy, sensitivity, and specificity of 100% each with the time required of 0.00042 seconds. Thus, it can be concluded that the results of GLDM feature extraction are superior to GLCM feature extraction.

Keywords: Corona Virus, ELM, GLCM, GLDM

Pendahuluan

Pada tahun 2019 terjadi suatu wabah penyakit yang diakibatkan oleh virus *corona*, yaitu COVID-19 (*Corona Virus Disease-19*). COVID-19 pertama kali dilaporkan terdeteksi di Wuhan, China dan kemudian menyebar secara cepat ke seluruh dunia, sehingga COVID-19 ditetapkan sebagai pandemi *global* [1]. Berdasarkan laporan data oleh WHO (*World Health Organization*), tercatat total kasus positif COVID-19 di dunia yaitu sebanyak 312.173.462 kasus dengan total orang meninggal dunia akibat COVID-19 sebanyak 5.501.000 orang [2]. Selain wabah penyakit COVID-19, terdapat penyakit lain yang pernah terjadi sebelumnya dan juga diakibatkan oleh virus *corona* yaitu MERS (*Middle East Respiratory Syndrome*) dan SARS (*Severe Acute Respiratory Syndrome*). Wabah penyakit MERS terjadi di tahun 2012 dengan total kasus di dunia sebanyak 2.499 kasus dan 861 orang yang meninggal dunia, sedangkan wabah penyakit SARS terjadi pada tahun 2002 dengan total terinfeksi SARS di dunia sebanyak 8.098 orang dan 774 orang yang meninggal dunia [3]. Penyakit COVID-19, MERS, SARS memiliki gejala yang hampir sama diantaranya yaitu demam tinggi, batuk, sesak napas, dan sebagainya [4]. Oleh karena itu, perlu adanya diagnosis ketiga penyakit tersebut dengan melalui pemeriksaan *X-ray* untuk mengetahui kondisi dari paru-paru. Diagnosis penyakit COVID-19, MERS, dan SARS menjadi hal yang harus dilakukan secara cepat dan akurat agar penyakit tersebut dapat segera ditangani lebih lanjut.

Saat ini, teknologi telah berkembang dengan cepat dalam berbagai bidang termasuk pada bidang kesehatan yang menggunakan sistem CAD (*Computer Aided Diagnosis*) untuk melakukan diagnosis penyakit melalui citra *X-ray* dengan melalui tahapan *preprocessing*, ekstraksi fitur, kemudian klasifikasi [5]. Tahap *preprocessing* bertujuan untuk memperbaiki citra yang memiliki kualitas kurang baik, karena hal tersebut dapat mempengaruhi hasil klasifikasi [6]. *Preprocessing* yang digunakan pada penelitian ini adalah metode CLAHE (*Contrast Limited Adaptive Histogram Equalization*) dan *median filter*. Tahap selanjutnya yaitu ekstraksi fitur bertujuan untuk mendapatkan suatu informasi tekstur yang terdapat pada citra [7]. Terdapat dua metode ekstraksi fitur yang digunakan sebagai perbandingan pada penelitian ini yaitu GLCM (*Gray Level Co-occurrence Matrix*) dan GLDM (*Gray Level Difference Matrix*). Metode GLCM (*Gray Level Co-occurrence Matrix*) mengekstraksi tekstur suatu citra sehingga menghasilkan empat fitur utama yaitu energi, kontras, homogenitas, dan korelasi [8]. Berbagai penelitian menggunakan metode GLCM yang sebelumnya pernah dilakukan seperti penelitian yang menggunakan citra jerawat pada wajah untuk mengidentifikasi jenis *acne vulgaris* menggunakan GLCM dan klasifikasi ELM. Hasil penelitian tersebut memperoleh akurasi tertinggi sebesar 95,24% [9]. Selain itu, penelitian lain yang membahas perbandingan metode GLCM dengan ekstraksi fitur orde pertama. Penelitian tersebut bertujuan untuk melakukan klasifikasi citra *mammogram* menggunakan metode SVM (*Support Vector Machine*) dan memberikan hasil akurasi terbaik pada metode ekstraksi fitur GLCM sebesar 89% [10].

Pada metode ekstraksi fitur GLDM (*Gray Level Difference Matrix*) melakukan ekstraksi tekstur dari sebuah citra dengan menghitung perbedaan piksel pada arah vertikal dan diagonal. Hasil dari GLDM berupa lima fitur yaitu GC (*Gradient Contrast*), GSM (*Gradient Second Moment*), GE (*Gradient Entropy*), GM (*Gradient Mean*), dan IDM (*Inverse Differences Moment*) [11]. Terdapat penelitian sebelumnya yang menggunakan ekstraksi fitur GLDM untuk melakukan deteksi diabetik retinopati dengan menggunakan FFNN (*Feedforward Neural Network*) yang memperoleh hasil akurasi sebesar 95% [12].

