

Analisis Penggunaan Segmentasi *K-Means* pada Klasifikasi Retinopati Diabetik

DOI: <http://dx.doi.org/10.35889/progresif.v22i3.4059>

Creative Commons License 4.0 (CC BY –NC)



Moh Arief Purwanto^{1*}, Muhammad Imam Ghozali², Wibowo Harry Sugiharto³

Teknik Informatika, Universitas Muria Kudus, Kudus, Indonesia

*e-mail Corresponding Author: purwanto.ariefmoh@gmail.com

Abstract

Diabetic retinopathy is one of the most common ocular complications of Diabetes Mellitus (DM) and is a leading cause of permanent blindness. Its occurrence is closely associated with the duration of diabetes. Diabetic retinopathy is characterized by abnormalities in the retinal blood vessels, including leakage, blockage, and, in advanced stages, the growth of abnormal blood vessels that are highly fragile and prone to bleeding, resulting in severe visual impairment. This study aims to develop an image classification system for diabetic retinopathy using the K-means segmentation method, Gray Level Co-occurrence Matrix (GLCM) feature extraction, and classification methods based on Support Vector Machine (SVM). The system's classification results were subsequently analyzed to evaluate its performance. The results showed that the model correctly classified 785 out of 2,306 observations, achieving an overall accuracy of 34.04%. Based on class-wise evaluation, the model demonstrated its best performance in Class PDR (Proliferative Diabetic Retinopathy), with a precision value of 0.450 and a sensitivity value of 0.492. Conversely, the lowest performance was observed in Class Moderate (Moderate Non-Proliferative Diabetic Retinopathy), with a precision value of 0.120 and a sensitivity value of 0.066

Keyword: *Diabetic Retinopathy; Segmentaion; K-Means; Gray Level Co-occurrence Matrix*

Abstrak

Retinopati diabetik merupakan salah satu komplikasi *Diabetes Melitus* (DM) pada mata yang paling banyak menyebabkan kebutaan menetap, terjadinya seiring dengan lamanya menderita DM. Retinopati diabetik ditandai dengan adanya gangguan pembuluh darah di retina berupa kebocoran, sumbatan dan pada tahap selanjutnya timbul pembuluh darah tidak normal yang sangat rapuh dan mudah menimbulkan pendarahan dengan segala akibat yang merugikan. Penelitian ini bertujuan untuk membangun sebuah sistem pengklasifikasian data citra retinopati diabetik menggunakan metode segmentasi K-means dengan metode ekstraksi ciri *Gray Level Co-occurrence Matrix* serta metode klasifikasi *Support Vector Machine* lalu memunculkan hasil dari sistem tersebut untuk selanjutnya dianalisis. Hasil penelitian menunjukkan hasil klasifikasi dengan benar 785 dari 2.306 data pengamatan dengan tingkat akurasi sebesar 34,04%. Berdasarkan evaluasi per kelas, model memiliki performa terbaik pada kelas PDR (*Proliferative Diabetic Retinopathy*) dengan nilai precision sebesar 0,450 dan sensitivity sebesar 0,492. Sebaliknya, performa terendah terdapat pada kelas Sedang (*Moderate Non-Proliferative Diabetic Retinopathy*) dengan nilai precision sebesar 0,120 dan sensitivity sebesar 0,066

Kata kunci: *Retinopati Diabetik; Segmentasi; K-Means; Gray Level Co-occurrence Matrix*

1. Pendahuluan

Retinopati diabetik merupakan salah satu komplikasi *Diabetes Melitus* (DM) pada mata yang paling banyak menyebabkan kebutaan menetap, terjadinya seiring dengan lamanya menderita DM. Semakin lama DM diderita semakin tinggi kemungkinan terjadinya retinopati [1]. Retinopati diabetik ditandai dengan adanya gangguan pembuluh darah di retina berupa kebocoran, sumbatan dan pada tahap selanjutnya timbul pembuluh darah tidak normal yang

sangat rapuh dan mudah menimbulkan pendarahan dengan segala akibat yang merugikan [2]. Retinopati diabetik tidak bisa dideteksi langsung secara kasat mata karena tanda-tandanya berada di bagian syaraf retina [3]. Tanda-tanda penyakit ini hanya dapat dilihat menggunakan foto fundus tetapi memerlukan waktu yang relatif lama untuk mengetahui hasilnya.

Permasalahan tersebut diselesaikan dengan membangun sebuah sistem yang dapat mendeteksi tingkat resiko retinopati diabetik dengan waktu yang relatif cepat. Sistem deteksi yang dibangun memerlukan sebuah model komputasi untuk mengubah piksel citra retina menjadi suatu ciri retina yang terindikasi retinopati diabetik [3]. Terdapat tiga permasalahan utama pada sistem, yaitu prapengolahan, ekstraksi ciri dan teknik klasifikasi.

Fadlila et al. [5] pada penelitiannya melakukan pengklasifikasian fase keparahan Diabetes Retinopati (Normal, NPDR, PDR, dan *Macular Edema/ME*) berdasarkan fitur citra digital retina, menggunakan ekstraksi ciri statistik orde pertama yang diambil dari histogram citra yaitu mean, variance, skewness, kurtosis, dan entropy dengan metode klasifikasi *Euclidean Distance K-Nearest Neighbors*. Penelitian tersebut menunjukkan penghapusan optical disk terbukti meningkatkan akurasi klasifikasi. Penelitian tersebut juga menyarankan penambahan langkah preprocessing lain misalkan *contrast enhancement* atau *gaussian blur* guna meningkatkan akurasi lebih lanjut.


