

# Klasifikasi Citra *Diabetic Retinopathy* Menggunakan 3D-GLCM *Projection*

Rocky Yefrenes Dillak

Program Studi Teknik Informatika  
Politeknik Negeri Kupang  
Jl. Adisucipto, Penfui, Kupang, NTT  
rocky\_dillak@yahoo.com

Martini Ganantowe Bintiri

Jurusan Teknik Sipil, Fakultas Teknik  
Universitas Sintuwu Maroso  
Jl. P. Timor No. 1, Poso, Sulawesi Tengah  
gana75mart@yahoo.com

**Abstrak**—Penyakit diabetes melitus yang berkelanjutan akan mengakibatkan banyak komplikasi pada pasien penderita. Salah satu diantaranya adalah penyakit *diabetic retinopathy*. Pemeriksaan medis terhadap penderita penyakit *diabetic retinopathy* dilakukan pengamatan secara langsung pada citra retina menggunakan kamera fundus. Tingkat keparahan penyakit *diabetic retinopathy* dibagi atas empat kelas yakni: normal, non-proliferative *diabetic retinopathy* (NPDR), proliferative *diabetic retinopathy* (PDR), dan macular edema (ME). Penelitian ini bertujuan untuk mengembangkan suatu metode yang dapat digunakan untuk mengklasifikasi tingkat keparahan penyakit *diabetic retinopathy* berdasarkan citra retina pasien. Proses klasifikasi terhadap tingkat keparahan penyakit *diabetic retinopathy* dilakukan berdasarkan ciri statistik dari citra retina pasien yang diperoleh melalui proses ekstraksi ciri menggunakan metode ekstraksi 3D-GLCM *Projection* yang merupakan modifikasi metode 3D-GLCM. Ciri-ciri statistik tersebut kemudian dilatih menggunakan jaringan saraf tiruan dengan aturan pembelajaran *backpropagation algorithm*. Berdasarkan hasil pengujian yang dilakukan maka metode ini dapat melakukan klasifikasi terhadap tingkat keparahan penyakit *diabetic retinopathy* dengan sensitivity sebesar 100%, spesivisity sebesar 91% dan akurasi sebesar 95,83%.

**Kata kunci**—Penyakit *diabetic retinopathy*; 3D-GLCM *Projection*; ciri statistik; JST; *backpropagation algorithm*

## I. PENDAHULUAN

Retinopati Diabetes (DR) merupakan salah satu komplikasi penyakit diabetes dan apabila terlambat ditangani akan menyebabkan penderita mengalami kebutaan permanen.

Gejala yang ditunjukkan oleh penderita DR antara lain mikroneurisma, hemorrhages, hard exudates, soft exudates dan neovascularis. Gejala-gejala tersebut pada suatu intensitas tertentu dapat menjadi indikator fase (tingkat keparahan) retinopati diabetes. Secara umum fase tersebut dibagi dalam tiga fase, yaitu non-proliferative *diabetic retinopathy* (NPDR) proliferative *diabetic retinopathy* (PDR) serta macular edema (ME) [1].

Pemeriksaan medis terhadap penderita penyakit retinopati diabetes dilakukan dengan pengamatan secara langsung oleh dokter pada citra retina pasien yang diambil menggunakan

kamera fundus. Kelemahan metode ini adalah lambatnya penanganan penyakit tersebut. Oleh karena itu, untuk mengatasi kelemahan tersebut dibutuhkan sistem pengolahan citra digital berbasis *machine learning* yang mampu memproses citra retina secara cepat dan akurat dalam mengklasifikasi fase DR untuk membantu dokter dalam menetapkan tindakan medis secara cepat dan tepat.

