



KLASIFIKASI CITRA CACAR MONYET MENGGUNAKAN GRAY LEVEL CO-OCCURRENCE MATRIX DAN ALGORITMA LINEAR DISCRIMINANT ANALYSIS

Abd. Charis Fauzan ¹⁾, Muhammad Naja Maskuri ²⁾

^{1,2)} Ilmu Komputer, Fakultas Ilmu Eksakta, Universitas Nahdlatul Ulama Blitar

Email : muhammadnaja1611.ok@gmail.com ¹⁾, abdcharis@unublitar.ac.id ²⁾

Diterima : 20 Februari 2025 ; Disetujui : 21 April 2025 ; Dipublikasikan : 31 Juli 2025

ABSTRAK

Monkeypox atau cacar monyet merupakan penyakit menular yang disebabkan oleh virus *orthopoxvirus* yang berasal dari hewan primata dan hewan pengerat. Berdasarkan data WHO sejak Januari 2022 sampai Juni 2023 terdapat 88.060 kasus terkonfirmasi cacar monyet dan 147 kasus kematian akibat cacar monyet yang tersebar di 112 negara di dunia. Penyebaran kasus cacar monyet yang terus meluas diberbagai negara, membuat cacar monyet menjadi salah satu penyakit yang banyak diperbincangkan. Pada penelitian ini dilakukan proses identifikasi citra lesi penyakit cacar monyet dan citra non-cacar monyet (campak dan cacar ayam) dengan melalui tahap *preprocessing*, tahap ekstraksi ciri GLCM dengan 7 fitur (*contras, correlation, energi, homogenitas, entropi, mean dan variance*), dan tahap pelatihan model pembelajaran mesin klasifikasi menggunakan algoritma LDA. Melalui proses evaluasi *10-fold cross validation* didapatkan hasil evaluasi model pembelajaran klasifikasi yang dibangun menunjukkan nilai performa rata-rata akurasi sebesar 80,55%, presisi 78%, recall 80%, dan spesificity 79%. Hasil ini menunjukkan bahwa model klasifikasi yang dikembangkan memiliki performa yang baik (*good classification*) dalam membedakan citra cacar monyet dan non-cacar monyet.

Kata Kunci : Cacar Monyet, Klasifikasi, GLCM, LDA

ABSTRACT

Monkeypox is an infectious disease caused by an *orthopoxvirus* that originates from primates and rodents. Based on WHO data from January 2022 to June 2023 there were 88.060 confirmed cases of monkey pox and 147 cases of death due to monkey pox spread across 112 countries in the world. The spread of monkey pox cases continues to expand in various countries, making monkey pox a disease that is widely discussed. In this research, the process of identifying monkey pox lesion images and non-monkey pox images (measles and chickenpox) is carried out by going through the preprocessing stage, the GLCM feature extraction stage with 7 features (*contrast, correlation, energy, homogeneity, entropy, mean and variance*), and the classification machine learning model training stage using the LDA algorithm. Through a *10-fold cross validation* evaluation process, the results of the evaluation of the classification learning model built show an average performance value of 80.55% accuracy, 78% precision, 80% recall, and 79% specificity. These results show that the classification model developed has good classification performance in distinguishing monkey pox and non-monkey pox images.

Keywords : Monkeypox, Classification, GLCM, LDA

1. PENDAHULUAN

Monkeypox atau cacar monyet merupakan penyakit menular *zoonosis* yang disebabkan oleh virus *orthopoxvirus* yang berasal dari hewan primata maupun pengerat seperti kera, tupai, anjing dan tikus [1]. Penularan cacar monyet dapat terjadi dari hewan ke manusia melalui kontak langsung seperti air liur, kotoran maupun urine dari hewan yang terinfeksi, serta memiliki kemungkinan untuk ditularkan dari manusia ke manusia. Pada penderita cacar monyet terdapat lesi kulit berupa ruam gatal dan bintik-bintik kecil yang berisi cairan atau nanah, dimana intensitas lesi pada penderita cacar monyet tergantung pada tingkat keparahan infeksi yang terjadi. Keberadaan lesi kulit pada penderita cacar monyet pada umumnya terjadi pada kurun waktu 2-3 minggu hingga penderita sembuh dan lesi mengering menjadi kerak [2].

Penyakit cacar monyet (*Mpox*) pertama kali ditemukan pada lesi tawanan monyet di Kopenhagen Denmark pada tahun 1958, sedangkan pertama kali teridentifikasi menginfeksi manusia terjadi pada tahun 1970 di negara Republik Kongo [2]. Penyakit ini merupakan penyakit endemik dari wilayah Afrika Tengah dan Afrika Barat, namun dalam kurun waktu belakangan penyakit ini diketahui telah menyebar di berbagai negara di dunia. Beberapa contoh kasus wabah cacar monyet yang pernah terjadi di luar wilayah endemik seperti di Amerika Serikat pada tahun 2003 dan Nigeria pada tahun 2017.

Pada pertengahan tahun 2022 kasus cacar monyet kembali merebak, beberapa wilayah mengkonfirmasi kasus cacar monyet seperti Eropa (Inggris, Prancis, Swedia, Portugal, Spanyol, Italia, Belanda, Belgia, Jerman, Austria dan Belgia), Asia Tenggara (Indonesia dan Singapura) dan Australia [3]. Berdasarkan data *World Health Organization* (WHO) sejak Januari 2022 sampai Juni 2023 terdapat 88.060 kasus terkonfirmasi cacar monyet dan 147 kasus kematian akibat cacar monyet yang tersebar di 112 negara di dunia [4]. Bahkan persebaran penyakit cacar monyet yang terus meningkat membuat WHO sempat menetapkan wabah cacar monyet sebagai darurat kesehatan global.