Bebi et al. [6] pada penelitiannya melakukan ekstraksi fitur tekstur pada citra Retinopati Diabetik dengan metode *Tapis Gabor* (Ordo 1) pada dua objek utama yaitu pembuluh darah dan eksudat, dengan klasifikasi menggunakan SVM. Penelitian tersebut mengemukakan perbedaan hasil pada fitur pembuluh darah yaitu akurasi 92,9%, sensitivitas 92,9%, spesifisitas 96,7% serta fitur eksudat yaitu akurasi 82,1%, sensitivitas 82,1%, spesifisitas 94%. Dalam penelitian dari Bustomi [7] dikemukakan bahwa metode ekstraksi fitur ordo kedua memiliki keunggulan dibandingkan ordo pertama yaitu masing-masing sebesar 7,1%; 14,8%; dan 14,8% pada kasus tekstur warna kulit buah, kain dan daun pisang. Sehingga metode ekstraksi fitur ordo kedua selalu lebih unggul dibandingkan metode ekstraksi fitur ordo pertama. Penelitian itu juga memperlihatkan bahwa penggunaan matriks *co-occurrence* citra memberikan hasil yang lebih baik dibandingkan penggunaan murni histogram citra saja. Oleh sebab itu penelitian ini mengusulkan untuk menggunakan metode ekstraksi fitur ordo 2 yaitu *Gray Level Co-occurrence Matrix* pada Klasifikasi retinopati diabetik.

Tingkat keabuan (*gray level quantization*) pada piksel sendiri terdapat 256, sehingga pada metode *Gray Level Co-occurrence Matrix* (GLCM) menghasilkan matriks tingkat keabuan maksimal sebesar 256x256. Hal ini menyebabkan dilema yaitu ukuran matriks yang terlalu besar (jika tingkat keabuan tinggi) akan memberatkan komputasi sebaliknya hilangnya informasi tekstur atau detail halus (jika tingkat keabuan direduksi terlalu kecil) [8]. Oleh sebab itu pada penelitian ini dilakukan segmentasi K-means untuk yang bertujuan mengelompokkan piksel ke dalam beberapa cluster sehingga tingkat keabuan citra dapat direduksi dan area yang menjadi objek analisis lebih mudah diidentifikasi.

Metode klasifikasi yang digunakan dalam penelitian ini adalah pengklasifikasi *Support Vector Machine* (SVM). Pengklasifikasi SVM menggunakan sebuah fungsi atau hyperplane untuk memisahkan dua buah kelas pola [9]. Berbeda dengan jaringan syaraf tiruan yang hanya mencari hyperplane saja, SVM berusaha mencari hyperplane yang optimal dimana dua kelas pola dapat dipisahkan dengan maksimal [10].

2. Metodologi

Penelitian ini dilaksanakan melalui beberapa tahapan yang saling berkaitan dan disusun secara sistematis. Tahapan metodologi penelitian yang diusulkan adalah tahap pengumpulan data, pra-pengolahan, segmentasi, ekstraksi ciri, klasifikasi, dan analisis hasil. Untuk memberikan gambaran umum mengenai proses penelitian, alur penelitian disajikan dalam bentuk diagram alir sebagaimana ditunjukkan pada Gambar 1.



Gambar 1. Tahapan Penelitian

2.1 Pengumpulan Data

Data penelitian diperoleh dari dataset *Diabetic Retinopathy Detection* yang disediakan oleh EyePACS melalui kompetisi di Kaggle. Dataset berupa citra fundus retina beresolusi tinggi yang telah diberi label tingkat keparahan Retinopati Diabetik oleh dokter ahli, yaitu Normal (0), Ringan/*Mild* (1), Sedang/*Moderate* (2), Parah/*Severe* (3), dan *Proliferative Diabetic Retinopathy* (4). Masing-masing kelas terdiri atas 500 citra sehingga total data yang digunakan sebanyak 2.500 citra. Model sistem yang dibuat sendiri dibangun menggunakan Bahasa pemrograman *Python* pada *Google Collab*.

2.2 Pra-pengolahan

Pra-pengolahan berfungsi mempersiapkan citra agar dapat menghasilkan ciri yang lebih baik pada tahap berikutnya [4]. Pada tahap ini sinyal informasi ditonjolkan dan sinyal pengganggu (derau) diminimalisasi. Seluruh citra terlebih dahulu diseragamkan menjadi ukuran 720×480 piksel. Proses pra-pengolahan meliputi eliminasi *Optic Disk* (OD) menggunakan kanal merah, operasi morfologi, dan thresholding serta peningkatan kualitas citra menggunakan pemilihan kanal hijau, *Gaussian Filter*, CLAHE, dan *masking*. Eliminasi OD dilakukan untuk mengurangi kesalahan deteksi karena karakteristik OD yang menyerupai lesi eksudat.

2.3 Segmentasi

Citra hasil pra-pengolahan kemudian disegmentasi menggunakan algoritma K-Means. Algoritma K-Means merupakan salah satu metode pengelompokan data (*clustering*) non-hierarki yang banyak digunakan dalam analisis data [11]. Proses ini bertujuan mengelompokkan piksel ke dalam beberapa cluster sehingga tingkat keabuan citra dapat direduksi dan area yang menjadi objek analisis lebih mudah diidentifikasi [12].

Banyaknya kluster yang dipakai pada penelitian ini sendiri terdapat 6 kluster yaitu 5, 7, 9, 11, 13, dan 15. Sehingga apabila memakai 5 kluster maka terdapat 5 derajat keabuan, 7 kluster maka terdapat 7 derajat keabuan, 9 kluster maka terdapat 9 derajat keabuan dan seterusnya. Hal ini dilakukan tidak hanya untuk menemukan kluster optimal juga untuk menganalisis pengaruh kecil dan besarnya derajat keabuan terhadap hasil yang diperoleh.