Permasalahan yang sering muncul dalam penelitian tentang *anomaly detection* pada citra digital menggunakan *machine learning* adalah kesulitan memisahkan antara wilayah yang merupakan anomali (abnormal) dan wilayah yang bukan merupakan anomali (normal). Turut dikomputasinya wilayah normal sebagai ciri suatu anomali citra akan menyebabkan berkurangnya keunikan suatu anomali sehingga akan berakibat pada rendahnya kemampuan sistem dalam membedakan anomali dan bukan anomali dalam suatu citra [2]. Hal ini dapat terjadi juga pada penelitian tentang DR dimana terdapat wilayah tertentu dalam citra retina yang sebaiknya dieliminasi karena tidak mengandung ciri (keunikan), dalam penelitiannya [3] mengatakan bahwa *optic disc* (OD) merupakan suatu wilayah dalam citra retina normal yang memiliki karakteristik yang mirip dengan ciri yang terdapat dalam kelainan *exudate* pada citra penyakit DR. Hal ini juga didukung oleh beberapa penelitian yang melakukan eliminasi OD sebelum deteksi gejala *exudate* menghasilkan akurasi lebih tinggi dibandingkan dengan akurasi tanpa eliminasi OD [4]. Berdasarkan uraian di atas maka OD semestinya merupakan wilayah yang dieliminasi dan tidak perlu dikomputasi pada saat klasifikasi DR karena dapat mempengaruhi akurasi klasifikasi.

Chen, dkk. (2009) dalam penelitian mereka menggunakan 3D *Co-occurrence Matrix* (3D-GLCM) dan 3D *Co-occurrence Matrix* (3D-GLCM) *Projection* untuk pengenalan iris mata, dimana dari hasil penelitian mereka menunjukkan bahwa 3D-GLCM *Projection* memiliki akurasi yang lebih baik (mencapai 99.65%) dibandingkan dengan 3D-GLCM (mencapai 94.83%) dan pada penelitian kami sebelumnya telah dilakukan menggunakan 3D-GLCM untuk klasifikasi DR mencapai akurasi 91,67% [6].

Berdasarkan latar belakang tersebut di atas, penelitian ini akan mengkaji pengaruh ekstraksi ciri menggunakan 3D-GLCM *Projection* untuk mengklasifikasi fase citra *diabetic*

retinopathy dengan pendekatan eliminasi *optic disc* (OD) menggunakan algoritma jaringan syaraf tiruan *backpropagation*.

Penelitian ini bertujuan untuk mengembangkan suatu metode yang dapat digunakan untuk melakukan klasifikasi terhadap fase retinopati diabetes menggunakan 3D-GLCM Projection [5] dengan *classifier* jaringan syaraf tiruan *Backpropagation*. Manfaat penelitian ini adalah untuk menghasilkan suatu metode yang dapat digunakan untuk melakukan klasifikasi terhadap fase retinopati diabetes. Penelitian ini juga diharapkan memberikan informasi bagi penelitian lanjutan tentang klasifikasi fase retinopati diabetes.

## II. TINJAUAN PUSTAKA

Penelitian tentang deteksi gejala DR dilakukan oleh [7] yang melakukan penelitian tentang deteksi gejala *hemorrhage* menggunakan *template matching*. Hasil dari penelitian ini menunjukkan sensitifitas sistem sebesar 85%. Penelitian serupa juga dilakukan oleh [8] yang meneliti tentang klasifikasi gejala *hard exudates* pada citra DR menggunakan metode RBF. Akurasi dari penelitian ini adalah 88.1 %.

David, dkk. (2008) melakukan perbandingan klasifikasi fase menggunakan LVQ dan *backpropagation*. Hasilnya adalah *backpropagation* dapat melakukan klasifikasi dengan akurasi lebih tinggi yakni 93.3% dibandingkan LVQ 90.3%. Penelitian serupa juga dilakukan [9] yang melakukan penelitian tentang klasifikasi gejala DR pada citra DR menggunakan metode ekstraksi ciri histogram serta algoritma klasifikasi *Leaning Vector Quantization* (LVQ). Gejala – gejala DR yang diklasifikasi adalah mikroneurisma, *exudates*, dan *hemorrhage*. Hasil dari penelitian ini adalah *sensititivity* 93.33 % dan *specificity* sebesar 90%.

Penelitian tentang klasifikasi fase DR juga dilakukan oleh [10] menggunakan metode ekstraksi ciri histogram dan *multi layer perceptron* (MLP). Pendekatan yang dilakukan dalam penelitian ini yakni menghitung luasan daerah *exudates*, dan daerah *blood vessel* untuk kemudian dilatihkan pada *classifier* jaringan syaraf tiruan MLP.