Penyebaran kasus cacar monyet yang terus meluas di berbagai negara, membuat

cacar monyet menjadi salah satu penyakit yang banyak diperbincangkan dan terus menjadi perhatian dunia internasional. Disisi lain perkembangan data-data kesehatan dan kecanggihan komputasi membuat Kecerdasan Buatan (AI) seringkali dimanfaatkan dalam mendeteksi, mendiagnosa dan mengidentifikasi suatu penyakit. Proses identifikasi penyakit dapat dilakukan melalui citra atau gambar dari representasi fisik suatu penyakit melalui penerapan metode pengolahan citra (*image processing*) berupa rangkaian proses ekstraksi ciri untuk mendapatkan fitur-fitur yang dapat digunakan dalam proses identifikasi. Sehingga berdasarkan kedua hal tersebut pada penelitian ini akan melakukan proses klasifikasi lesi penyakit cacar monyet menggunakan penerapan *image processing* dan *machine learning* dalam mengidentifikasi ciri dan membentuk model pembelajaran sekaligus mengetahui performa dari model yang dibangun.

Dalam mengidentifikasi pola suatu citra melalui penerapan *image processing* dapat menggunakan metode ekstraksi ciri tekstur, salah satunya adalah metode GLCM (*Gray Level Co-occurrence Matrix*). Ekstraksi ciri tekstur GLCM dapat digunakan untuk mendapatkan fitur atau parameter yang dapat dipakai untuk membedakan objek satu dengan dengan objek lain melalui proses klasifikasi. Metode GLCM merupakan deskriptor fitur atau ciri yang baik dalam merepresentasikan fitur tekstur citra [5]. Beberapa penelitian yang pernah dilakukan mengenai penerapan metode GLCM seperti identifikasi pola dengan menggunakan ekstraksi ciri *Gray Level Co-occurrence Matrix* (GLCM) untuk mendapatkan fitur tekstur dari citra wayang, dimana penelitian tersebut menghasilkan rata-rata akurasi sebesar 83% dengan *precision* 87% dan *recall* 83% [6]. Selanjutnya penelitian tentang metode ekstraksi ciri tekstur GLCM untuk mendeteksi melasma dari citra wajah. Melalui fitur GLCM yang digunakan seperti kontras, energi, homogenitas dan entropi, dengan teknik klasifikasi *K-Nearest Neighbour* (KNN) diperoleh nilai akurasi tertinggi sebesar 98% dengan nilai $k=5$ [7].

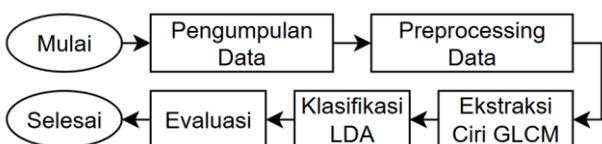
Proses klasifikasi citra selanjutnya dapat menerapkan teknik klasifikasi seperti algoritma *Linear Discriminant Analysis* (LDA). Dalam

penelitian yang dilakukan oleh Grace disebutkan bahwa algoritma LDA adalah salah satu metode klasifikasi yang memiliki kemampuan dalam memisahkan antar kelas menjadi lebih terpisah [1]. LDA bekerja dengan menganalisa matriks sebaran untuk memberikan proyeksi optimal yang bertujuan untuk memaksimalkan pemisahan antar objek dan meminimalkan jarak antar objek [8]. Penelitian berkaitan dengan penerapan algoritma LDA juga pernah dilakukan oleh Nurhalimah dkk untuk melakukan klasifikasi terhadap citra kain songket Lombok dengan menggunakan GLCM dan LDA, dengan dataset citra berjumlah 1000 gambar yang terdiri dari 10 motif songket Lombok, menghasilkan nilai akurasi tertinggi sebesar 98.33% [9].

Penelitian selanjutnya berkenaan dengan penerapan LDA seperti yang dilakukan oleh Rizka dkk dengan judul “Implementasi Metode *Linear Discriminant Analysis* untuk Deteksi Kematangan pada Buah Stroberi” [10]. Melakukan pemodelan terhadap dataset citra buah stroberi, untuk melakukan klasifikasi tingkat kematangan buah stroberi berdasarkan warnanya. Dimana hasil penelitian diperoleh nilai akurasi sebesar 84.28%. Berdasarkan hal tersebut, maka pada penelitian ini akan dilakukan proses pengenalan pola terhadap dataset citra lesi penyakit cacar monyet untuk mengklasifikasikan penyakit cacar monyet menggunakan metode ekstraksi ciri tekstur *Gray Level Co-occurrence Matrix* (GLCM) dalam mencari nilai atau parameter yang digunakan dalam tahap klasifikasi menggunakan algoritma *Linear Discriminant Analysis* (LDA).

2. METODE

Dalam membangun system klasifikasi penyakit cacar monyet dibutuhkan alur atau tahapan yang berguna sebagai landasan dalam melakukan penelitian. Alur penelitian diawali dengan pengumpulan data, *preprocessing*, ekstraksi ciri, klasifikasi dan evaluasi. *Flowchart* alur penelitian ditunjukkan pada Gambar 1.