2.4 Ekstraksi Ciri

Tahap ekstraksi ciri dilakukan menggunakan metode *Gray Level Co-occurrence Matrix* (GLCM). Hasil dari derajat keabuan tiap piksel pada citra yang telah melalui proses segmentasi diatas kemudian dijadikan matriks GLCM. Matriks GLCM dibentuk pada sudut 0° , 45° , 90° , dan 135° dengan jarak piksel 2. Dari matriks tersebut diperoleh beberapa fitur statistik, yaitu *maximum probability*, *entropy*, *energy*, *correlation*, *contrast*, dan *homogeneity*, yang selanjutnya digunakan sebagai masukan pada proses klasifikasi.

2.5 Klasifikasi

Klasifikasi merupakan proses pengelompokan suatu objek atau data ke dalam kategori yang telah ditetapkan sebelumnya. Dalam proses ini, kelas-kelas tujuan ditentukan terlebih dahulu, kemudian setiap data ditempatkan pada kelas yang sesuai berdasarkan kesamaan karakteristik atau atribut yang dimilikinya [13]. Pada penelitian ini Ekstraksi ciri yang telah didapat akan dibuat menjadi file ARFF untuk selanjutnya dipakai sebagai input pada aplikasi WEKA 3.9.4. Klasifikasi dilakukan menggunakan algoritma *Support Vector Machine* (SVM). SVM dikenal memiliki kemampuan yang baik dalam menangani data yang kompleks dan berdimensi tinggi sehingga mampu menghasilkan performa klasifikasi yang akurat [14]. Sebelum proses klasifikasi, data dibagi menggunakan metode *10-fold cross validation* menjadi data pelatihan dan data pengujian. Sistem kemudian mengelompokkan citra ke dalam lima tingkat keparahan Retinopati Diabetik sesuai label yang telah ditentukan.


2.6 Analisis Hasil

Kinerja sistem dievaluasi menggunakan parameter sensitivitas, spesifisitas, dan akurasi yang dihitung berdasarkan confusion matrix. Nilai-nilai tersebut digunakan untuk mengukur kemampuan sistem dalam mengidentifikasi setiap tingkat keparahan Retinopati Diabetik dan membandingkan performa klasifikasi pada masing-masing kelas.

3. Hasil dan Pembahasan

3.1 Pengumpulan Data


Data penelitian ini berasal dari data set citra Retinopati Diabetik EyePacs lewat kompetisi pada website kaggle.com yang disponsori oleh *California Healthcare Foundation*. Data telah melalui ahli atau disini dokter yang sudah membagi tiap citra retina kedalam lima tingkat yaitu Normal/tanpa Diabetik Retinopati (0), ringan/*mild* (1), sedang/*moderate* (2), parah/*severe* (3), dan *Proliferative Diabetic Retinopathy* (4) berdasarkan ditemukan atau tidaknya Mikroaneurisma, Hemorrhages, *Hard Exudates*, *Soft Exudates*, dan Neovaskularisasi. Pada setiap tingkat Retinopati Diabetik diambil data sebanyak 500 citra, sehingga data yang diolah 2500 citra, klasifikasinya berada pada file csv, disertai dengan nama file citra tersebut. Berikut merupakan beberapa contoh data citra Retinopati Diabetik tersebut.



Gambar 2. Contoh citra Retinopati Diabetik berdasarkan tingkatannya
(a)Tingkat 0, (b)Tingkat 1, (c)Tingkat 2, (d)Tingkat 3, (e)Tingkat 4

3.2 Pra-pengolahan

Data citra diubah resolusinya menjadi 720x480, kemudian diolah menggunakan bahasa pemrograman Python pada *Google Collab*. Proses selanjutnya adalah pengeliminasian *Optic Disk*. Adapun tahapannya, yaitu pemilihan *Red Channel*, *Histogram Specification*, *Erosi*, *Dilasi* dan *Thresholding*. Pemilihan *Red Channel* dilakukan dengan cara memilih *channel* pada citra *RGB* yang *Red*. Tetapi dalam pelaksanaannya, ditemukan permasalahan pada beberapa citra dataset, dimana beberapa citra memiliki kontras yang terlalu redup dan juga sebaliknya kontras yang terlalu terang. Sehingga pada saat pengambilan *Red Channel* dilakukan, *Optic Disk* tidak terlihat jelas.



Gambar 3. *Red Channel* bermasalah pada citra 10081_left.jpeg(a), 10022_left.jpeg(b), dan 10032_left.jpeg(c)

Oleh sebab itu, maka pada penelitian ini diambil keputusan untuk menggunakan citra *grayscale*. Untuk mendapatkan citra *Grayscale* tersebut digunakan nilai $\alpha = 0.299$, $\beta = 0.587$, dan $\gamma = 0.114$ berdasar standar Rec. 601 luma. Apabila didapat nilai Red = 120, Green = 40, dan Blue = 78 maka hasil *grayscale* akan seperti berikut :

$$\begin{aligned} I(x,y) &= 0.299 R + 0.587 G + 0.114 B \\ &= 0.299 \cdot 120 + 0.587 \cdot 40 + 0.114 \cdot 78 \\ &= 35.88 + 23.48 + 8.92 \\ &= 68.252 \end{aligned} \quad (1)$$

Setelah konversi citra ke *grayscale*, masih terdapat citra yang tidak terdeteksi *optic disk*-nya, karena *threshold* yang terlalu tinggi dan kualitas citra yang kurang baik sehingga *optic disk* ikut hilang. Oleh sebab itu, *optic disk* yang tidak terdeteksi, maka citra tersebut akan dilewati dan dimasukkan ke dalam file csv berisi semua citra yang bermasalah pada saat pendeteksian *optic disk*-nya. Setelah citra RGB diubah menjadi *grayscale*, langkah selanjutnya adalah *histogram specification*, yang dilakukan dengan mencari *Cumulative Density Function* (CDF) histogram pada citra data dan citra dengan histogram yang diinginkan. Selanjutnya memetakan histogram citra data ke dalam citra histogram yang diinginkan.