Acharya, dkk. (2011) melakukan penelitian menggunakan *classifier support vector machine* (SVM) untuk melakukan klasifikasi terhadap fase retinopati diabetes. Pada penelitian ini dilakukan preprosesing pada citra retina yakni mengkonversi RGB ke bentuk *grayscale* dan dilakukan *adaptive histogram equalization*. Setelah preprosesing, maka citra retina DR akan di *crop* secara manual untuk memisahkan wilayah retina dari *background*. Langkah selanjutnya adalah melakukan ekstraksi *feature* (ciri) menggunakan metode *gray level co-occurrence* (GLCM) sebagai masukan pada SVM sebagai *clasifier*. Chen, dkk. (2009) dalam penelitian mereka menggunakan 3D-GLCM dan 3D-GLCM Projection menunjukkan bahwa 3D-GLCM Projection memiliki akurasi yang lebih baik dibandingkan 3D-GLCM untuk itu pada penelitian ini peneliti memanfaatkan 3D-GLCM projection untuk ekstraksi ciri citra *diabetic retinopathy* yang kemudian akan diklasifikasi menggunakan JST *backpropagation*.

## III. METODE PENELITIAN


### A. Analisis Kebutuhan Sistem

Sesuai dengan analisis kebutuhan system yang dilakukan maka sistem yang dibangun harus mampu melakukan beberapa hal berikut:

1. Membaca citra masukan.
2. Melakukan *preprocessing* terhadap citra masukan.
3. Mengeliminasi *optic disc* pada citra masukan..
4. Mengekstrak ciri citra masukan.
5. Melakukan training terhadap ciri yang telah diekstrak.
6. Menampilkan hasil klasifikasi terhadap suatu citra.

### B. Rancangan Arsitektur Sistem

Peneliti mengusulkan arsitektur sistem seperti Gambar 1. Penjelasan pada sub-bab berikut memaparkan dengan lebih detail proses yang terjadi dalam setiap bagiannya.



Gambar 1. Arsitektur sistem klasifikasi fase retinopati diabetes

#### 1) Preprocessing

Tujuan utama dari preprosesing citra adalah untuk meningkatkan kualitas citra dimana citra yang dihasilkan dapat memberikan informasi yang lebih jelas bagi manusia sehingga memudahkan dalam melakukan interpretasi atas suatu citra [2]. Dalam penelitian ini digunakan dua teknik preprosesing sebagai berikut :

##### a) Peregangan Kontras

Kontras suatu citra adalah distribusi piksel gelap dan terang. Citra keabuan dengan kontras yang rendah akan terlihat terlalu gelap, terlalu terang, atau terlalu abu-abu. Pada peregangan kontras, setiap piksel pada citra A ditransformasi menggunakan fungsi berikut:

$$B(i, j) = \frac{A(i, j) - c}{(d - c)} (L - 1) \quad (1)$$

Dengan B(i,j) dan A(i,j) berturut-turut menyatakan piksel sesudah dan sebelum ditransformasi, c dan d menyatakan nilai minimum dan maksimum dari piksel citra masukan serta L menyatakan nilai *grayscale* maksimum.

##### b) Filter Median

Filter median adalah salah satu filter yang sangat baik dalam mereduksi *noise* berjenis *salt & pepper* sehingga sangat sering digunakan dalam memperbaiki kualitas citra retina khususnya penelitian dibidang retinopati diabetes [12]. Filter median bekerja dengan mengganti nilai suatu piksel pada citra asal (pusat citra)

dengan nilai median dari piksel citra asal tersebut berdasarkan suatu lingkungan tetangga (*window*) yang diformulasikan :

$$f(x, y) = \text{median}\{g(s, t) \mid (s, t) \in S_{x,y}\} \quad (2)$$

Dimana  $S_{x,y}$  merupakan suatu *window*. Pada umumnya ukuran *window* ( $S_{x,y}$ ) yang dipilih adalah bernilai ganjil. Jika  $S_{x,y}$  adalah genap, nilai tengahnya diambil dari nilai rata-rata dua buah piksel yang ditengah. Ukuran *window* yang biasa digunakan yaitu 3x3, 5x5 dan 7x7.