Gambar 1. Diagram Alur Penelitian

2.1 Dataset

Data citra yang digunakan dalam penelitian diperoleh dari *Kaggle Repository* berupa dataset citra lesi kulit penyakit cacar. Data citra mentah awal terbagi menjadi 4 direktori, yaitu direktori “*Chicken Pox*” yang berisi data citra lesi kulit penyakit cacar ayam, direktori “*Measles*” berisi data citra lesi kulit penyakit campak, direktori “*Monkeypox*” berisi data citra lesi kulit penyakit cacar monyet dan direktori “*Normal*” berisi citra kulit normal. Pada penelitian ini, peneliti hanya mengambil data dari 3 direktori saja yaitu *Chickenpox*, *Measles* dan *Monkeypox*. Dimana data citra pada direktori *Monkeypox* akan digunakan sebagai kelas “Cacar Monyet” sedangkan data citra pada direktori *Chickenpox* dan *Measles* akan digunakan sebagai kelas “Non-Cacar Monyet”. Total data citra yang digunakan berjumlah 420 data dengan komposisi data citra cacar monyet berjumlah 220 data sedangkan data citra non-cacar monyet berjumlah 200 data. Sampel data dari citra lesi kulit non-cacar monyet dan cacarmonyet yang ditunjukkan pada Gambar 1 dan 3.



Gambar 2. Citra Non Cacar Monyet



Gambar 3. Citra Cacar Monyet

2.2 Preprocessing

Tahap *preprocessing* merupakan tahap awal pengolahan citra. Tahap ini dilakukan untuk mendapatkan citra yang sesuai dan dapat digunakan dalam proses selanjutnya yaitu ekstraksi ciri. Proses *preprocessing* yang digunakan dalam penelitian terdiri dari pemotongan citra (*Cropping*), merubah ukuran citra (*Resizing*), mempertajam citra (*Sharpening*), augmentasi citra dan merubah citra RGB menjadi *grayscale* (*Greyscaling*). Adapun alur proses *preprocessing* citra dapat dilihat pada Gambar 4 sebagai berikut.

Pre-Processing
- Memotong Citra (Cropping)
- Merubah Ukuran Citra (Resizing)
- Mempertajam Citra (Sharpening)
- Augmentasi Citra
- Merubah Citra RGB ke Grayscale (Grayscale)

Gambar 4. Tahap *Preprocessing*

2.3 Ekstraksi GLCM

Dataset citra yang telah melalui proses *preprocessing*, selanjutnya dilakukan proses ekstraksi ciri tekstur untuk mendapatkan fitur atau parameter yang akan digunakan dalam pelatihan model. Metode ekstraksi ciri tekstur yang digunakan dalam penelitian ini adalah *Gray Levels Co-occurrence Matrix* (GLCM). Melalui metode ini akan didapatkan beberapa fitur atau parameter yang akan digunakan dalam proses pembelajaran mesin. Beberapa fitur tekstur GLCM yang digunakan antara lain *Correlation, Contrast, Energy, Homogeneity, Entropy, Mean, dan Variance*. Alur perhitungan ekstraksi ciri tekstur pada metode GLCM ditunjukkan pada Gambar 5.



Gambar 5. Flowchart Ekstraksi Ciri GLCM

Proses ekstraksi ciri GLCM diawali dengan memasukkan data citra yang akan di cari fitur-fiturnya, kemudian dilakukan kuantisasi citra untuk merubah rentang nilai piksel citra *grayscale*. Perubahan rentang *grayscale* pada penelitian ini dilakukan dengan menggunakan proses normalisasi citra dari rentang nilai 0-255 menjadi 1-8, proses ini dilakukan untuk mengurangi beban komputasi [11]. Kuantisasi citra memanfaatkan rumus normalisasi citra *grayscale* sebagai berikut [12]:

$$X(i,j) = \left(\frac{NewMax}{Max - Min} * I(i,j) \right) + \left(1 - \left(\frac{NewMax}{Max - Min} \right) * Min \right) \quad (1)$$

Pembentukan matriks GLCM dilakukan dengan menghitung frekuensi kemunculan

pasangan piksel dengan intensitas tertentu berdasarkan jarak piksel (*distance*) dan orientasi sudut yang telah ditentukan (θ). Pada penelitian ini orientasi sudut yang digunakan sebesar 0 derajat sedangkan jarak ketetanggaan piksel (*distance*) sebesar 5. Sehingga proses perhitungan frekuensi ketetanggaan piksel citra dilakukan secara horizontal dari kanan ke kiri maupun sebaliknya dengan jarak piksel sejumlah 5.

Hasil pembentukan matrik GLCM, selanjutnya dilakukan proses normalisasi, dengan cara membagi setiap elemen matrik dengan jumlah total nilai piksel matrik GLCM.

$$GLCM(i,j) = \frac{GLCM(i,j)}{n} \quad (2)$$

Setelah didapatkan matriks GLCM yang telah dinormalisasi, maka selanjutnya dilakukan perhitungan fitur ekstraksi ciri GLCM. Beberapa firur ekstraksi ciri GLCM yang digunakan sebagai diskriptor ciri tekstur pada peneleitian ini sebagai berikut [13]:

1. Energi (*energy*), digunakan untuk mengukur keseragaman piksel dalam suatu citra. Dimana nilai energi yang tinggi mengartikan tingkat keseragaman yang konstan.

$$Energi = \sum \sum (GLCM(i,j))^2 \quad (3)$$

2. Kontras (*contrast*), digunakan untuk mengukur perbedaan aras keabuan dalam piksel citra. Dimana semakin tinggi nilai kontras maka semakin jauh perbedaan aras keabuan setiap pasangan piksel citra.

$$Kontras = \sum \sum |i - j|^2 GLCM(i,j) \quad (4)$$

3. Korelasi (*Correlation*), digunakan untuk mengukur hubungan dari tingkat keabuan pasangan piksel. Nilai korelasi bernilai tinggi jika tingkat keterkaitan level keabuan pasangan piksel tinggi.