Gambar 4. (a) citra dengan histogram yang diinginkan dan (b) citra 10003_left.jpeg hasil *histogram specification*

Selanjutnya, citra akan mengalami proses Morfologi Matematika yaitu Erosi kemudian Dilasi untuk memperjelas *Optic Disk*. *Structuring Element* (SE) yang dipakai pada penelitian ini adalah (5,5) dengan iterasi pada Erosi dan Dilasinya 5.




Gambar 5. citra 10003_left.jpeg setelah mengalami erosi (a) dan dilasi (b)

Citra yang telah mengalami proses morfologi matematik, kemudian melewati proses *thresholding* untuk menghilangkan background dan memperjelas *optic disk*. Selanjutnya diambil koordinat kontur terbesar dari citra hasil *thresholding* untuk digunakan pada proses penghilangan *optic disk*.




Gambar 6. Citra 10003_left.jpeg setelah mengalami proses *thresholding*

Sebelum diproses dengan *K-means* dan *Gray Level Co-occurrence Matrix* citra melewati beberapa pra-pengolahan. Pertama citra akan melalui proses pemilihan *green channel*. Kemudian melalui proses *Gaussian Filter* untuk menghilangkan noise. Selanjutnya proses peregangan kontras menggunakan *Contrast-Limited Adaptive Histogram Equalization* (CLAHE). Terakhir proses *masking* selanjutnya dilakukan agar *background* berwarna hitam pada citra retina, tidak dihitung sebagai obyek. Pada proses ini juga dilakukan penghilangan *Optic Disk* sesuai dengan koordinat yang telah didapatkan pada proses sebelumnya.



3.3 Segmentasi K-means

Proses segmentasi citra pada penelitian ini dilakukan menggunakan algoritma *K-means*. Proses perhitungan *K-means* citra, dilakukan dengan pemilihan nilai acak piksel dalam citra sebanyak *centroid* yang sudah ditentukan [15]. Selanjutnya menghitung *eucledian distance* dari setiap piksel ke *centroid* awal yang sudah ditentukan. Piksel tersebut kemudian dimasukkan ke dalam *cluster centroid* dengan nilai *eucledian distance* terkecil, sehingga setiap piksel masuk ke dalam *cluster centroid* terdekat. Kemudian pada setiap *cluster centroid* tersebut dihitung means (rata-rata) untuk menjadi nilai *centroid* baru [16]. Selanjutnya kembali lagi ke proses perhitungan *eucledian distance* dari setiap piksel citra tetapi dibandingkan nilai *centroid* baru, kemudian menghitung *means centroid* pada setiap *cluster*. Proses ini dilakukan sampai nilai *means* dari setiap *centroid* tidak berubah sesuai toleransi yang ditentukan sebelumnya atau sebanyak iterasi yang sudah ditentukan sebelumnya [17]. Pada penelitian ini iterasi dilakukan sampai nilai *centroid* dibawah toleransi 1×10^{-4} atau maksimal sebanyak 300 iterasi. Gambar 7 menunjukkan citra 10003_left.jpeg setelah melakukan proses *clustering K-means* dengan banyaknya *cluster centroid* 5.



Gambar 8. citra 10003_left.jpeg setelah melalui *clustering K-means* dengan 5 *centroid*

Citra 10003_left.jpeg dengan cluster 5 nilai *K-means* yang didapatkan adalah 111.286034, 3.246978243, 175.7614979, 86.13298805 dan 137.3946562. Nilai tersebut kemudian diurutkan dari yang terkecil ke paling tinggi untuk menjadi nilai derajat keabuan yang akan dipakai pada saat GLCM.

Tabel 1. *cluster K-means* pada citra 10003_left.jpeg sesuai derajat keabuan

Derajat Keabuan	0	1	2	3	4
<i>Centroid</i>	3.246978243	86.13298805	111.286034	137.3946562	175.7614979

Setelah didapatkan nilai derajat keabuan yang direpresentasikan oleh setiap *centroid* tersebut, maka nilai derajat keabuan tersebut di-*mapping* ke dalam matriks piksel citra. Apabila pada matriks citra setelah mengalami *K-means* piksel bernilai 3.246978243 maka nilai tersebut

akan diganti menjadi nilai 0, nilai 86.13298805 akan diganti dengan nilai 1, dan seterusnya sesuai dengan tabel 1 sehingga akan didapatkan matriks derajat keabuan citra.

3.4 Ekstaksi Ciri dan Klasifikasi

Matriks derajat keabuan yang sudah didapatkan pada proses Segmentasi kemudian digunakan sebagai dasar dari proses ekstraksi ciri *Gray Level Co-occurrence Matrix* (GLCM). Pada proses ini ditentukan nilai dari jarak (*distance*) dan arah/sudut dari GLCM. Penelitian ini menggunakan dua *distance* yaitu 1 dan 2 piksel, serta empat arah yaitu 0°, 45°, 90°, dan 135° sehingga matriks GLCM yang terbentuk sebanyak delapan yaitu *distance* 1 piksel dengan sudut 0°, *distance* 1 piksel dengan sudut 45°, *distance* 1 piksel dengan sudut 90°, dst sampai *distance* 2 piksel dengan sudut 135°. Penggunaan empat arah utama (0°, 45°, 90°, dan 135°) adalah standar dalam ekstraksi fitur GLCM. Hal ini didasarkan pada definisi awal GLCM yang menggunakan keempat sudut tersebut untuk menangkap informasi tekstur dari berbagai orientasi [18]. Citra 10003_left.jpeg dengan *K-means centroid* lima akan menghasilkan derajat keabuan sebanyak lima juga sehingga matriks GLCM untuk tiap pasang *distance* dan arah yang terbentuk akan sebesar 5×5.