Tahapan selanjutnya yang dilakukan setelah ekstraksi fitur yaitu klasifikasi. Metode klasifikasi yang digunakan pada penelitian ini yaitu ELM (*Extreme Learning Machine*) dengan perbandingan ekstraksi fitur GLCM (*Gray Level Co-occurrence Matrix*) dan GLDM (*Gray Level Difference Matrix*). Metode ELM merupakan salah satu dari algoritma *feedforward neural network* yang hanya memiliki satu *hidden layer* atau disebut dengan SLFNs (*Single Hidden Layer Feedforward Neural Networks*) [13]. Keunggulan dari ELM yaitu dapat melakukan proses *training* secara cepat [14]. Oleh karena itu, metode tersebut banyak digunakan oleh beberapa penelitian sebelumnya, seperti pada penelitian yang

menggunakan metode ELM untuk mengklasifikasi suatu penyakit tumor otak dengan hasil akurasi yang diperoleh yaitu 86% [15]. Terdapat juga penelitian yang melakukan perbandingan ELM dengan metode *Backpropagation* untuk klasifikasi prestasi akademik mahasiswa yang menunjukkan bahwa ELM memperoleh tingkat kesalahan paling rendah sebesar 14.84% dibandingkan *Backpropagation* sebesar 20.12% [16].

Pada penelitian sebelumnya yang menggunakan metode MLP (*Multilayer Perceptron*) dan GLCM untuk mengklasifikasikan COVID-19 dan SARS memperoleh hasil akurasi sebesar 91,67% [17]. Berdasarkan penelitian tersebut, maka pada penelitian ini dilakukan pengembangan dengan menambahkan metode ekstraksi fitur GLDM untuk membandingkan hasil dari metode ekstraksi fitur GLCM dengan GLDM. Oleh karena itu, penelitian ini memiliki tujuan untuk mengklasifikasi COVID-19, MERS, dan SARS menggunakan metode ELM dengan perbandingan metode ekstraksi fitur GLCM dengan GLDM.

Landasan Teori

1. CLAHE

CLAHE (*Contrast Limited Adaptive Histogram Equalization*) merupakan salah satu tahap *preprocessing* yang bertujuan untuk memperbaiki kualitas citra dengan memberikan batasan kontras pada citra agar tidak terjadi peningkatan kontras yang berlebihan [18]. Metode ini bekerja pada setiap piksel suatu citra yang disebut dengan *tile*. Pada setiap *tile* dilakukan perbaikan kontras dengan memotong histogram berdasarkan nilai *clip limit*. Histogram yang melebihi nilai *clip limit* kemudian dilakukan distribusi ke bagian lainnya [19]. Perhitungan nilai *clip limit* dapat dilakukan dengan menggunakan rumus yang terdapat pada Persamaan (1).

$$\beta = \frac{x}{y} \left(1 + \frac{\alpha}{100} (S_{max} - 1) \right) \quad (1)$$

dimana, β merupakan *clip limit*, x merupakan ukuran pada *tile*, y merupakan nilai *grayscale*, α merupakan nilai *clip factor*, dan S_{max} merupakan nilai kontras maksimum. Kontras pada setiap *tile* yang telah diperbaiki kemudian digabungkan menggunakan interpolasi bilinear agar hasil *tile* yang digabungkan terlihat halus.

2. Median Filter

Median filter merupakan metode yang bertujuan untuk mengurangi *noise* pada sebuah citra [20]. Proses dari metode ini yaitu mencari nilai *median* dengan mengurutkan nilai-nilai piksel pada setiap *window* kemudian mengganti nilai piksel yang berada di tengah *window* dengan nilai hasil *median* [21]. Umumnya, *window* yang digunakan berukuran 3×3 . Perhitungan *median filter* dapat dilakukan berdasarkan Persamaan (2).

$$f(x, y) = \text{median}\{g(x, y)\} \quad (2)$$

dimana, x, y merupakan ukuran dari *window*, $f(x, y)$ merupakan hasil *median filter*, dan $g(x, y)$ merupakan nilai piksel pada *window*.

3. GLCM

GLCM (*Gray Level Co-occurrence Matrix*) merupakan metode ekstraksi tekstur suatu citra berdasarkan frekuensi hubungan intensitas keabuan antara pasangan piksel bertetangga berdasarkan jarak dan orientasi arah sudut tertentu [22]. Terdapat empat arah sudut yang digunakan pada GLCM yaitu 0° , 45° , 90° , dan 135° . GLCM melakukan ekstraksi tekstur menghasilkan beberapa fitur yang umumnya digunakan diantaranya yaitu energi, kontras, homogenitas, dan korelasi [23]. Berdasarkan keempat fitur tersebut dapat dihitung menggunakan rumus yang terdapat pada Persamaan (3) – (6).

$$energi = \sum_{i,j} p(i,j)^2 \quad (3)$$

$$kontras = \sum_{i,j} p(i,j) |i - j|^2 \quad (4)$$

$$homogenitas = \sum_{i,j} p(i,j) \frac{1}{1+|i-j|^2} \quad (5)$$

$$korelasi = \sum_{i,j} \frac{p(i,j)(i-\mu_i)(j-\mu_j)}{\sigma_i \sigma_j} \quad (6)$$

dimana, $p(i,j)$ merupakan nilai matriks *co-occurrence* berdasarkan baris i dan kolom j , μ merupakan nilai rata-rata, σ merupakan nilai standar deviasi.