$$Korelasi = \sum \sum \frac{(i - \mu_i)(j - \mu_j)(GLCM(i,j))}{\sqrt{\sigma_i \sigma_j}} \quad (5)$$

4. Homogenitas (*Homogeneity*), digunakan untuk mengukur tingkat homogenitas lokal dari citra. Nilai homogenitas semakin tinggi jika tingkat keabuan dari masing-masing pasangan piksel sama atau seragam.

$$Homogenitas = \frac{\sum \sum (GLCM(i,j))}{1 + (i-j)^2} \quad (6)$$

5. Rata-rata (*Mean*), digunakan untuk melihat nilai rata-rata piksel dari citra.

$$Mean = \frac{\mu_i + \mu_j}{2} \quad (7)$$

6. Varians (*variance*), digunakan untuk melihat banyaknya variasi derajat keabuan

dalam sebuah citra.

$$Variance = \frac{\sigma_i + \sigma_j}{2} \quad (8)$$

7. Entropi (*Entropy*), digunakan untuk mengukur ketidakteraturan aras keabuan (karakteristik tekstur) dalam citra. Nilai entropi semakin besar apabila citra secara tekstural tidak seragam atau acak.

$$Entropy = -\sum \sum GLCM(i, j) \cdot \log(GLCM(i, j)) \quad (9)$$

2.4 Algoritma LDA

Salah satu metode yang sering digunakan dalam menyelesaikan masalah klasifikasi adalah analisis deskriminan linier atau *Linear Discriminant Analysis* (LDA). LDA merupakan algoritma *supervised learning* yang sering digunakan dalam pengenalan pola suatu data. Dalam tujuan pengenalan obyek (observasi), LDA mencoba menemukan suatu *discriminant* yang nilainya dapat membedakan objek dengan karakteristik yang telah diketahui. Cara kerja LDA yaitu dengan memaksimalkan diskriminasi antar kelas dan meminimalkan persebaran dalam kelas. Hasil akhir dari LDA yaitu berupa fungsi diskriminan yang digunakan dalam mengelompokkan observasi ke dalam satu kelas. Rumus persamaan diskriminan ditunjukkan pada Persamaan (10) sebagai berikut [8]:

$$f_i = \mu_i C^{-1} X_k^T - \frac{1}{2} \mu_i C^{-1} \mu_i^T + \ln(p_i) \quad (10)$$

Dimana:

f_i = fungsi diskriminan kelas ke-i

μ_i = rata-rata kelas ke-i

μ_i^T = transpos rata-rata kelas ke-i

C^{-1} = matriks covariance yang diinverskan

p_i = probabilitas prior kelas ke-i

2.5 K Fold Cross Validation

Metode *k-fold cross validation* bekerja dengan membagi dataset menjadi beberapa skenario pemodelan dan pengujian [14]. Tahap awal evaluasi model ini adalah dengan membagi data menjadi sejumlah n partisi dengan ukuran yang sama, kemudian selanjutnya proses pelatihan dan pengujian dilakukan sebanyak n kali, sebagai contoh ilustrasi metode *k-fold cross validation* dengan $k=5$ ditunjukkan pada Tabel 1.

Tabel 1. Ilustrasi K-Fold Cross Validation

Iterasi ke-	Dataset					Akurasi
1	Test	Train	Train	Train	Train	1

2	Train	Test	Train	Train	Train	2
3	Train	Train	Test	Train	Train	3
4	Train	Train	Train	Test	Train	4
5	Train	Train	Train	Train	Test	5

Confusion matrix merupakan salah satu metode evaluasi yang merepresentasikan kemampuan sistem dalam memprediksi suatu kelas. *Confusion matrix* digunakan untuk melihat seberapa besar kemampuan model pembelajaran dalam memprediksi suatu kelas. *Confusion matrix* berisi jumlah prediksi benar maupun salah dari hasil model pembelajaran klasifikasi, sesuai dengan kelas target yang terlibat.

Tabel 2. Confusion Matrix

Nilai Prediksi	Nilai Aktual	
	True	False
True	True Positive (TP)	False Positive (FP)
False	False Negative (FN)	True Negative (TN)

Berdasarkan Tabel 2, tabel *Confusion matrik* pada umumnya berbentuk 2x2 untuk kasus klasifikasi 2 kelas, dengan empat kemungkinan hasil prediksi yaitu TP (*True Positive*), TN (*True Negative*), FP (*False Positive*), FN (*False Negative*). TP menotasikan jumlah kelas aktual positif dan diprediksi positif (benar), TN menotasikan jumlah kelas aktual negatif dan diprediksi negatif (benar), FP menotasikan kelas aktual negatif dan diprediksi positif (salah), sedangkan FN menotasikan kelas aktual positif dan diprediksi negatif (salah). Melalui nilai TP, TN, FN, dan FP dapat digunakan untuk menghitung *akurasi*, *presisi*, *recall* dan *spesifisitas*, untuk rumus perhitungannya sebagai berikut [15]:

$$Akurasi = \frac{TP+TN}{TP+FP+FN+TN} \times 100 \quad (11)$$

$$Presisi = \frac{TP}{TP+FP} \times 100 \quad (12)$$

$$Recall = \frac{TP}{TP+FN} \times 100 \quad (13)$$

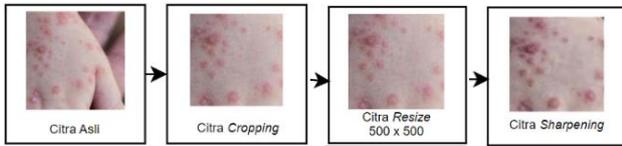
$$Spesifisitas = \frac{TN}{TN+FP} \times 100 \quad (14)$$

3. HASIL DAN PEMBAHASAN

3.1 Preprocessing

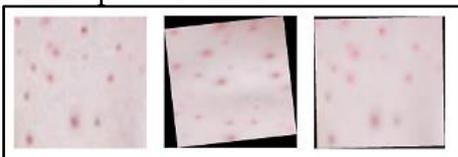
Data citra lesi kulit penyakit cacar yang yang telah diperoleh, dilakukan proses pengolahan citra untuk mendapatkan data citra inputan yang sesuai dengan kebutuhan, proses ini disebut sebagai *preprocessing*. *Preprocessing* citra pada penelitian ini dilakukan dengan beberapa tahap yaitu

cropping, *resizing*, *sharpening*, augmentasi data, dan *grayscale*. Sebagai contoh proses *cropping*, *resizing*, *sharpening* citra ditunjukkan pada Gambar 6.