## 2) Eliminasi Optic Disc

*Optic Disc* (OD) atau pusat syaraf mata merupakan daerah pada mata tempat syaraf mata memasuki retina dan merupakan pertemuan seluruh syaraf mata [13]. Tahap – tahap eliminasi OD adalah *thresholding*, dilasi, invert dan perkalian citra sebagai berikut :

### a) Thresholding

*Thresholding* adalah proses mengubah citra berderajat keabuan menjadi citra biner atau hitam putih sehingga dapat diketahui daerah mana yang termasuk obyek dan *background* dari citra secara jelas. Untuk keperluan segmentasi OD maka digunakan metode *thresholding* global dengan  $T=203$ , menggunakan persamaan:

$$g(x, y) = \begin{cases} 1 & \text{if } f(x, y) > T \\ 0 & \text{if } f(x, y) \leq T \end{cases} \quad (3)$$

### b) Dilasi

Operasi dilasi merupakan suatu operasi morfologi citra yang dilakukan untuk memperbesar ukuran segmen obyek dengan menambah lapisan disekeliling obyek. Operasi morfologi dilasi menggunakan dua buah input yaitu suatu citra dan suatu *window* yang disebut juga *structuring element* (SE). SE merupakan suatu matrik yang umumnya berukuran kecil yang digunakan untuk memperbesar citra input.

Pada citra biner, dilasi merupakan proses penggabungan titik-titik latar (0) menjadi bagian dari objek [1], berdasarkan *structuring element* yang digunakan. Bila suatu obyek (citra input) dinyatakan dengan A dan SE dinyatakan dengan B serta Bx menyatakan translasi B sedemikian sehingga pusat B terletak pada x, maka operasi dilasi A dengan B dapat dinyatakan sebagai berikut :

$$D(A, B) = A \oplus B = \{x : B_x \cap A \neq \emptyset\} \quad (4)$$

dengan  $\emptyset$  menyatakan himpunan kosong.

Proses dilasi dilakukan dengan membandingkan setiap pixel citra input dengan nilai pusat SE, dimana

nilai pusat SE diletakan pada pixel citra input. Jika ada 1 pixel SE sama dengan nilai pixel citra input, maka nilai pixel citra input tersebut diganti dengan nilai 1. Proses serupa dilanjutkan dengan menggerakkan SE pixel demi pixel pada citra input.

### c) Invert

Invert adalah proses pemetaan nilai pixel suatu citra (dalam hal ini citra biner) dimana nilai pixel hitam (0) akan dirubah menjadi putih (1) demikian juga sebaliknya.

### d) Perkalian Citra

Perkalian dua buah citra dapat dilakukan dengan persamaan :

$$C(x, y) = A(x, y) * B(x, y) \quad (5)$$

di mana

C = citra hasil perkalian citra A dan citra B

x, y = posisi pixel

## 3) Pembentukan 3D-GLCM Projection

Penelitian ini menggunakan 3D-GLCM *Projection* [5] yang dibentuk menggunakan jarak 1 pixel tetangga ( $d=1$ ) menggunakan multiple arah. Jarak 1 pixel tetangga dipilih karena termasuk salah satu jarak ideal dalam membentuk GLCM [14]. Langkah – langkah membentuk 3D-GLCM *Projection* sebagai berikut :

- Tetapkan jarak pixel ( $d$ ) yang diinginkan.
- Hitung semua arah yang mungkin.
- Bentuk 3D-GLCM untuk setiap arah (menggunakan langkah – langkah membentuk 3D-GLCM).
- Proyeksikan 3D-GLCM yang telah terbentuk ke tiga bidang 2D.
- Hitung semua ciri statistik untuk setiap arah yang terbentuk.
- Hitung rata – rata (mean) dari setiap ciri pada semua arah yang terbentuk.

Jumlah arah yang terbentuk pada distance  $d=1$  adalah 16, artinya terdapat 16 3D-GLCM yang terbentuk ( $M_1$  sampai  $M_{16}$ ) atau 48 2D-GLCM yang terbentuk (Hasil proyeksi 3D-GLCM).

