

Klasifikasi Citra Glaukoma dengan ANN Berdasarkan Pembuluh Darah pada Citra Fundus Retina Menggunakan Perbandingan Metode Otsu-Thresholding dan Deteksi Tepi Canny

(Classification of Glaukoma Image with ANN Based on Blood Vessels on Retina Fundus Image Using Comparison of Otsu-Thresholding Method and Canny Edge Detection)

Teguh Ardian Samudra*, Gibran Satya Nugraha, Fitri Bimantoro

Prodi Teknik Informatika, Universitas Mataram

Jl. Majapahit 62, Mataram, Lombok NTB, INDONESIA

Email: teguhardi1309@gmail.com, [gibransn, bimo]@unram.ac.id

*Penulis Korespondensi

Abstract Glaucoma is an eye disease that can lead to permanent blindness caused by increased Intraocular Pressure (IOP). There are several methods to detect glaucoma, namely Optical Nerve Hypoplasia Stereo Photographs (ONHSPs), Optical Coherence Tomography (OCT), Scanning Laser Polarimetry (SLP), and Confocal Scanning Laser Ophthalmoscopy (CSLO). However, these methods require a lot of money and expert supervision. In this paper, glaucoma classification will be carried out using the ANN method with a comparison of the otsu-thresholding segmentation method and canny edge detection with the aim of knowing which method gives better results in diagnosing glaucoma images based on the parameters of accuracy, sensitivity, and specificity. The dataset used is RIM-ONE r2 and r3 which will be extracted using 5 features of GLCM and 6 statistical features, and obtained an accuracy of 76% for the otsu-thresholding method, and 79% for canny edge detection.

Key words: ANN, Otsu, Canny, Retinal Blood Vessels, Glaukoma.

I. PENDAHULUAN

Glaukoma merupakan salah satu penyakit mata pada manusia yang menyebabkan kebutaan pada rentang usia 40 hingga 80 tahun [1]. Organisasi Kesehatan Dunia telah menyatakan Glaukoma sebagai penyebab kebutaan terbesar kedua di dunia dan mencakup 15% dari kasus kebutaan di dunia [2]. Glaukoma disebabkan karena adanya peningkatan tekanan cairan yang disebut *Intraocular Pressure* (IOP) pada saraf optik [3].

Beberapa metode yang digunakan oleh dokter untuk mendeteksi glaukoma antara lain adalah *Optical Nerve Hypoplasia Stereo Photographs* (ONHSPs), *Optical Coherence Tomography* (OCT), *Scanning Laser Polarimetry* (SLP), dan *Confocal Scanning Laser Ophthalmoscopy* (CSLO) untuk menghasilkan gambar referensi mata dan struktur internal-nya. Namun, metode-

metode tersebut membutuhkan banyak biaya, pengawasan dari para ahli dan memakan waktu yang cukup lama [1] [4].

Untuk mengatasi masalah tersebut, telah banyak penelitian yang dilakukan dengan memanfaatkan teknik-teknik dalam bidang pengolahan citra dan *machine learning*, diantaranya adalah segmentasi pembuluh darah dan deteksi tepi [1]. Pembuluh darah pada retina dapat digunakan untuk mendiagnosis berbagai macam penyakit seperti diabetes, glaukoma, degenerasi makula, hipertensi, dan lain-lain, karena pada pembuluh darah memiliki banyak ciri-ciri alamiah seperti ketebalan, panjang, dan warna [5][6][7]. Dengan memanfaatkan ciri alamiah tersebut, pada penelitian ini akan dilakukan segmentasi pembuluh darah untuk mengambil ciri yang ada dan dilakukan klasifikasi untuk mendeteksi mata normal dan glaukoma. Beberapa metode yang dapat digunakan adalah deteksi tepi canny dan segmentasi *otsu-thresholding*. Deteksi tepi canny memastikan objek yang disegmentasikan terbebas dari *noise*, kelebihan lainnya adalah metode ini dapat mendeteksi bagian tepi dengan probabilitas kesalahan yang kecil [8]. Kemudian *Otsu-thresholding* adalah salah satu metode segmentasi yang memberikan nilai *error* yang kecil pada hasil segmentasinya. Selain itu, kelebihan metode ini adalah proses komputasi pada segmentasi-nya berlangsung cepat dan baik dalam mensegmentasikan objek yang besar dan tersebar merata [8][9]. Pada beberapa penelitian, kedua metode ini mendapatkan akurasi keberhasilan yang cukup tinggi dengan rata-rata akurasi di atas 90%.