Langkah selanjutnya setelah mendapatkan matriks GLCM adalah mengambil ciri statistik dari citra. Ciri-ciri statistik yang diambil menggunakan GLCM adalah *maximum probability*, *entropi*, *energy*, korelasi, kontras, dan homogenitas. Berikut merupakan nilai GLCM pada citra 10003_left.jpeg dengan cluster 5, threshold 150, distance 1 piksel, dan arah 0°.

199761	410	52	32	36
370	29677	2956	5	0
125	2913	57295	2286	1
29	8	2316	30029	931
6	0	1	961	14920

Gambar 9. Nilai GLCM pada citra 10003_left.jpeg dengan cluster 5, threshold 150, distance 1 piksel, dan arah 0°.

Nilai – nilai tersebut kemudian dinormalisasikan dengan dibagi jumlah keseluruhan sehingga didapatkan:

0.578816064	0.001187993	0.000150672	9.27214E-05	0.000104312
0.001072091	0.08599038	0.008565137	1.44877E-05	0
0.000362193	0.008440542	0.16601472	0.006623783	2.89754E-06
8.40287E-05	2.31803E-05	0.006710709	0.087010315	0.002697612
1.73853E-05	0	2.89754E-06	0.002784539	0.04323134

Gambar 10. Nilai Hasil Normalisasikan

Nilai tersebut kemudian digunakan sebagai inputan untuk mendapatkan ciri-ciri statistik dari citra, seperti *maximum probability*, *entropi*, *energy*, korelasi, kontras, dan homogenitas. Berikut merupakan perhitungan dari ciri – ciri statistik tersebut:

1. Maximum probability

$$\max(p_{ij}) = \max(0.578816064, 0.001187993, 0.000150672, 9.27214E-05, 0.000104312, 0.001072091, 0.08599038, 0.008565137, 1.44877E-05, 0, 0.000362193, 0.008440542, 0.16601472, 0.006623783, 2.89754E-06, 8.40287E-05, 2.31803E-05, 0.006710709, 0.087010315, 0.002697612, 1.73853E-05, 0, 2.89754E-06, 0.002784539, 0.04323134) \\ = 0.578816064$$

2. Entropi

$$\text{entropi} = - \sum_{i=0}^{k-1} \sum_{j=0}^{k-1} p_{ij} \log_2 p_{ij} \quad (2) \\ = - (-1.986380655) \\ = 1.986380655$$

3. Energy

$$ASM = \sum_{i=0}^{k-1} \sum_{j=0}^{k-1} p_{ij}^2 \quad (3)$$

$$\begin{aligned} &= 0.379674298 \\ Energy &= \sqrt{ASM} \\ &= 0.616177164 \end{aligned} \quad (4)$$

4. Korelasi

$$korelasi = \sum_{i=0}^{k-1} \sum_{j=0}^{k-1} p_{ij} \left[\frac{(i - \mu_i)(j - \mu_j)}{\sqrt{(\sigma_i^2)(\sigma_j^2)}} \right] \quad (5)$$

$$\begin{aligned} &= \sum_{i=0}^{k-1} \sum_{j=0}^{k-1} p_{ij} \left[\frac{(i-0.93225255)(j-0.93225255)}{\sqrt{(1.248052489^2)(1.248052489^2)}} \right] \\ &= 1 \end{aligned}$$

5. Kontras

$$\begin{aligned} Kontras &= \sum_{i=0}^{k-1} \sum_{j=0}^{k-1} (i - j)^2 p_{ij} \\ &= 0.043845619 \end{aligned} \quad (6)$$

6. Homogenitas

$$\begin{aligned} Homogenitas &= \sum_{i=0}^{k-1} \sum_{j=0}^{k-1} \frac{p_{ij}}{1 + (i - j)^2} \\ &= 0.980240121 \end{aligned} \quad (7)$$

Setiap jarak dan sudut dari GLCM akan mendapatkan ciri statistik yang berbeda-beda. Terdapat dua jarak dan empat sudut yang telah ditentukan sebelumnya, lalu dari setiap pasangan jarak dan sudut tersebut menghasilkan enam ciri-ciri statistik. Sehingga terdapat 48 variabel inputan yang dipakai dalam proses klasifikasi selanjutnya. Variabel hasil dari ekstraksi ciri tersebut kemudian dimasukkan kedalam satu file CSV untuk kemudian disiapkan ke proses selanjutnya.

Proses klasifikasi SVM dilakukan dengan menggunakan *software machine learning* WEKA 3.9.4. Dikarenakan WEKA 3.9.4 membutuhkan input file ARFF, pertama-tama file CSV yang berisi variable inputan ciri statistic akan diubah menjadi file ARFF. Proses tersebut dilakukan dengan bantuan *converter online* yang bisa diakses pada situs <https://ikuz.eu/csv2arff>. Data tersebut kemudian melalui proses *cross-validation* untuk menentukan data pelatihan dan *data testing*. Pada penelitian ini dipilih *kfold 10* untuk proses *cross-validation*-nya. Selanjutnya dilakukan proses *training* dan *testing* untuk semua file ARFF hasil sistem. Hasil yang didapatkan setelah melalui proses klasifikasi adalah berupa *confusion matrix* untuk selanjutnya melalui proses analisis.