## 4) Ekstraksi ciri 3D-GLCM Projection

Setelah 3D-GLCM *projection* terbentuk pada jarak  $d$  dan semua arah yang mungkin , maka langkah selanjutnya adalah menghitung ciri statistik dari semua 3D-GLCM *Projection* yang terbentuk. Enam ciri (fitur) yang digunakan dalam penelitian ini adalah : (i) *maximum probability*, (ii) entropi, (iii) energy, (iv) korelasi, (v) kontras, dan (vi) homogenitas, seperti yang diusulkan oleh [14]. Proses ekstraksi ciri dilakukan dengan menghitung 6 ciri statistik dari setiap 3D-GLCM yang telah diproyeksikan ke 3 bidang datar 2D menggunakan fitur indexes 2D sebagai berikut :

a. Max Probability =  $\max(p_{ij})$  (6)

b. Entropi.  
Entropi menunjukkan ukuran ketidakteraturan distribusi intensitas suatu citra pada matriks *co-occurrence*. Persamaannya untuk menghitung entropi adalah:

$$\text{Entropi} = -\sum_{i=1}^q \sum_{j=1}^q P_{i,j} \log_2 P_{i,j} \quad (7)$$

c. Energi.  
Energi adalah fitur untuk mengukur konsentrasi pasangan intensitas pada matriks *co-occurrence* [15]. Nilai energi akan makin membesar bila pasangan piksel yang memenuhi syarat matriks intensitas *co-occurrence* terkonsentrasi pada beberapa koordinat dan mengecil bila letaknya menyebar. yang digunakan untuk menghitung energi adalah :

$$\text{Energi} = \sum_{i=1}^q \sum_{j=1}^q P_{i,j}^2 \quad (8)$$

d. Korelasi.  
Ciri ini menunjukkan tingkat korelasi antar pixel dalam suatu citra. Persamaannya adalah :

$$\text{Korelasi} = \frac{1}{q} \sum_{i=1}^q \sum_{j=1}^q \frac{(i-m_r)(j-m_c)}{\sigma_r \sigma_c} P_{i,j} \quad (9)$$

e. Kontras  
Kontras adalah fitur yang digunakan untuk mengukur kekuatan perbedaan intensitas dalam citra [15]. Nilai kontras membesar jika variasi intensitas citra tinggi dan menurun bila variasi rendah. Persamaan yang digunakan untuk mengukur kontras suatu citra ditunjukkan pada persamaan di bawah ini :

$$\text{Kontras} = \sum_{i=1}^q \sum_{j=1}^q (i-j)^2 P_{ij} \quad (10)$$


f. Homogenitas  
Homogenitas digunakan untuk mengukur kehomogenan variasi intensitas citra [15]. Nilai homogenitas akan semakin membesar bila variasi intensitas dalam citra mengecil. Homogenitas dihitung dengan persamaan di bawah ini :

$$\text{Homogeneitas} = \frac{1}{q} \sum_{i=1}^q \sum_{j=1}^q \frac{P_{i,j}}{1+|i-j|} \quad (11)$$

Untuk melakukan klasifikasi terhadap fase DR, maka hasil proses ekstraksi ciri statistik selanjutnya akan dijadikan sebagai data masukan untuk dilatih dengan jaringan syaraf tiruan (JST) untuk mengenali pola inputan serta pasangan pola outputnya.

## 5) Pelatihan Jaringan Syaraf Tiruan Backpropagation

Proses pelatihan jaringan pada dasarnya merupakan proses penyesuaian bobot-bobot untuk masing – masing simpul antara lapisan input, lapisan tersembunyi, dan lapisan output. Penyesuaian bobot dilakukan secara terus-menerus sampai dicapai *error* yang paling minimum [16] ; [17]. Fungsi aktivasi yang digunakan adalah fungsi aktivasi *tangent hyperbolic*. Flowchart algoritma pelatihan JST *backpropagation* seperti pada Gambar 2.