Selanjutnya akan dilakukan ekstraksi fitur berbasis tekstur yang dimana fitur tersebut akan dijadikan masukan dalam proses klasifikasi citra fundus normal dan glaukoma. Beberapa ekstraksi fitur berbasis tekstur seperti *Gray Level Co-occurrence Matrices* (GLCM) dan statistik memberikan nilai akurasi di atas 95%. Lalu pada

penelitian ini, digunakan metode *Artificial Neural Network* (ANN) dengan algoritma *Multilayer Perceptron-Back Propagation* (MLP-BP) sebagai metode klasifikasi-nya yang pada beberapa penelitian memberikan akurasi yang cukup tinggi yaitu sebesar 97.60% [10].

Melihat pentingnya pembuluh darah dalam deteksi dini suatu penyakit dan pentingnya kualitas hasil segmentasi dalam proses klasifikasi, maka pada penelitian ini peneliti akan melakukan perbandingan antara deteksi tepi *canny* dan metode *otsu-thresholding* untuk mengetahui metode yang paling tepat digunakan untuk mendiagnosis glaukoma berdasarkan pembuluh darah dengan ekstraksi fitur tekstur menggunakan fitur gabungan statistik dan *Gray Level Co-occurrence Matrix* (GLCM) serta klasifikasi menggunakan ANN algoritma MLP-BP dengan *dataset* yang digunakan berupa RIM-ONE R2 dan RIM-ONE R3.

II. TINJAUAN PUSTAKA

Pada penelitian ini akan dilakukan perbandingan dari dua metode yaitu deteksi tepi *canny* dan *otsu-thresholding*. Beberapa contoh penelitian terkait seperti penelitian oleh Chin-Chen Chang dkk yang dalam penelitian-nya digunakan metode segmentasi berbasis *line operator* dan deteksi tepi menggunakan metode *canny* untuk mendeteksi pembuluh darah pada retina dan didapatkan akurasi rata-rata sebesar 94%. Namun pada penelitian ini hanya membahas proses segmentasi yang dilakukan dan tidak membahas ekstraksi fitur dan klasifikasi [5].

Kemudian penelitian yang dilakukan oleh Sunita Sarangi dkk yang pada penelitian ini dilakukan pendeteksian kelainan pembuluh darah pada retina dengan menggunakan detektor tepi *sobel* dan *canny*. Kemudian didapatkan kesimpulan bahwa operator *canny* lebih akurat dalam mendeteksi pembuluh darah dibandingkan dengan operator *sobel* dilihat dari tingkat kesalahan histogram yang lebih kecil yaitu sebesar 0.0015 pada operator *canny* dan sebesar 0.0142 pada operator *sobel*. Kekurangan dari penelitian ini adalah data yang digunakan hanya berupa sepuluh sampel *image* mata normal dan diabetes dan tidak membahas ekstraksi fitur dan klasifikasi [11].

Penelitian oleh Shouvik Chakraborty dkk yang membandingkan beberapa metode untuk segmentasi pembuluh darah. Pada penelitian ini diusulkan metode baru yang kemudian dibandingkan dengan metode-metode deteksi tepi yang sudah ada sebelumnya, salah satunya adalah deteksi tepi *canny* dan mendapatkan hasil akurasi sebesar 90%. Kekurangan dari penelitian ini hanya membahas metode segmentasi yang dimana hasil segmentasi-nya akan dibandingkan dengan versi *ground truth* serta data yang digunakan hanya berjumlah 40 buah citra fundus. Penelitian ini juga tidak membahas proses ekstraksi fitur dan klasifikasi [12].