4. GLDM

GLDM (*Gray Level Difference Matrix*) merupakan metode ekstraksi fitur yang digunakan untuk mendapatkan informasi tekstur yang terdapat pada suatu citra. Metode ini berfokus pada perbedaan absolut dari intensitas keabuan antara kedua piksel yang dipisahkan oleh jarak tertentu dengan menghitung jumlah frekuensi kemunculan perbedaan intensitas keabuan tersebut [24]. Beberapa fitur statistik yang didapatkan dari ekstraksi GLDM yaitu GC (*Gradient Contrast*), GSM (*Gradient Second Moment*), GE (*Gradient Entropy*), GM (*Gradient Mean*), dan IDM (*Inverse Differences Moment*) [11]. Fitur-fitur tersebut dapat dihitung menggunakan Persamaan (7) – (11).

$$GC = \sum_g g^2 h(g|\theta) \quad (7)$$

$$GSM = \sum_g [h(g|\theta)]^2 \quad (8)$$

$$GE = -\sum_g h(g|\theta) \times \log h(g|\theta) \quad (9)$$


$$GM = \sum_g h(g|\theta) \times g \quad (10)$$

$$IDM = \sum_g \frac{h(g|\theta)}{(g^2+1)} \quad (11)$$

dimana, θ merupakan arah piksel yang dekat dengan jarak. θ dapat berupa sudut $0^\circ, 45^\circ, 90^\circ, 135^\circ$.

5. K-fold Cross Validation


K-fold Cross Validation merupakan metode yang berguna untuk melakukan pembagian data menjadi data pelatihan dan data pengujian. Metode ini memiliki konsep yaitu data dibagi menjadi k subset dengan jumlah pembagian yang sama besar kemudian dilakukan proses pelatihan dan pengujian, dimana $k - 1$ sebagai data pelatihan dan sisanya merupakan data pengujian [25]. Terdapat ilustrasi dari proses *cross validation* dengan $k = 5$ pada Gambar 1.



Gambar 1. Proses *K-fold Cross Validation*.

6. ELM

ELM (*Extreme Learning Machine*) termasuk dari salah satu algoritma FFNN (*Feedforward Neural Network*) yang hanya memiliki satu *hidden layer* atau dapat disebut juga dengan istilah SLFN (*Single Hidden Layer Feedforward Neural Networks*) [13]. Metode ini memiliki kemampuan yang unggul yaitu dapat melakukan proses pelatihan secara cepat serta dapat memberikan hasil kinerja generalisasi yang lebih baik [26]. Terdapat parameter ELM yang dapat ditentukan yaitu jenis fungsi aktivasi dan jumlah *node* yang terdapat pada *hidden*. ELM memiliki arsitektur yang divisualisasikan pada Gambar 2.



Gambar 2. Arsitektur ELM.

Berdasarkan arsitektur pada Gambar 2 dapat dilihat bahwa ELM terdiri dari 3 *layer* yaitu *input layer*, *hidden layer*, dan *output layer*. Selain itu, terdapat dua proses perhitungan dari metode ELM yaitu pelatihan yang dilakukan untuk memperoleh model optimal dan pengujian yang dilakukan untuk mengevaluasi hasil proses pelatihan [27]. Langkah-langkah perhitungan pada proses pelatihan dan pengujian metode ELM sebagai berikut.

Proses pelatihan

1. Melakukan *input* data untuk pelatihan.
2. Menginisialisasi bias, bobot, dan jumlah *node* pada *hidden* secara *random*.
3. Menghitung *output hidden layer* menggunakan Persamaan (12).

$$H_{init} = (\sum_{i=1}^n x_i \times w_{ij}) + b_j \quad (12)$$

dimana, H_{init} merupakan *output hidden layer*, x merupakan data, w merupakan bobot, dan b merupakan bias.

4. Menghitung fungsi aktivasi *sigmoid* menggunakan Persamaan (13).

$$f(x) = \frac{1}{1 + e^{-H_{init}}} \quad (13)$$

5. Melakukan transpose matriks *output hidden layer* dan mengalikan matriks H dengan *output hidden layer* hasil transpose (H^T).