Gambar 6. Tahap Cropping, Resizing, dan Sharpening citra lesi cacar

Selanjutnya dilakukan tahap augmentasi untuk mendapatkan citra baru, guna menambah dataset citra yang terbatas. Proses augmentasi data pada penelitian ini dilakukan dengan melalui proses *rotating* dan *flipping* citra. Proses *rotating* dan *flipping* citra dilakukan dengan menggunakan aplikasi matlab yaitu melalui fungsi *randomAffine2d* untuk merotasi dan membalik posisi citra. Parameter yang digunakan dalam fungsi *randomAffine2d* adalah [175 180] yang mengartikan bahwa proses perotasian citra dilakukan secara random dengan sudut yang digunakan yaitu pada interval 175 derajat sampai 180 derajat. Sedangkan dalam melakukan *flipping* citra dilakukan dengan menggunakan fungsi *randomAffine2d* dengan nilai parameter adalah “*Yreflection*”, mengartikan bahwa citra akan dibalik secara vertikal. Hasil dari proses augmentasi citra dapat dilihat pada Gambar 7.

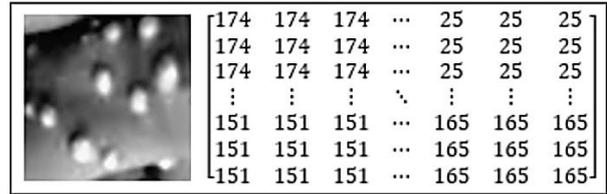


Gambar 7. Hasil Augmentasi Citra

Melalui tahap augmentasi citra, data citra dari semula berjumlah 420 data akan bertambah menjadi 1260 data. Dimana citra sejumlah 840 data diperoleh dari hasil proses augmentasi tahap *flipping* dan *rotating* citra.

Proses ekstraksi ciri fitur tekstur GLCM hanya dapat dilakukan pada citra dengan tipe *grayscale* (keabuan), sehingga pada tahap akhir proses *preprocessing* dilakukan perubahan atau konversi citra dari tipe RGB (*Red Green Blue*) menjadi citra keabuan atau disebut sebagai tahap *grayscale*. Proses *grayscale* citra dilakukan untuk menyederhanakan nilai pixel citra yang semula memiliki 3 kanal warna utama yaitu *Red Green Blue* (RGB) menjadi

satu kanal warna keabuan (*gray*). Representasi matrik pixel *grayscale* pada citra lesi cacar.



Gambar 8. Representasi Matrik Pixel grayscale pada citra lesi cacar

3.2 Ekstraksi Ciri GLCM

Ekstraksi fitur adalah proses mencari ciri atau informasi dari sebuah citra. Proses ekstraksi fitur tekstur pada penelitian ini, menggunakan metode *Gray Levels Co-occurrence Matrix* (GLCM), dengan fitur-fitur yang dipakai yaitu *contrast*, *correlation*, *energy*, *homogeneity*, *entropy*, *mean* dan *variance*. Proses pembentukan matrik *co-occurrence* menggunakan arah sudut sebesar 0 derajat dan jarak (*distance*) sejumlah 5 pixel.

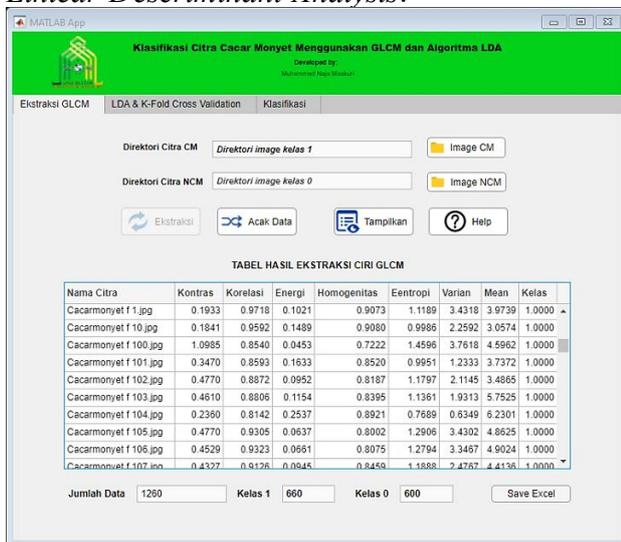
Proses ekstraksi ciri fitur GLCM dilakukan terhadap seluruh citra inputan dengan menerapkan rumus pada persamaan (1) sampai dengan persamaan (9). Sehingga terbentuklah dataset baru yang berisi 8 kolom atribut yang terdiri dari *contrast*, *correlation*, *energy*, *homogeneity*, *entropy*, *mean*, *variance* dan kelas/label. Dimana untuk kelas atau label untuk cacar monyet dinotasikan sebagai 1 sedangkan kelas non cacar monyet dinotasikan sebagai 0. Sampel citra inputan dan hasil nilai ekstraksi ciri tekstur GLCM ditunjukkan pada Tabel 3.