Penelitian yang dilakukan oleh Jyotiprava Dash dkk dengan menerapkan metode *otsu-thresholding* untuk

mengeksktraksi pembuluh darah yang kemudian digunakan *morphological cleaning* untuk menghilangkan *noise* yang ada dan didapatkan akurasi rata-rata sebesar 95%. Metode *otsu* dipilih karena memiliki kinerja segmentasi yang baik dan penerapannya yang mudah, akan tetapi pada penelitian ini didapatkan sensitivitas yang rendah sebesar 72% untuk *DRIVE database* dan 73% untuk *STARE database* [7].

Penelitian oleh Owais Ali dkk yang melakukan perbandingan dari tiga algoritma segmentasi pembuluh darah yang baru-baru ini dikembangkan dalam hal akurasi, sensitivitas, dan spesifisitas. Algoritma yang dibandingkan dalam penelitian ini adalah metode segmentasi berbasis SUACE dan *tyler coye* terintegrasi, *frangi* filter dan metode segmentasi berbasis *otsu-thresholding*, dan pendekatan segmentasi pembuluh jaringan saraf konvolusional berbasis *unet*. Dari penelitian tersebut didapatkan kesimpulan bahwa algoritma segmentasi pembuluh darah berbasis *frangi* dan *otsu thresholding* menghasilkan akurasi tertinggi dengan akurasi rata-rata sebesar 94.17%. Kekurangan dari penelitian ini adalah rendahnya nilai sensitivitas yang didapatkan yaitu sebesar 46% untuk *DRIVE database* dan sebesar 49% untuk *STARE database*. Nilai dari sensitivitas yang rendah disebabkan karena sedikitnya *dataset* yang digunakan yaitu 40 *image* untuk *DRIVE dataset* dan 20 *image* untuk *STARE dataset* yang mengakibatkan nilai *false negative* yang tinggi [13].

Penelitian oleh Nur Rafidah Sabri dkk yang melakukan perbandingan terhadap tiga metode berbasis *thresholding* untuk mengidentifikasi *mikroaneurisma* (MAs) dan pembuluh darah, salah satunya *otsu thresholding*. Pada penelitian ini didapatkan akurasi rata-rata sebesar 92.18% untuk *database DRIVE*. Namun pada penelitian ini didapatkan nilai spesifisitas yang rendah, dengan nilai rata-rata sebesar 63%. Ini dikarenakan sedikitnya *dataset* yang digunakan, yaitu 20 sampel *image*. Penelitian ini juga tidak menjelaskan ekstraksi fitur dan klasifikasi yang digunakan [14].

Selanjutnya, ekstraksi fitur yang diusulkan pada penelitian ini adalah ekstraksi fitur GLCM dan statistik. Ekstraksi fitur tersebut sudah pernah dilakukan sebelumnya, seperti penelitian tentang segmentasi pembuluh darah pada retina untuk mendiagnosis penyakit *diabetic retinopathy* yang memadukan ekstraksi fitur GLCM dan *daubechies wavelet transform* sebagai ekstraksi fitur-nya, pada penelitian ini citra fundus retina diklasifikasikan sebagai citra fundus normal atau abnormal menggunakan ekstraksi fitur GLCM yang diperoleh menggunakan *daubechies wavelet transform* dan menunjukkan hasil yang lebih baik dari tiga metode lainnya dengan tingkat akurasi dan sensitivitas berturut-turut sebesar 97.76% dan 96.77% [15].