3.5 Analisis Hasil

Pengujian dilakukan pada file ARFF yang berisi ciri statistik GLCM yang telah melalui segmentasi K-means terlebih dahulu lalu diklasifikasikan menggunakan algoritma SVM dengan bantuan perangkat lunak WEKA 3.9.4. Berdasarkan hasil perangkat lunak WEKA 3.9.4 pada file ARFF, diperoleh output terbaik dari model sistem seperti pada Gambar 9. Dari gambar 9 tersebut dapat diambil *confusion matrix*-nya seperti pada Tabel 2 untuk kemudian dihitung *Sensitivity*, *Specificity* dan *Accuracy* lewat rumus berikut.

$$Sensitivity = \frac{TP}{TP + FN} \quad (8)$$

$$Specificity = \frac{TN}{TN + FP} \quad (9)$$

$$Accuracy = \frac{TP + TN}{TP + FN + TN + FP} \quad (10)$$

Tabel 2. *Confusion matrix* hasil file ARFF

	a (normal)	b (ringan)	c (sedang)	d (Parah)	e (PDR)
a (normal)	88	238	25	61	58
b (ringan)	53	284	29	70	34
c (sedang)	67	195	30	78	87
d (Parah)	37	159	22	167	85
e (PDR)	46	59	17	101	216
Sensitifity	18.72%	60.43%	6.56%	35.53%	49.20%
Specificity	88.94%	64.54%	94.97%	83.12%	85.86%
Accuracy	74.63%	63.70%	77.45%	73.42%	78.88%

```

Correctly Classified Instances      785           34.0416 %
Incorrectly Classified Instances    1521          65.9584 %
Kappa statistic                     0.1748
Mean absolute error                 0.2974
Root mean squared error             0.3963
Relative absolute error             92.953 %
Root relative squared error         99.0932 %
Total Number of Instances          2306

=== Detailed Accuracy By Class ===

      TP Rate  FP Rate  Precision  Recall   F-Measure  MCC      ROC Area  PRC Area  Class
      0.187    0.111    0.302     0.187    0.231     0.093    0.627    0.266     0
      0.604    0.355    0.304     0.604    0.404     0.205    0.646    0.280     1
      0.066    0.050    0.244     0.066    0.103     0.027    0.504    0.202     2
      0.355    0.169    0.350     0.355    0.353     0.185    0.625    0.281     3
      0.492    0.141    0.450     0.492    0.470     0.339    0.731    0.362     4
Weighted Avg.  0.340    0.166    0.329     0.340    0.311     0.168    0.626    0.278

=== Confusion Matrix ===

  a  b  c  d  e  <-- classified as
88 238 25 61 58 | a = 0
53 284 29 70 34 | b = 1
67 195 30 78 87 | c = 2
37 159 22 167 85 | d = 3
46  59 17 101 216 | e = 4

```

Gambar 11. Output WEKA 3.9.4 dari file .arff

Gambar 11 menunjukkan bahwa model yang dirancang mampu mengklasifikasikan dengan benar sebanyak 785 dari total 2.306 data observasi, atau menghasilkan tingkat akurasi total sebesar 34,04%. Sementara itu, sebanyak 1.521 observasi (65,96%) mengalami kesalahan klasifikasi. Apabila dibandingkan dengan Tingkat akurasi per kelas seperti pada yang Tabel 2 hasil akurasi total tersebut sangat jauh dibawah akurasi per kelasnya. Hal ini disebabkan oleh rumus dari perhitungan akurasi per kelas itu sendiri yang memiliki banyak nilai *True Negative*. Banyaknya nilai *True Negative* juga menimbulkan nilai *Specificity* yang tinggi per kelasnya seperti yang tertera pada Tabel 2. Walaupun begitu, nilai *Kappa Statistic* yang terdapat pada Gambar 9 sebesar 0,1748 menunjukkan bahwa tingkat kesesuaian antara hasil prediksi model dan kondisi aktual masih tergolong rendah, sehingga kemampuan model dalam membedakan kelas belum optimal. Terdapat 2.306 data observasi sendiri menunjukkan bahwa masih terdapat data citra yang tidak ditemukan *optic disk*-nya sebanyak 194 citra.

Disisi lain berdasarkan evaluasi per kelas, Kelas Sedang adalah yang paling buruk dikenali model dengan *sensitivity* 6,56%, hal ini berarti bahwa dari 457 data aktual Sedang, hanya 30 yang berhasil diklasifikasikan dengan benar. Kelas Ringan punya sensitivitas tertinggi (60,43%), tetapi memiliki nilai *precision* rendah (30,37%). Hal ini menunjukkan model sistem bias untuk memprediksi Kelas Ringan dengan total prediksi untuk kelas ini mencapai nilai 935, padahal data

aktualnya hanya 470. Sebagai contoh, data aktual Kelas Normal hanya berhasil diklasifikasikan benar sebanyak 88 data oleh model, sisanya masuk ke kelas lain dengan kelas 1 sebagai terbanyak mencapai 238 data. Kelas PDR memiliki keseimbangan terbaik antara *sensitivity* (49,20%) dan *precision* (45,00%), menjadikannya kelas dengan *F1-score* tertinggi (47,01%). Lalu Kelas Normal dan Parah sendiri masing-masing memiliki nilai *sensitivity* 18.72% dan 35.53%.

Hasil dari evaluasi pengaruh banyaknya derajat keabuan dalam GLCM yang ditunjukkan dengan banyaknya *centroid K-means* pada penelitian ini ditunjukkan pada Tabel 3 berikut.

Tabel 3. Hasil akurasi total terhadap tiap banyaknya derajat keabuan GLCM

Banyak Derajat Keabuan	Akurasi Total
5	31.4831%
7	32.3938%
9	33.2611%
11	33.2177%
13	33.0875%
15	34.0416%

Menurut Tabel 3, akurasi total yang didapatkan oleh model akan cenderung naik sesuai dengan banyaknya derajat keabuan pada GLCM yang dipakai walaupun kenaikan yang terjadi tidak terlalu signifikan yaitu dari 5 derajat keabuan ke 15 derajat keabuan terjadi kenaikan 8,13%.

3.6 Pembahasan

Berdasarkan hasil evaluasi model klasifikasi yang diperoleh dari aplikasi WEKA, dapat disimpulkan bahwa kinerja model masih belum menunjukkan hasil yang optimal dalam mengklasifikasikan data Retinopati Diabetik. Hal ini terlihat dari tingkat akurasi total yang hanya mencapai 34,04%, yang menunjukkan bahwa model masih memiliki keterbatasan dalam mengenali pola data secara keseluruhan. Rendahnya akurasi tersebut diperkuat oleh nilai *Kappa Statistic* sebesar 0,1748 yang mengindikasikan tingkat kesesuaian antara hasil prediksi model dengan kondisi aktual berada pada kategori rendah, sehingga kemampuan model dalam melakukan klasifikasi masih jauh dari baik.