6. Menghitung matriks *moore penrose pseudoinverse* menggunakan Persamaan (14).

$$H^\dagger = (H^T H)^{-1} H^T \quad (14)$$

dimana, $H^\dagger$ merupakan matriks *moore penrose pseudoinverse* dan H merupakan matriks *hidden layer*.

7. Menghitung *output* bobot menggunakan Persamaan (15).

$$\beta = H^\dagger \times t \quad (15)$$

dimana, β merupakan *output* bobot dan t merupakan target.

Proses pengujian

1. Melakukan *input* data untuk pengujian.

2. Menghitung *output hidden layer* dan fungsi aktivasi berdasarkan bobot dan bias yang didapatkan pada proses pelatihan. Perhitungan tersebut dilakukan menggunakan rumus pada Persamaan (12) dan (13).
3. Menghitung *output layer* dengan β yang didapatkan pada proses pelatihan menggunakan Persamaan (16).

$$Y = H \times \beta \quad (16)$$

dimana, Y merupakan *output layer*.

7. Confusion Matrix

Confusion Matrix merupakan metode yang digunakan untuk evaluasi kinerja model klasifikasi biner maupun klasifikasi *multiclass* [28]. Metode ini menganalisis hasil klasifikasi berdasarkan empat bagian diantaranya yaitu True Positive (TP) menunjukkan data aktual dan hasil klasifikasi bernilai positif, True Negative (TN) menunjukkan data aktual dan hasil klasifikasinya bernilai negatif, False Positive (FP) menunjukkan data aktual bernilai negatif sedangkan hasil klasifikasinya positif, False Negative (FN) menunjukkan data aktual positif sedangkan hasil klasifikasinya negatif [29]. *Confusion matrix* untuk permasalahan klasifikasi *multiclass* divisualisasikan oleh Gambar 3.

Aktual	Klasifikasi		
	A	B	C
A	TP	FN	FN
B	FP	TN	TN
C	FP	TN	TN

Aktual	Klasifikasi		
	A	B	C
A	TN	FP	TN
B	FN	TP	FN
C	TN	FP	TN

Aktual	Klasifikasi		
	A	B	C
A	TN	TN	FP
B	TN	TN	FP
C	FN	FN	TP

TP (A)

FP (A)

FN (A)

TN (A)

TP (B)

FP (B)

FN (B)

TN (B)

TP (C)

FP (C)

FN (C)

TN (C)

Gambar 3. *Confusion matrix multiclass.*

Berdasarkan perolehan nilai dari TP, TN, FP, dan FN kemudian dihitung tingkat keakuratan dari model menggunakan rumus akurasi, sensitivitas, dan spesifisitas pada Persamaan (17) – (19).

$$akurasi = \frac{TP_a}{n_a} \times 100\% \quad (17)$$

$$sensitivitas = \frac{\sum \left(\frac{TP_i}{TP_i + FN_i} \right)}{n} \times 100\% \quad (18)$$

$$spesifisitas = \frac{\sum \left(\frac{TN_i}{TN_i + FP_i} \right)}{n} \times 100\% \quad (19)$$

dimana, TP_a merupakan jumlah TP dari semua kelas, n_a merupakan jumlah dari seluruh data, n merupakan jumlah kelas, dan i merupakan kelas ke- i .

Bahan dan Metode


Penelitian ini merupakan penelitian kuantitatif dengan data yang digunakan berupa data citra *X-ray* tiga penyakit yaitu COVID-19, MERS, dan SARS. Data citra *X-ray* termasuk data sekunder yang didapatkan dari *Kaggle* dengan jumlah keseluruhan data yaitu 422 data yang meliputi 144 data COVID-19, 144 data MERS, dan 134 data SARS. Terdapat sampel data dari masing-masing penyakit yang ditunjukkan oleh Gambar 4.



(a) (b) (c)

Gambar 4. Sampel data (a) COVID-19, (b) MERS, (c) SARS.

Terdapat beberapa tahapan yang dilakukan untuk memproses data agar mendapatkan hasil klasifikasi yang divisualisasikan berupa diagram alir pada Gambar 5.




Gambar 5. Diagram alir penelitian.

Berdasarkan diagram alir Gambar 5, tahap awal penelitian ini yaitu melakukan input data citra *X-ray* COVID-19, MERS, dan SARS. Selanjutnya dilakukan tahap *preprocessing* untuk memperbaiki kualitas dari citra *X-ray* seperti meningkatkan kontras menggunakan CLAHE dan menghilangkan *noise* menggunakan *median filter*. Setelah itu, dilakukan proses ekstraksi fitur menggunakan metode GLCM untuk memperoleh fitur energi, kontras, homogenitas, dan korelasi serta pada metode GLDM untuk mendapatkan fitur GC, GSM, GE, GM, dan IDM. Langkah selanjutnya yaitu membagi data menjadi data pelatihan dan data pengujian menggunakan metode *K-fold Cross Validation* dengan parameter uji coba k yang digunakan yaitu $k = 5$ dan $k = 10$. Pada data pelatihan dilakukan proses pelatihan ELM yang meliputi inisialisasi bobot, bias, jumlah *node* pada *hidden layer* hingga didapatkan model optimal yang kemudian digunakan pada proses pengujian. Setelah didapatkan hasil klasifikasi, kemudian melakukan evaluasi kinerja klasifikasi ELM menggunakan *confusion matrix* sehingga diperoleh hasil akurasi, sensitivitas, dan spesifisitas.