Kemudian pada penelitian untuk mendiagnosis penyakit glaukoma dengan menggunakan kombinasi ekstraksi fitur statistik dan *wavelet-based textural* yang dihitung dari *aproksimasi subband* hijau dan biru dari daerah *optic disc* untuk dilakukan karakterisasi pada *optic*

disc secara menyeluruh dan mempertimbangkan tujuh fitur statistik untuk klasifikasi glaukoma. Dari penelitian yang dilakukan didapatkan akurasi rata-rata sebesar 95% [16].

Untuk klasifikasi pada penelitian ini diusulkan dengan menggunakan metode ANN. Metode klasifikasi ini sudah sering digunakan, seperti pada penelitian dengan judul “*Automated Glaucoma Detection System based on Wavelet Energy features and ANN*” yang menggunakan ANN *backpropagation* sebagai metode klasifikasi-nya. Klasifikasi ANN pada penelitian tersebut menggunakan dua fase yaitu *forward phase* dan *backward phase* dan menghasilkan akurasi rata-rata sebesar 97.60% [10].

Kemudian penelitian oleh Endi Permata dkk yang melakukan penelitian tentang klasifikasi penyakit glaukoma menggunakan metode klasifikasi ANN. Dimana pada penelitian ini, citra fundus yang telah melalui tahap *pre-processing* akan dilakukan segmentasi *optic cup* dan *optic disk*, kemudian dilakukan ekstraksi ciri dari hasil segmentasi dan terakhir dilakukan klasifikasi menggunakan metode ANN dan dibagi menjadi tiga kategori yaitu glaukoma ringan, sedang dan parah dengan nilai rata-rata akurasi, sensitivitas, dan spesifisitas secara berurutan sebesar 94.2%, 99%, dan 98% [17].

Berdasarkan penelitian-penelitian yang telah dilakukan sebelumnya, dapat dilihat bahwa metode deteksi tepi *canny* dan segmentasi *otsu-thresholding* dapat bekerja dengan baik dan memberikan tingkat akurasi yang tinggi. Oleh karena itu pada penelitian ini dilakukan perbandingan kedua metode tersebut untuk mengetahui metode mana yang memberikan hasil lebih baik dalam diagnosis glaukoma berdasarkan pembuluh darah dengan metode klasifikasi ANN dilihat dari tingkat akurasi, sensitivitas, dan spesifisitas dengan *dataset* yang digunakan berupa RIM-ONE R2 dan RIM-ONE R3.

III. METODOLOGI PENELITIAN

A. Alat dan Bahan Penelitian

Alat dan bahan pada penelitian yang dilakukan berupa *software* dan *hardware* serta data-data yang dibutuhkan selama kegiatan

A1. Alat penelitian

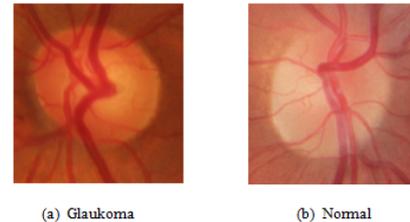
Alat-alat yang akan digunakan dalam melakukan penelitian ini adalah sebagai berikut:

- *Processor Laptop* : Intel(R) Core(TM) i3-2377M CPU @ 1.50GHz
- *Sistem Operasi* : Windows 10 64-bit.
- *Bahasa Pemrograman* : Python

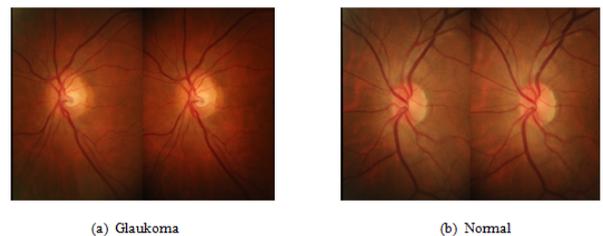
A2. Bahan Penelitian

Bahan yang digunakan pada penelitian ini merupakan *dataset* RIM-ONE r2 berupa 255 data citra fundus mata normal dan 200 data citra fundus mata diduga dan positif glaukoma dan *dataset* RIM-ONE r3 berupa 85 data citra fundus mata normal dan 74 data citra fundus mata diduga dan positif glaukoma [18], kedua *dataset* tersebut merupakan *dataset* citra fundus yang diambil dari berbagai rumah sakit di Spanyol [19]. Contoh citra fundus

retina dari RIM-ONE r2 dan RIM-ONE r3 dapat dilihat pada Gambar 1 dan Gambar 2. Citra fundus yang digunakan merupakan citra fundus retina yang telah melalui proses *cropping* secara manual dengan format .jpg dan resolusi sebesar 300 x 300 piksel untuk setiap *dataset*.