Gambar 2. Pelatihan JST

- Data input yang digunakan sebagai pola dalam pelatihan JST sebanyak 6 buah yang terdiri atas 6 buah ciri statistik dan bias. Data inputan tersebut adalah :  
 x1 = *maximum probability*  
 x2 = *correlation*  
 x3 = *contrast*  
 x4 = *energy*  
 x5 = *entropy*  
 x6 = *homogeneity*  
 x7 = *bias*
- Jumlah *hidden layer* : 1 lapisan tersembunyi, dengan jumlah neuron dalam lapisan tersembunyi divariasikan antara 5 - 7 neuron pada setiap *hidden layer*.
- Jumlah *neuron* dalam lapisan output sebanyak 1 *neuron* dengan target seperti pada Tabel 1.

TABLE I. TARGET OUTPUT JST

| Kelas  | Target |
|--------|--------|
| Normal | 0.0    |
| NPDR   | 0.1    |
| PDR    | 0.2    |
| ME     | 0.3    |


Arsitektur JST yang digunakan dalam penelitian ini seperti ditunjukkan pada Gambar 3.



Gambar 3. Arsitektur JST

#### 6) Pengujian Jaringan Syaraf Tiruan Backpropagation


Setelah JST dilatih dengan sekumpulan pola maka tahap selanjutnya adalah melakukan pengujian terhadap kinerja dari JST sekaligus untuk mengukur kinerja dari sistem yang dibangun. Algoritma pengujian jaringan syaraf tiruan mengikuti *flowchart* seperti Gambar 4.



Gambar 4. Pengujian JST

#### C. Implementasi

Hasil visual implementasi dapat dilihat pada gambar form seperti ditunjukkan pada Gambar 5.



Gambar 5. Contoh tampilan form

## IV. HASIL DAN PEMBAHASAN

Pada penelitian ini, pengujian dilakukan dengan melatih JST secara berulang-ulang untuk mendapatkan bobot-bobot jaringan yang optimal sehingga dapat digunakan untuk menyelesaikan permasalahan klasifikasi. Data yang digunakan dalam penelitian ini berjumlah 200 citra terbagi atas dua kelompok data yakni:

- Data pelatihan 150.
- Data pengujian 50 citra.

Data – data tersebut diekstrak menggunakan metode 3D-GLCM *Projection* dengan jarak 1 pixel tetangga. Parameter JST yang digunakan dalam pengujian ini adalah sebagai berikut :

- *Learning rate* ( $\alpha$ ) = 0.1.
- *Momentum* ( $\mu$ ) = 0.9.
- Jumlah lapisan tersembunyi = 1 lapis.
- Jumlah neuron dalam lapis tersembunyi = 5.
- Batas toleransi *error* = 0,001

#### A. Pengujian Akurasi Kinerja JST Backpropagation

Kinerja JST dalam mengklasifikasi fase citra retinopati diabetes diuji menggunakan data citra sebanyak lima puluh buah citra yang telah diproses menggunakan dua pendekatan yakni pendekatan eliminasi *optic disc* dan pendekatan tanpa eliminasi *optic disc*. Hasil pengujian yang diperoleh digunakan untuk menghitung sensitivitas, spesivitas, dan akurasi berdasarkan persamaan yang dilakukan pada penelitian sebelumnya [18].

Sensitivitas adalah persentasi abnormal hasil klasifikasi sistem sesuai klasifikasi dari kamera fundus. Spesivitas adalah persentasi normal hasil klasifikais sistem sesuai klasifikasi dari kamera fundus. Semakin besar nilai persentase sensitivitas dan nilai persentase spesivitas dari sistem maka semakin baik pula kinerja dari sistem tersebut.

TABLE II. HASIL PENGUJIAN

| Kelas  | Data Latih | Data Uji | Klasifikasi |       | Klasifikasi (%) |
|--------|------------|----------|-------------|-------|-----------------|
|        |            |          | Benar       | Salah |                 |
| Normal | 25         | 10       | 10          | 0     | 100.00%         |
| NPDR   | 50         | 10       | 9           | 1     | 90.00%          |
| PDR    | 50         | 15       | 15          | 0     | 100.00%         |
| ME     | 25         | 15       | 14          | 1     | 93.33%          |