Hasil dan Pembahasan

Langkah pertama dalam penelitian ini melakukan *input* data citra *X-ray* penyakit COVID-19, MERS, dan SARS. Selanjutnya melalui proses perbaikan citra *X-ray* menggunakan metode CLAHE dan *median filter*. Perhitungan kedua metode *preprocessing* tersebut dilakukan berdasarkan Persamaan (1) dan (2), sehingga menghasilkan kualitas citra yang lebih baik. Terdapat perbedaan citra *X-ray* asli, hasil CLAHE, dan hasil *median filter* yang ditunjukkan oleh Gambar 6.



(a) (b) (c)

Gambar 6. Perbandingan citra *X-ray* (a) asli, (b) hasil CLAHE, (c) hasil *median filter*.

Setelah pada tahap *preprocessing*, kemudian melakukan ekstraksi fitur menggunakan metode GLCM dan GLDM. Masing-masing dari kedua metode tersebut dilakukan ekstraksi tekstur berdasarkan uji coba orientasi arah sudut 0° , 45° , 90° , dan 135° . Selanjutnya, untuk mendapatkan nilai fitur pada metode GLCM dapat dihitung menggunakan Persamaan (3) – (6), sedangkan nilai fitur pada metode GLDM diperoleh pada perhitungan menggunakan Persamaan (7) – (11). Sampel hasil ekstraksi fitur GLCM dan GLDM pada arah sudut 0° dapat dilihat pada Tabel 1 dan 2 berikut.

Tabel 1. Sampel hasil ekstraksi GLCM sudut 0° .

Data ke-	Energi	Kontras	Homogenitas	Korelasi	Kelas
1	0.899158	0.210802	0.13239	0.94583	COVID-19
2	0.867258	0.316984	0.093301	0.952297	COVID-19
⋮	⋮	⋮	⋮	⋮	⋮
421	0.952357	0.097414	0.238745	0.94829	MERS
422	0.932883	0.141936	0.147767	0.97183	SARS

Tabel 2. Sampel hasil ekstraksi GLDM sudut 0° .

Data ke-	Kontras	ASM	Entropi	IDM	Mean	Kelas
1	0.570025	0.458483	0.448028	0.55969	0.565957	COVID-19
2	0.693033	0.6092	0.316325	0.689483	0.693056	COVID-19
⋮	⋮	⋮	⋮	⋮	⋮	⋮
421	0.251381	0.169306	0.763287	0.243847	0.24809	MERS
422	0.523679	0.419348	0.495156	0.512092	0.517418	SARS

Langkah selanjutnya yaitu menggunakan metode *k-fold cross validation* untuk melakukan pembagian data pelatihan dan data pengujian. Parameter *k-fold* digunakan untuk uji coba dengan $k = 5$ dan $k = 10$. Berdasarkan hasil pembagian data menggunakan *k-fold*, kemudian dilakukan proses klasifikasi menggunakan ELM dengan data pelatihan digunakan sebagai *input* awal proses pelatihan. Setelah itu, melakukan inisialisasi bobot, bias, dan jumlah *node* pada *hidden layer* secara *random*. Penelitian ini menggunakan *node* yang terdapat pada *hidden layer* sebagai parameter uji coba dengan jumlah *node* 25, 50, dan 100. Proses perhitungan pada pelatihan dan pengujian klasifikasi ELM menggunakan rumus pada Persamaan (12) – (16), sehingga memperoleh hasil uji coba yang terdapat pada Tabel 3 dan 4 sebagai berikut.

Tabel 3. Hasil uji coba ELM menggunakan ekstraksi fitur GLCM.