Tabel 3. Sampel Hasil Ekstraksi Ciri GLCM

Citra ke-	1	2	3	4
Citra Uji				
	Cacarmonyet f 1.jpg	Cacarmonyet f 104.jpg	Noncacarmonyet 16.jpg	Noncacarmonyet 79.jpg
Contrast	0.193293	0.236	0.245422	0.30238
Correlation	0.971838	0.81415	0.936981	0.918996
Energy	0.102075	0.25369	0.138591	0.130407
Homogeneity	0.907265	0.892134	0.893672	0.856358
Entropy	1.118932	0.76891	1.013377	1.055214
Varian	3.431753	0.634921	1.947195	1.866443

Mean	3.973927	6.230065	6.104857	6.085562
Kelas/Label	1	1	0	0

Setelah nilai fitur GLCM untuk seluruh citra didapatkan, maka terbentuklah dataset baru yang berisi 9 buah atribut yang terdiri dari nama citra, *contrast*, *correlation*, *energy*, *homogeneity*, *entropi*, *mean*, *variance* dan kelas. Dataset hasil proses ekstraksi ciri GLCM pada program GUI Matlab ditunjukkan pada Gambar 9. Dataset tersebut akan disimpan dengan nama “latih” dengan ekstensi mat, dan akan digunakan sebagai inputan dalam melakukan proses melatih model pembelajaran klasifikasi menggunakan algoritma klasifikasi *Linear Discriminant Analysis*.



Gambar 9. Hasil Ekstraksi Ciri GLCM di GUI Matlab

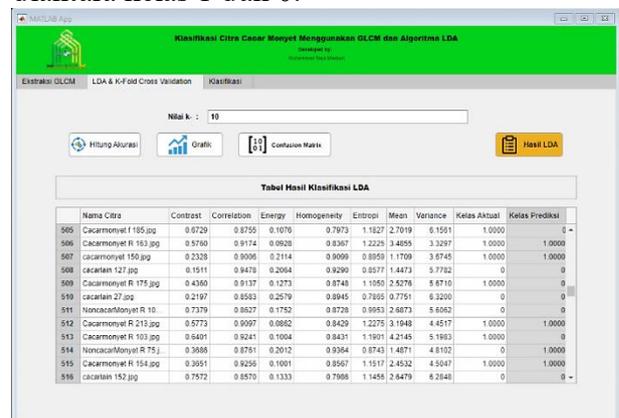
3.3 Klasifikasi LDA

Proses perhitungan LDA diawali dengan menginputkan data pelatihan dan data uji. Oleh karena komposisi data latih dan data uji berdasarkan rule metode *10-Fold Cross Validation*, maka dari dataset berjumlah 1260 data, 1134 data akan digunakan sebagai data latih dan 126 data digunakan sebagai data uji. Selanjutnya dilakukan perhitungan nilai diskriminan dengan menggunakan rumus sebagaimana pada Persamaan (10). Nilai diskriminan yang didapatkan setiap kelas dapat digunakan untuk mengklasifikasikan objek berdasarkan nilai diskriminan tertinggi. Hasil nilai diskriminan dan hasil klasifikasi LDA data uji pada Tabel 4.

Tabel 4. Hasil nilai deskriminan dan hasil klasifikasi LDA data uji

Indeks	Nilai Fungsi Deskriminan		Kelas Pediksi	Kelas Asli
	CM	NCM		
505	3388.886	3389.545	Non Cacar Monyet	Cacar Monyet
506	3436.637	3434.683	Cacar Monyet	Cacar Monyet
507	3433.553	3431.93	Cacar Monyet	Cacar Monyet
508	3409.926	3410.954	Non Cacar Monyet	Non Cacar Monyet
509	3544.335	3544.766	Non Cacar Monyet	Cacar Monyet
510	3343,553	3344,261	Non Cacar Monyet	Non Cacar Monyet
.
.
525	3369,03	3369,493	Non Cacar Monyet	Non Cacar Monyet
526	3461.747	3463.309	Non Cacar Monyet	Non Cacar Monyet
527	3448.523	3449.609	Non Cacar Monyet	Cacar Monyet
528	3417.996	3417.361	Cacar Monyet	Cacar Monyet
529	3505.823	3504.62	Cacar Monyet	Cacar Monyet
630	3454.24	3452.64	Cacar Monyet	Cacar Monyet

Selanjutnya pada program GUI Matlab Proses klasifikasi dilakukan dengan menggunakan statemen *for* untuk melakukan perulangan klasifikasi pada setiap baris dalam data uji, dimana penentuan kelas didasarkan pada nilai skor fungsi diskriminan tertinggi diantara kelas 1 dan 0.



Gambar 10. Hasil output klasifikasi LDA pada program GUI Matlab

Hasil output klasifikasi LDA pada program GUI Matlab untuk setiap record data

uji berupa kelas prediksi antara kelas 0 atau kelas 1 yang ditunjukkan pada atribut kelas prediksi yang ditunjukkan pada Gambar 10. Hasil kelas prediksi selanjutnya dapat digunakan untuk mengukur performa dari model pembelajaran LDA melalui evaluasi menggunakan metode *K-Fold Cross Validation*.

3.4 Evaluasi

Hasil klasifikasi untuk setiap iterasi pada 10-fold cross validation selanjutnya dapat diketahui nilai *confusion matrix* berupa hasil kalkulasi nilai TP (*True Positive*), TN (*True Negative*), FP (*False Positive*), dan FN (*False Negative*) dari 10 itersi percobaan (*fold*).