Jika ditinjau berdasarkan evaluasi per kelas, terlihat adanya ketimpangan performa model dalam mengenali setiap kelas. Model menunjukkan kinerja terbaik pada kelas PDR (*Proliferative Diabetic Retinopathy*) ditunjukkan dengan keseimbangan terbaik antara *sensitivity* (49,20%) dan *precision* (45,00%) yang menjadikannya kelas dengan *F1-score* tertinggi (47,01%). Hal ini menunjukkan bahwa meskipun model masih sering keliru, namun kemampuan untuk mengenali kasus PDR relatif lebih baik dibandingkan kelas lainnya. Namun demikian, nilai tersebut masih belum cukup tinggi untuk dikatakan baik, karena masih terdapat lebih dari separuh prediksi yang tidak sesuai dengan kelas sebenarnya.

Sebaliknya, performa terendah ditemukan pada kelas Sedang (*Moderate Non-Proliferative Diabetic Retinopathy*), dengan *precision* sebesar 0,120 dan *sensitivity* sebesar 0,066. Nilai ini menunjukkan bahwa model sangat kesulitan dalam mengenali kelas tersebut, baik dari sisi ketepatan prediksi maupun kemampuan menangkap seluruh data aktual kelas Sedang. Hal ini sejalan dengan penelitian Alamri et al. menunjukkan bahwa model sering kesulitan membedakan kelas yang memiliki kemiripan visual, sehingga performa untuk kelas awal dan menengah seringkali jauh lebih rendah dibandingkan kelas lanjut. Hal ini terjadi karena fitur pada tahap awal lebih halus dan sulit ditangkap [19]. Kondisi ini mengindikasikan adanya kemungkinan ketidakseimbangan distribusi data atau kemiripan fitur yang tinggi antara kelas Sedang dengan kelas lainnya, sehingga model tidak mampu membentuk batas keputusan yang jelas. Hasil confusion matrix juga memperkuat temuan tersebut, di mana model cenderung mengklasifikasikan sebagian besar data ke kelas 1, menunjukkan adanya bias prediksi terhadap kelas tertentu.

Dalam penelitian dari Bustomi [7] dikemukakan bahwa metode ekstraksi fitur ordo kedua memiliki keunggulan dibandingkan ordo pertama yaitu masing-masing sebesar 7,1%; 14,8%; dan 14,8% pada kasus tekstur warna kulit buah, kain dan daun pisang. Tetapi dalam penelitian ini ditemukan hasil yang kurang memuaskan, sehingga dapat disimpulkan bahwa penggunaan ekstraksi ciri fitur ordo kedua belum tentu memiliki keunggulan dibandingkan dengan ekstraksi ciri fitur ordo pertama terutama pada klasifikasi citra retinopati diabetik.

Penggunaan segmentasi *K-means* untuk menentukan derajat keabuan yang digunakan pada *Gray Level Co-occurrence Matrix* (GLCM) pun tidak dapat dianjurkan penggunaannya mengacu pada hasil model yang telah dibuat. Hasil akurasi total yang diperoleh dibandingkan dengan derajat keabuan menunjukkan semakin banyaknya derajat keabuan pada GLCM maka dapat meningkatkan hasil akurasi total walaupun tidak terlalu signifikan yaitu kenaikan 8,13% dari 5 derajat keabuan ke 15 derajat keabuan. Perlu diadakan pengkajian ulang penggunaan segmentasi *K-means* untuk menentukan derajat keabuan sebelum ekstraksi ciri GLCM sehingga hasil akan menjadi lebih optimal. Penggunaan segmentasi khusus untuk dua ekstraksi ciri berbeda yaitu eksudat dan pembuluh darah seperti yang dilakukan Bebi et al. [6] pada penelitiannya mungkin akan memberikan hasil yang lebih baik.

Terdapatnya citra yang tidak terdeteksi *optic disk* sebanyak 194 citra menunjukkan bahwa proses prapengolahan yang masih belum optimal. Metode eliminasi *optic disk* yang mengandalkan tingkat keabuan paling terang yang dilakukan, menunjukkan kekurangan apabila diperuntukkan untuk data citra yang banyak dan kompilasi dari berbagai tempat dan waktu berbeda seperti dari *website* Kaggle.com yang dipakai pada penelitian ini. Penulis yakin bahwa dengan semakin berkembangnya teknologi data citra retinopati diabetik akan semakin baik dan terstandarisasi sehingga memudahkan untuk pengolahannya.

5. Simpulan

Hasil evaluasi menunjukkan bahwa kinerja model masih belum menunjukkan hasil yang optimal dalam mengklasifikasikan data citra Retinopati Diabetik. Model mampu mengklasifikasikan dengan benar 785 dari 2.306 data pengamatan dengan tingkat akurasi sebesar 34,04%. Berdasarkan evaluasi per kelas, model memiliki performa terbaik pada kelas PDR (*Proliferative Diabetic Retinopathy*) dengan nilai *precision* sebesar 0,450 dan *sensitivity* sebesar 0,492. Sebaliknya, performa terendah terdapat pada kelas Sedang (*Moderate Non-Proliferative Diabetic Retinopathy*) dengan nilai *precision* sebesar 0,120 dan *sensitivity* sebesar 0,066. Dalam penelitian ini, masih terdapat beberapa keterbatasan yang dapat menjadi bahan perbaikan pada penelitian selanjutnya, seperti optimalisasi metode eliminasi *optic disk*, optimalisasi parameter segmentasi, serta penggunaan metode ekstraksi ciri dan klasifikasi yang lebih beragam untuk memperoleh hasil yang lebih akurat dan stabil.