Sudut	<i>K-fold</i>	<i>Node</i>	Akurasi (%)	Sensitivitas (%)	Spesifisitas (%)	waktu (s)
0°	5	25	78.5714	78.7798	89.279	0.00084
		50	73.8095	74.0495	87.0428	0.0016

45°	10	100	67.8571	68.3024	84.0752	0.0032
		25	73.8095	74.3956	86.9397	0.00059
		50	71.4286	71.8559	85.9135	0.0014
		100	69.0476	69.4505	84.6378	0.0028
	5	25	83.3333	83.3775	91.5778	0.0012
		50	82.1429	82.2281	91.0345	0.0017
		100	76.1905	76.3484	88.0355	0.0039
	10	25	83.3333	83.7607	91.6236	0.00054
		50	80.9524	81.5385	90.5553	0.0011
		100	80.9524	81.3797	90.5142	0.0032
		25	84.5238	84.527	92.1839	0.00058
	5	50	78.5714	78.6472	89.185	0.0015
		100	73.8095	74.1821	86.8861	0.0038
90°	10	25	83.3333	83.7607	91.6226	0.00042
		50	78.5714	78.9988	89.2796	0.0012
		100	78.5714	78.4982	89.2355	0.0029
	5	25	80.9524	81.0787	90.3657	0.0313
		50	78.5714	78.7798	89.185	0.0156
		100	80.9524	81.0787	90.4284	0.0313
135°	10	25	83.3333	83.602	91.6195	0.00054
		50	80.9524	81.5385	90.4731	0.0011
		100	78.5714	78.9988	89.2796	0.0031


Berdasarkan hasil uji coba pada Tabel 3 disimpulkan bahwa klasifikasi ELM dengan metode GLCM memperoleh hasil yang cukup baik pada beberapa parameter. Perolehan hasil tertinggi terdapat pada uji coba arah sudut 90°, *k-fold* 5, dan jumlah *node* 25 dengan akurasi, sensitivitas, dan spesifisitas masing-masing sebesar 84.5238%, 84.527%, dan 92.1839%.

Tabel 4. Hasil uji coba ELM menggunakan ekstraksi fitur GLDM.

Sudut	<i>K-fold</i>	<i>Node</i>	Akurasi (%)	Sensitivitas (%)	Spesifisitas (%)	waktu (s)
0°	5	25	98.8095	98.8506	99.3939	0.00058
		50	98.8095	98.8506	99.3939	0.0016
		100	98.8095	98.8506	99.3939	0.0031
	10	25	97.619	97.619	98.7654	0.00062
		50	97.619	97.619	98.7654	0.00014
		100	97.619	97.619	98.7654	0.003
45°	5	25	100	100	100	0.0014
		50	100	100	100	0.0023

		100	100	100	100	0.0041	
	10	25	100	100	100	0.00047	
		50	100	100	100	0.0012	
		100	100	100	100	0.0036	
90°	5	25	98.8095	98.8506	99.3939	0.0011	
		50	98.8095	98.8506	99.3939	0.0017	
		100	98.8095	98.8506	99.3939	0.0039	
	10	25	97.619	97.7778	98.8095	0.00059	
		50	97.619	97.7778	98.8095	0.00014	
		100	97.619	97.7778	98.8095	0.0032	
	135°	5	25	100	100	100	0.00067
			50	100	100	100	0.0015
100			100	100	100	0.0044	
10		25	100	100	100	0.00042	
		50	100	100	100	0.0012	
		100	100	100	100	0.0024	

Berdasarkan hasil uji coba pada Tabel 4 dapat disimpulkan bahwa klasifikasi ELM dengan metode GLDM memperoleh hasil yang sangat baik pada beberapa parameter. Hasil tertinggi terdapat pada uji coba arah sudut 135°, *k-fold* 10, jumlah *node* 25, dan berdasarkan waktu tercepat yaitu 0.00042 dengan perolehan akurasi, sensitivitas, dan spesifisitas masing-masing sebesar 100%. Selanjutnya, untuk perbandingan hasil klasifikasi ELM menggunakan metode GLCM dan GLDM dapat dilihat pada visualisasi Gambar 7.



Gambar 7. Grafik perbandingan rata-rata nilai sensitivitas dari GLCM dan GLDM

Pada Gambar 7 merupakan grafik perbandingan rata-rata nilai sensitivitas dari GLCM dan GLDM yang dilihat dari jumlah *node*. Berdasarkan grafik tersebut, diketahui bahwa klasifikasi ELM menggunakan ekstraksi fitur GLDM memberikan persentase nilai sensitivitas yang lebih tinggi daripada klasifikasi menggunakan ekstraksi fitur GLCM, sehingga dapat disimpulkan bahwa ekstraksi fitur metode GLDM lebih unggul sebesar 99.1373% daripada ekstraksi fitur metode GLCM yaitu 76.030%.

Kesimpulan

Berdasarkan penelitian yang telah dilakukan ini yaitu perbandingan ekstraksi fitur GLCM dan GLDM untuk klasifikasi COVID-19, MERS, dan SARS menggunakan metode ELM menunjukkan bahwa penggunaan ekstraksi fitur metode GLDM mendapatkan hasil yang lebih unggul daripada ekstraksi fitur GLCM. Hasil tertinggi klasifikasi ELM dengan GLDM terdapat pada pembagian *k-fold* 10, arah sudut 135°, dan *node* 25 dengan nilai akurasi, sensitivitas, dan spesifisitas masing-masing sebesar 100%. Proses pelatihan yang dibutuhkan untuk memperoleh hasil tersebut yaitu 0.00042 detik.