Tabel 5. Confusion Matrix pada 10-fold Cross Validation

Nilai Prediksi	Nilai Aktual	
	Cacar Monyet	Non-Cacar Monyet
Cacar Monyet	518	103
Non-Cacar Monyet	142	497

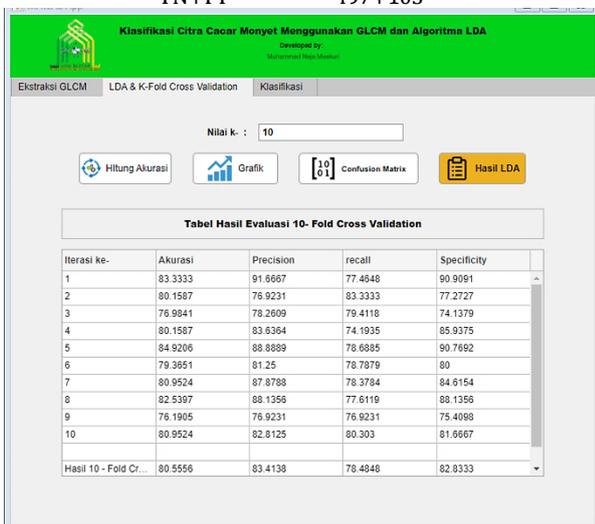
Nilai pada Tabel 5 *confusion matrix* tersebut, selanjutnya dapat digunakan untuk menghitung performa model pembelajaran klasifikasi algoritma LDA, yaitu melalui parameter *akurasi*, *presisi*, *recall*, dan *specificity*. Perhitungan parameter *akurasi*, *presisi*, *recall* dan *specificity* menggunakan rumus sebagaimana pada persamaan (11) sampai persamaan (14) dengan proses perhitungan sebagai berikut:

$$Akurasi = \frac{TP+TN}{TP+FP+FN+TN} \times 100 = \frac{518+497}{518+142+103+497} \times 100 = 80,55\%$$

$$Presisi = \frac{TP}{TP+FP} \times 100 = \frac{518}{518+103} \times 100 = 83,41\%$$

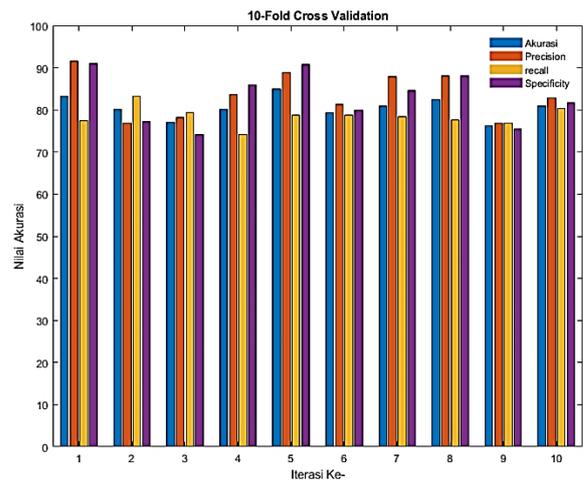
$$Recall = \frac{TP}{TP+FN} \times 100 = \frac{518}{518+142} \times 100 = 78,48\%$$

$$Specificity = \frac{TN}{TN+FP} \times 100 = \frac{497}{497+103} \times 100 = 82,83\%$$



Gambar 11. Hasil 10-Fold Cross Validation pada Program GUI Matlab

Gambar 11 merupakan hasil evaluasi metode 10 fold cross validation untuk setiap iterasi pada GUI Matlab. Dimana didapatkan 4 nilai berupa *akurasi*, *presisi*, *recall* dan *specificity* pada setiap iterasi melalui proses pemodelan dan pengujian dari iterasi 1-10. Visualisasi hasil *akurasi*, *presisi*, *recall* dan *specificity* pada 10 iterasi percobaan metode 10 fold cross validation dalam bentuk grafik ditunjukkan pada Gambar 12.



Gambar 12. Grafik hasil 10-fold cross validation

Berdasarkan Gambar 11 dan Gambar 12 dapat diketahui bahwa nilai akurasi tertinggi didapatkan pada iterasi percobaan ke-5 dengan nilai akurasi mencapai 84,92%, sedangkan akurasi terendah berada pada iterasi ke-9 dengan nilai akurasi sebesar 76,19%. Selanjutnya melalui perhitungan nilai *confusion matrix* pada 10-fold cross validation didapatkan nilai akhir rata-rata akurasi sebesar 80,55%, presisi 83%, recall 78% dan spesificity 82%. Performa model klasifikasi dapat dikatakan baik (*good classification*) jika memiliki nilai akurasi 80% - 90% [16]. Sehingga dapat disimpulkan bahwa proses klasifikasi citra penyakit cacar monyet menggunakan GLCM dan LDA berdasarkan evaluasi menggunakan 10 fold cross validation memiliki performa yang baik (*good classification*).

4. PENUTUP

4.1. Kesimpulan

Berdasarkan permasalahan yang telah dipaparkan, maka dapat disimpulkan bahwa proses klasifikasi citra cacar monyet

menggunakan GLCM dan LDA dapat dilakukan melalui beberapa proses, diantaranya proses *preprocessing* (*cropping, resizing, sharpening, augmentasi data, dan grayscaling*), proses ekstraksi ciri GLCM melalui 7 properti yaitu *contras, correlation, energi, homogenitas, entropi mean* dan *variance*, dan proses klasifikasi menggunakan algoritma LDA. Berdasarkan pemodelan LDA yang dilakukan pada dataset citra cacar monyet dan citra non-cacar monyet sejumlah 1260 data yang terdiri dari 660 citra cacar monyet dan 600 citra non-cacar monyet, melalui metode evaluasi *10-Fold Cross Validation* Didapatkan hasil evaluasi model klasifikasi yang dibangun menunjukkan nilai rata-rata akurasi dari sebesar 80,55%, presisi sebesar 78%, recall sebesar 80%, dan spesifisitas sebesar 79%. Hasil ini menunjukkan bahwa model klasifikasi yang dikembangkan memiliki performa yang baik (*good classification*) dalam membedakan citra cacar monyet dan non-cacar monyet.