Berdasarkan hasil pengujian seperti pada Tabel 2 maka dapat dihitung sensitivitas, spesivitas dan akurasi sistem berdasarkan persamaan yang dikemukakan [18] sebagai berikut :

$$\text{Sensitivity} = \frac{TP}{TP + FN} \quad (12)$$

$$\text{Specivicity} = \frac{TN}{TN + FP} \quad (13)$$

$$\text{Accuracy} = \frac{\sum \% \text{klasifikasi fase}}{n} \quad (14)$$

TP (*true positive*) adalah citra abnormal yang berhasil dideteksi sebagai abnormal oleh sistem, FN (*false negative*) adalah citra normal yang dideteksi sebagai abnormal oleh sistem, TN (*true negative*) adalah citra normal dideteksi normal oleh sistem, FP (*false positif*) adalah citra abnormal dideteksi sebagai citra normal oleh sistem, %klasifikasifase adalah persentase klasifikasi benar dari tiap kelas yang dihitung dengan rumus jumlah klasifikasi benar pada kelas itu dibagi dengan jumlah data pengujian pada kelas yang sama dikali 100%, dan n adalah banyaknya kelas.

TABLE III. SENSITIVITY, SPECIFICITY, DAN ACCURACY

| <i>Sensitivity in %</i> | <i>Specificity in %</i> | <i>Percentage of accuracy (%)</i> |
|-------------------------|-------------------------|-----------------------------------|
| 100.00%                 | 91.00%                  | 95.83%                            |

Hasil pengujian akurasi kinerja JST *Backpropagation* menggunakan ekstraksi ciri 3D-GLCM *Projection* ditunjukkan pada Tabel 2. Tabel 3 menunjukkan hasil *sensitivity*, *specificity*, dan *percentage of accuracy*, untuk empat fase citra retina menggunakan klasifikasi JST *Backpropagation*. Hasil pengujian menunjukkan bahwa sistem dapat mendeteksi kelas Normal dan PDR dengan akurasi 100% sedangkan pada kelas NPDR akurasinya 90% dan ME akurasinya 93.33%. Sensitivitas dari sistem mencapai 100% dan spesivisitas dari sistem mencapai 91%. Akurasi dari sistem adalah 95.83%.

#### B. Perbandingan Akurasi 3D-GLCM *Projection* dan 3D-GLCM

Berdasarkan hasil kajian di atas jelas terlihat bahwa klasifikasi fase retinopati diabetes menggunakan ekstraksi ciri 3D-GLCM *Projection* memberikan hasil yang lebih baik terhadap akurasi sistem dibandingkan dengan ekstraksi ciri 3D-GLCM yang dilakukan [6] pada penelitian sebelumnya. Tabel 4 menunjukkan bahwa kinerja sistem yang menggunakan 3D-GLCM *Projection* sangat baik.

TABLE IV. PERBANDINGAN HASIL DENGAN PENELITIAN SEBELUMNYA

| Peneliti                | Ekstraksi ciri            | Percentage of accuracy (%) |
|-------------------------|---------------------------|----------------------------|
| Dilak dan Martini, 2012 | 3D-GLCM                   | 91.67%                     |
| Dilak dan Martini, 2013 | 3D-GLCM <i>Projection</i> | 95.83%                     |

## V. KESIMPULAN

- Metode yang dikembangkan mampu melakukan klasifikasi terhadap citra retinopati diabetes pada kelas normal, NPDR, PDR dan ME.
- Pendekatan klasifikasi yang dilakukan dalam penelitian ini dapat melakukan klasifikasi dengan hasil *Sensitivity* 100%, *Specificity* 91% dan akurasi 95.83%.
- Akurasi klasifikasi sistem menggunakan 3D-GLCM *Projection* menunjukkan hasil yang lebih baik (4.16%) dibandingkan dengan 3D-GLCM.

## PENGHARGAAN DAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada database MESSIDOR yang telah memberikan dukungan data citra retinopati diabetes beserta data hasil pemeriksaan medis terhadap penelitian ini.