Referensi

- [1] A. Simajuntak, I. Kusadhiani, dan V. Z. Latuconsina, "Hubungan Jumlah Trombosit Dengan Severitas Klinis Pasien COVID-19 Pada Tiga Rumah Sakit Rujukan COVID-19 di Kota Ambon Tahun 2020," *MoluccaMedica*, vol. 15, no. 2, 2022, doi: 10.30598/molmed.2022.v15.i2.138.
- [2] Y. F. Riti dan S. S. Tandjung, "Klasifikasi Covid-19 Pada Citra CT Scans Paru-Paru Menggunakan Metode Convolution Neural Network," *Progresif J. Ilm. Komput.*, vol. 18, no. 1, hal. 91, 2022, doi: 10.35889/progresif.v18i1.784.
- [3] T. T. Yao, J. D. Qian, W. Y. Zhu, Y. Wang, dan G. Q. Wang, "A systematic review of lopinavir therapy for SARS coronavirus and MERS coronavirus—A possible reference for coronavirus disease-19 treatment option," *J. Med. Virol.*, vol. 92, no. 6, hal. 556–563, 2020, doi: 10.1002/jmv.25729.
- [4] X.-Y. Zhang *et al.*, "Biological, clinical and epidemiological features of COVID-19, SARS and MERS and AutoDock simulation of ACE2," *MedNexus*, 2020.
- [5] B. N. Mohammed, F. H. Al-Mukhtar, R. Z. Yousif, dan Y. S. Almarshhadani, "Automatic Classification of Covid-19 Chest X-Ray Images Using Local Binary Pattern and Binary Particle Swarm Optimization for Feature Selection," *Cihan Univ. Sci. J.*, vol. 5, no. 2, hal. 46–51, 2021.
- [6] A. A. Nurfitri, A. I. Kaparang, M. T. Hidayat, A. B. Kaswar, dan D. D. Andayani, "Classification of the Level of Sugar Content in Papaya Fruit Based on Color Features Using Artificial Neural Network," *JUTIF (Jurnal Tek. Inform.)*, vol. 4, no. 6, 2023.
- [7] A. R. Damanik, S. Annisa, A. I. Rafeli, A. S. Liana, dan D. S. Prasvita, "Klasifikasi Jenis Buah Cherry Menggunakan Support Vector Machine (SVM) Berdasarkan Tekstur dan Warna Citra," *Semin. Nas. Mhs. Ilmu Komput. dan Apl.*, 2022.
- [8] C. Gupta, N. K. Gondhi, dan P. K. Lehana, "Gray Level Co-Occurrence Matrix (GLCM) Parameters Analysis for Pyoderma Image Variants," *J. Comput. Theor. Nanosci.*, vol. 17, hal. 1, 2020.
- [9] R. L. Hasanah, "Identifikasi Jenis Acne Vulgaris pada Citra Jerawat Wajah dengan Ekstraksi Fitur GLCM dan Algoritma Extreme Learning Machine," 2020.
- [10] E. Elfira, W. Priharti, dan D. Rahmawati, "Comparison of GLCM and First Order Feature Extraction Methods for Classification of Mammogram Images," *J. Teknokes*, vol. 15, no. 4, hal. 197–205, 2022, doi: 10.35882/teknokes.v15i4.458.
- [11] B. Sri Aprillia, A. Rizal, dan M. A. Gerald Fauzi, "Grey Level Differences Matrix for Alcoholic EEG Signal Classification," *JOIV Int. J. Informatics Vis.*, vol. 8, no. 1, hal. 26, 2024, doi: 10.62527/joiv.8.1.2602.
- [12] E. B. Talal dan E. Thabet, "Diabetic Retinopathy Recognition System based on GLDM Features and FeedForward Neural Network Classifier," *Al-Qadisiyah J. Pure Sci.*, vol. 27, no. 1, 2022.
- [13] D. Kumar, T. Roshni, A. Singh, M. K. Jha, dan P. Samui, "Predicting groundwater depth fluctuations using deep learning, extreme learning machine and Gaussian process: a comparative study," *Earth Sci. Informatics*, vol. 13, no. 4, hal. 1237–1250, 2020, doi: 10.1007/s12145-020-00508-y.
- [14] E. Budianita, F. Syafria, dan I. Afriyanti, "Prediksi Jumlah Perceraian Menggunakan Metode Extreme Learning Machine (ELM)," *J. Inf. Syst. Res.*, vol. 4, no. 4, hal. 1448–1454, 2023, doi: 10.47065/josh.v4i4.3581.
- [15] R. R. Wahid, F. T. Anggraeny, dan B. Nugroho, "Implementasi Metode Extreme Learning Machine untuk Klasifikasi Tumor Otak pada Citra Magnetic Resonance Imaging," *Pros. Semin. Nas. Inform. Bela Negara*, vol. 1, hal. 16–20, 2020, doi: 10.33005/santika.v1i0.45.
- [16] H. Pratiwi dan K. Harianto, "Perbandingan Algoritma ELM Dan Backpropagation Terhadap Prestasi Akademik Mahasiswa," *J-SAKTI (Jurnal Sains Komput. dan Inform.)*, vol. 3, no. 2, hal. 282, 2019, doi: 10.30645/j-sakti.v3i2.147.
- [17] J. F. Azzahra, H. Sumarti, dan H. H. Kusuma, "Klasifikasi Kasus COVID-19 dan SARS Berbasis Ciri Tekstur Menggunakan Metode Multi-Layer Perceptron," *J. Fis.*, vol. 12, no. 1, hal. 16–27, 2022, doi: 10.15294/jf.v12i1.35685.
- [18] J. Kalyani dan M. Chakraborty, "Contrast Enhancement of MRI Images using Histogram Equalization Techniques," *2020 Int. Conf. Comput. Electr. Commun. Eng.*, hal. 1–5, 2020.
- [19] F. M. Hana dan I. D. Maulida, "Analysis of contrast limited adaptive histogram equalization (CLAHE) parameters on finger