Daftar Referensi

- [1] Sudirman, "Pengaruh Diabetes Melitus Terhadap Tajam Penglihatan," *J. Kesehat. Qamarul Huda*, vol. 8, no. 1, pp. 1–7, 2020.
- [2] R. Manalu, S. Arifin, D. I. N. Pratiwi, M. A. Faisal, R. Adhani, and L. Marlinae, *Retinopati Diabetik: Mengungkap Rahasia Dibalik Kerusakan Retina*. Uwais Inspirasi Indonesia, 2025.
- [3] M. A. Putri, I. Setiawan, and S. Mujiyono, "Sistem Pengenalan Retina Menggunakan Self Organizing Map Untuk Mendeteksi Retinopati Diabetika," *J. Multimatrix*, vol. 5, no. 1, pp. 10–17, 2023.
- [4] M. Rofi and R. Ningtias, "Local Adaptive Thresholding Menggunakan Metode Sauvola sebagai Tahapan Pra Pengolahan pada Data Citra Isyarat EKG (Elektrokardiogram)," *Jurnal Teori dan Aplikasi Fisika*, vol. 10, no. 01, pp. 103–112, 2022.
- [5] Y. Fadlila Rachman and H. al Fatta, "Klasifikasi Citra Digitalretina Penderita Diabetes Retinopati Menggunakan Metode Euclidean," vol. 3, no. 2, pp. 75–82, 2020, [Online]. Available: <http://e-journal.unipma.ac.id/index.php/doubleclick>
- [6] N. Bebi et al., "Klasifikasi Retinopati Diabetik Berbasis Ciri Tekstur Tapis Gabor Menggunakan SVM," *Media ElektriKa*, vol. 18, no. 1, pp. 14-27, 2025, [Online]. Available: <http://jurnal.unimus.ac.id>
- [7] M. Bustomi, "Keunggulan Ekstraksi Fitur Ordo Kedua terhadap Ordo Pertama untuk Identifikasi Ciri Berbasis Tekstur Warna: Arief Bustomi," *Jurnal Fisika dan Aplikasinya*, vol. 15, pp. 119-127, Mei 2025, doi: 10.12962/j24604682.v15i3.5311.
- [8] A. Oprisan and S. A. Oprisan, "Scaling of Haralick features with image bit depth and gray level co-occurrence matrix displacement vector for linear gradients," *Comput Biol Med*, vol. 196 pp. 110880, Sep. 2025, doi: 10.1016/j.combiomed.2025.110880.
- [9] R. S. Tantika, "Penggunaan Metode Support Vector Machine Klasifikasi Multiclass pada Data Pasien Penyakit Tiroid," *Bandung Conf. Ser. Stat.*, vol. 2, no. 2, pp. 159–166, 2022.
- [10] Gunawan and Y. Reswan, "Desain Aplikasi Pengenalan Pola Tanda Tangan Menggunakan Metode Support Vector MachinE (SVM)," *J. Media Infotama Vol.17*, vol. 17, no. 1, pp. 8–12,

- 2021.
- [11] P. Sari, Efan, and R. Syahri, "ALGORITMA K-MEANS Clustering : Sebuah Studi Literatur," *J. Inform.*, vol. 1, no. 1, pp. 1–7, 2023, doi: 10.12345/juri.
 - [12] A. Sulistiyawati and E. Supriyanto, "Implementasi Algoritma K-means Clustering dalam Penentuan Siswa Kelas Unggulan," *J. Tekno Kompak*, vol. 15, no. 2, pp. 25–36, 2020.
 - [13] S. Rahayu and Y. Yamasari, "Klasifikasi Penyakit Stroke dengan Metode Support Vector Machine (SVM)," *J. Informatics Comput. Sci.*, vol. 5, no. 3, pp. 440–446, 2024.
 - [14] D. R. Nurqotimah, A. N. Khudori, and R. S. Pradini, "Implementasi Algoritma Support Vector Machine (SVM) Untuk Klasifikasi Penyakit Stroke," *J. Appl. Comput. Sci. Technol. Vol.*, vol. 5, no. 2, pp. 179–185, 2024.
 - [15] Y. Reswan, M. Syahrial, Y. Darmi, and D. Abdullah, "Analisis penggunaan algoritma k-means dan self-organizing maps dalam sistem deteksi kematangan tandan buah segar kelapa sawit berbasis citra digital," *J. Mhs. Tek. Inform.*, vol. 9, no. 5, pp. 8913–8920, 2025.
 - [16] Azrahwati, M. Nusrang, M. K. Aidid, and Z. Rais, "K-Means Cluster Analysis for Grouping Districts in South Sulawesi Province Based on Village Potential," *ARRUS J. Math. Appl. Sci.*, vol. 2, no. 2, pp. 73–82, 2022.
 - [17] U. D. Rosiani, C. Rahmad, M. A. Rahmawati, and F. Tupamahu, "Segmentasi berbasis k-means pada deteksi citra penyakit daun tanaman jagung," *JIP (Jurnal Inform. Polinema)*, vol. 6, no. 3, pp. 37–42, 2021.
 - [18] M. Malkauthekar, A. Gulve, and R. Deshmukh, "A novel Probabilistic Bi - Level Teaching – Learning - Based Optimization (P - BTLBO) algorithm for hybrid feature extraction and multi - class brain tumor classification using ResNet - 50 and GLCM," *J. Eng. Appl. Sci.*, vol. 72, no. 103, pp. 1–23, 2025.
 - [19] F. S. Alamri, T. Sadad, K. John, and A. Rashad, "Ensemble of graph neural networks with Transformer fusion for diabetic retinopathy severity classification," *Egypt. Informatics J.*, vol. 34, pp. 1–12, 2026, doi: 10.1016/j.eij.2026.100946.