## DAFTAR PUSTAKA

- P. Mithcell, S. Foran, T.Y. Wong, B. Chua, I. Patel, dan E. Ojaimi Guidelines for the Management of Diabetic Retinopathy, 2008, Electronic Publication, National Health and Medical Research Council (NHMRC), Australia.
- M. Kuivaleinen, Retinal Image Analysis Using Machine Vision, Tesis, Departemen of Information Technology, Lappeenranta University of Technology, Lappeenranta, 2005.
- A. Sopharak, M.N. Dailey, B. Uyyanonvara, S. Barman, T. Williamson, K.T. New, dan Y.A. Moe, Machine Learning Approach to Automatic Exudate Detection in Retinal Images from Diabetic Patients, *Journal of Modern Optic*, 2010, No. 2, Vol. 57 : 124-135.
- J. David, R. Krihnan, dan S. Kumar, Neural Network Based retinal Image Analysis, *IEEE*, 2008.
- W.S. Chen, R.H. Huang, dan L. Hsieh, Iris Recognition Using 3D Co-occurrence Matrix, *Springer-Verlag, Berlin Heidelberg*, 2009 : 1122-1131.
- R.Y. Dillak, dan M.G. Bintiri, Klasifikasi Citra Diabetic Retinopathy Menggunakan Gray Level Coocurrence Matrix Tiga Dimensi (3D-GLCM), *Seminar Nasional Sains dan Teknik (SAINTEK)*, 2012.
- J.P. Bae, K.G. Kim, H.C. Kang, C.B. Jeong, K.H. Park, dan J.M. Hwang, A Study on Hemorrhage Detection Using Hybrid Method in Fundus Images, *Journal of Digital Imaging*, 2010.
- M. Garcia, C.I. Sanchez, J. Poza, M.I. Lopez, dan R. Hornero, Detection of Hard Exudates in Retinal Images Using a Radial Basis Function Classifier., *Journals of Biomedical Engineering*, 2009, No. 7, Vol. 37 : 1448-1463.
- A. Fahrudin, Deteksi Diabetic Retinopathy Pada Citra Retina Dengan Jaringan Syaraf Tiruan, Tesis, Program Pasca Sarjana Fakultas Teknik Universitas Gadjah Mada Yogyakarta, 2010.
- B. Nayak, P. Bhat, dan R. Acharya, Automated Identification of Diabetic Retinopathy Stages Using Digital Fundus Images, *J. Med. Syst*, 2008, 32 : 107-115.
- U.R. Acharya, E.Y.K. Ng, J.H. Tan, S.V. Sree, dan K.H. Ng, An Integrated Index for the Identification of Diabetic Retinopathy Using Texture Parameters, *Springer-Verlag, Germany*, 2011.
- S. Prabakar, K. Porkumaran, P.K. Shah, dan V. Narendran, A Novel Image Processing Approach for Retinopathy of Prematurity Stage Screening, *European Journal of Scientific Research*, 2011, No. 3, Vol. 55 : 334 – 347.
- M. Ulinuha, I. Purnama, dan M. Hariadi, Segmentasi Optic Disc pada Penderita Diabetic Retinopathy Menggunakan GVF Snake, 2010.
- D. Gadkari, Image Quality Analysis Using GLCM, Tesis, University of Central Florida, Florida, 2004.
- R. C. Gonzales, dan R.E. Woods, Digital Image Processing, 3<sup>rd</sup> ed., 2008, Prentice Hall : Upper Sadle River, New Jersey, USA.
- R.Y. Dillak, dan M.G. Bintiri, Identifikasi Fase Penyakit Retinopati Diabetes Menggunakan Jaringan Syaraf Tiruan Levenberg-Marquardt, *Seminar Nasional Informatika (SEMNASIF)*, 2012 : C-110-C-114.
- R.Y. Dillak, M.G. Bintiri, dan D.W. Pangestuty, Pemanfaatan Algoritma Jaringan Syaraf Tiruan Levenberg-Marquardt Untuk Mendeteksi Penyakit Alzheimer, *Seminar Nasional Informatika (SEMNASIF)*, 2012 : C-126-C-133.
- R. Priya, dan P. Aruna, Review of Automated Diagnosis Of Diabetic Retinopathy using The Support Vector Machine, *International Journal of Applied Engineering Research*, 2010, No. 4, Vol. 1 : 844-863.