- knuckle print identification,” *J. Phys. Conf. Ser.*, vol. 1764, no. 1, 2021, doi: 10.1088/1742-6596/1764/1/012049.
- [20] D. C. R. Novitasari, A. Z. Foady, M. Thohir, A. Z. Arifin, K. Niam, dan A. H. Asyhar, “Automatic Approach for Cervical Cancer Detection Based on Deep Belief Network (DBN) Using Colposcopy Data,” *2020 Int. Conf. Artif. Intell. Inf. Commun. ICAIIC 2020*, hal. 415–420, 2020, doi: 10.1109/ICAIIIC48513.2020.9065196.
- [21] O. Appiah, M. Asante, dan J. B. Hayfron-Acquah, “Improved approximated median filter algorithm for real-time computer vision applications,” *J. King Saud Univ. - Comput. Inf. Sci.*, vol. 34, no. 3, hal. 782–792, 2022.
- [22] V. U. M. Maksu, D. C. R. Novitasari, dan A. Hamid, “Image X-Ray Classification for COVID-19 Detection Using GCLM-ELM,” *J. Mat. MANTIK*, vol. 7, no. 1, hal. 74–85, 2021, doi: 10.15642/mantik.2021.7.1.74-85.
- [23] F. R. Hendri dan F. Utaminingrum, “Cancer Mammography Detection Using Four Features Extractions on Gray Level Co-occurrence Matrix with SVM Kernel Analysis,” *Proc. 2nd Int. Conf. Electron. Biomed. Eng. Heal. Informatics*, 2022.
- [24] E. Barges dan E. Thabet, “GLDM and Tamura features based KNN and particle swarm optimization for automatic diabetic retinopathy recognition system,” *Multimed. Tools Appl.*, vol. 82, hal. 271–295, 2023.
- [25] N. G. Ramadhan dan A. Khoirunnisa, “Klasifikasi Data Malaria Menggunakan Metode Support Vector Machine,” *J. Media Inform. Budidarma*, vol. 5, no. 4, hal. 1580, 2021, doi: 10.30865/mib.v5i4.3347.
- [26] B. Y. Phiadelvira, D. Z. Haq, D. C. R. Novitasari, dan F. Setiawan, “Prediksi Besar Daya Listrik Tenaga Gelombang Laut Metode Oscillating Water Coloumn (PLTGL-OWC) di Banyuwangi Menggunakan Extreme Learning Machine (ELM),” *Unnes J. Math.*, vol. 11, no. 1, hal. 1–7, 2022, doi: 10.15294/ujm.v11i1.50967.
- [27] W. T. Puspitasari, D. Z. Haq, dan D. C. R. Novitasari, “Identifikasi Leukemia Berdasarkan Analisis Tekstur Citra Darah Tepi Mikroskopis Menggunakan Jaringan Syaraf Tiruan Feed-Forward,” *Tek. Komput. J. Apl.*, vol. 11., no. 3, hal. 215–225, 2022.
- [28] N. Hidayah, A. N. Ramadanti, dan D. C. R. Novitasari, “Classification of Colon Cancer Based on Hispathological Images using Adaptive Neuro Fuzzy Inference System (ANFIS),” vol. 9, no. 2, hal. 162–168, 2023.
- [29] A. A. Salih dan A. M. Abdulazeez, “Evaluation of Classification Algorithms for Intrusion Detection System: A Review,” *J. Soft Comput. Data Min.*, vol. 02, no. 01, hal. 31–40, 2021, doi: 10.30880/jscdm.2021.02.01.004.