4.2. Saran

Beberapa saran yang dapat dilakukan untuk penelitian selanjutnya agar menghasilkan penelitian yang lebih baik yaitu penambahan data citra lesi penyakit cacar dengan komposisi antara data citra lesi penyakit cacar dan non-cacar monyet yang seimbang, dalam hal ekstraksi ciri dapat menggunakan fitur GLCM lain atau menambahkan fitur GLCM yang sudah ada pada penelitian ini, Selain itu pada tahap pembentukan matrik GLCM penggunaan sudut dan jarak dapat di teliti lebih lanjut.

5. DAFTAR PUSTAKA

- [1] D. Grace, F. Christin, and H. Buan, "Penerapan Metode Runge-Kutta Orde 4 pada Pemodelan Penularan Penyakit Cacar Monyet," vol. 5, no. 2622, pp. 24–26, 2022.
- [2] L. Qelina and R. Graharti, "Human Monkeypox Virus: Respon Kesiapan Darurat," *Medula*, vol. 9 (3), pp. 483–489, 2019.
- [3] M. H. Temsah, F. Aljamaan, S. Alenezi, and Dkk, "Monkeypox caused less worry than COVID-19 among the general population during the first month of the WHO Monkeypox alert: Experience from Saudi Arabia," *Travel Med. Infect. Dis.*, vol. 49, no. July, p. 102426, 2022.
- [4] World Health Organization, "2022-23 Mpox (Monkeypox) Outbreak: Global Trends)," Internet. Accessed: Feb. 22, 2023. [Online]. Available:<https://worldhealthorg.shinyapps.io/mpxglobal/>
- [5] K. Yupie, S. Ajib, U. Ibnu, W. Mulyono, and D. P. Prabowo, "Klasifikasi Batik Kudus Berdasarkan Pola Menggunakan K-NN dan GLCM," pp. 509–514, 2020.
- [6] Muhathir, S. M Hamdani, and D. A. Larasati, "Wayang Image Classification Using SVM Method and GLCM Feature Extraction," *JITE (Journal Informatics Telecommun. Eng.*, vol. 4, no. 2, pp. 373–382, 2021.
- [7] W. I. Praseptiyana, A. W. Widodo, and M. A. Rahman, "Pemanfaatan Ciri Gray Level Co-Occurrence Matrix (GLCM) untuk Deteksi Melasma pada Citra Wajah," *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 3, no. 11, pp. 10402–10409, 2019.
- [8] A. Anggrestianingsih, A. W. Widodo, and M. T. Furqon, "Implementasi Metode Linear Discriminant Analysis (LDA) Untuk Klasifikasi Pengambilan Mata Kuliah Pilihan," vol. 3, no. 10. pp. 10337–10343, 2019.
- [9] Nurhalimah, P. S. W. I Gede, and B. Fitri, "Klasifikasi Kain Songket Lombok Berdasarkan Fitur GLCM dan Moment Invariant dengan Teknik Pengklasifikasian Linear Discriminant Analysis," vol. 2, no. 2, pp. 173–183, 2020.
- [10] P. S. Rizka, D. R. Ulfa, and R. S. Arie, "Implementasi Metode Linear Discriminant Analysis untuk Deteksi Kematangan pada Buah Stroberi," *Semin. Inform. Apl. Polinema 2020*, no. 2013, pp. 395–401, 2020.
- [11] S. Anwar and S. Maringan, "Implementasi Metode Color Moment dan GLCM Untuk Mendeteksi Penyakit Tanaman Karet," *Inf. dan Teknol. Ilm.*, vol. 7, no. 2, pp. 145–151, 2020.
- [12] G. Arunkumar, K. Geetha, S. Arulraj, and P. Rajesh, "an Enhanced Diagnosis

- Method for Cancer Detection Fuzzy Logic Method,” *Int. J. Electr. Eng. Technol.*, vol. 9, no. 5, pp. 183–191, 2018.
- [13] Y. Mohtar *et al.*, “Klasifikasi Kanker Paru Paru menggunakan Naïve Bayes dengan Variasi Filter dan Ekstraksi Ciri GLCM,” *Indones. J. Appl. Phys.*, vol. 11, no. 2, p. 256, 2021.
- [14] Z. Muhammad Syah, Jondri, and L. Kemas Muslim, “Prediksi Retweet Berdasarkan Feature User-based Menggunakan Metode Klasifikasi Support Vector Machine,” *eProceedings ...*, vol. 8, no. 5, pp. 11183–11191, 2021.
- [15] A. Luthfiyah, W. Yuni, and C. Nurul, “Penerapan Klasifikasi Random Forest Terhadap Data Gangguan Spektrum Autisme (ASD) Pada Anak – Anak Menggunakan Seleksi Fitur Principal Component Analysis,” *SENAMIKA (Seminar Nas. Mhs. Ilmu Komput. dan Apl.*, pp. 356–364, 2022.
- [16] P. Tiska and R. Didi, “COMPARISON OF DATA MINING CLASSIFICATION ALGORITHM FOR,” *J. Techno Nusa Mandiri*, vol. 17, no. 1, pp. 23–30, 2020.