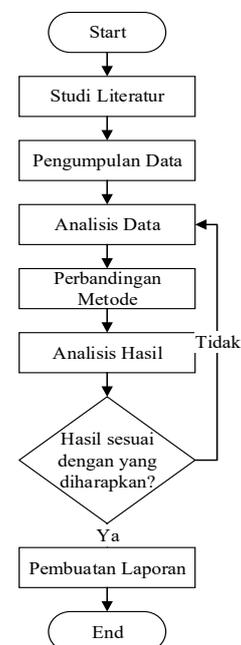
Gambar 1. Citra Fundus Retina RIM-ONE r2



Gambar 2. Citra Fundus Retina RIM-ONE r3

B. Proses Penelitian

Proses penelitian dilakukan untuk mengetahui tahapan-tahapan penelitian yang akan dilakukan, mulai dari studi literatur sampai dengan penyusunan laporan. Proses penelitian yang dilakukan pada penelitian ini digambarkan pada diagram alir pada Gambar 3.



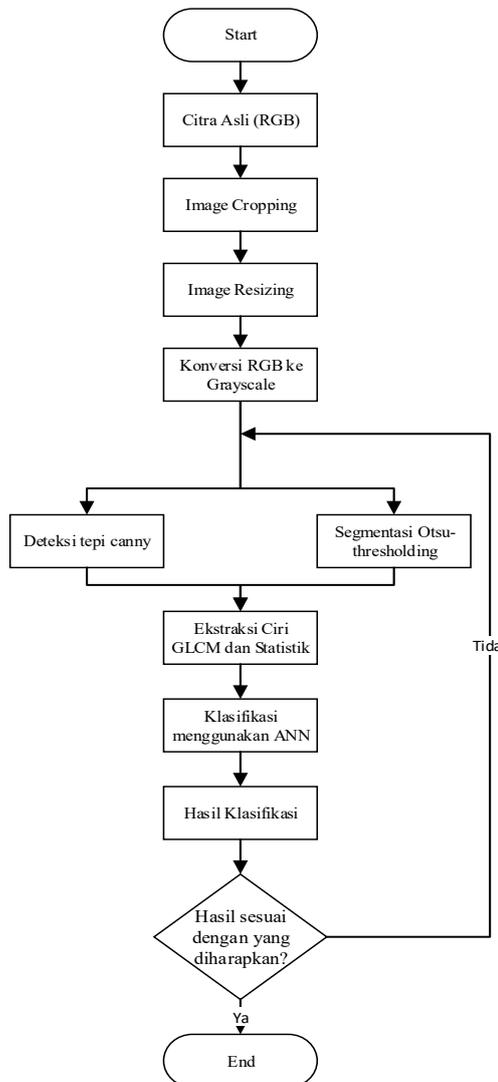
Gambar 3. Diagram Alir Proses Penelitian

Berdasarkan Gambar 3, ada beberapa tahap dalam proses penelitian ini, yaitu pertama melakukan studi literatur dimana pada tahap ini dilakukan dengan

mempelajari buku-buku, karya ilmiah, jurnal-jurnal penelitian sebelumnya, serta sumber lain yang berkaitan dengan penelitian yang dilakukan. Selanjutnya merupakan proses pengumpulan data, dimana data yang digunakan didapatkan dari *dataset* yang tersedia di internet. Kemudian tahap selanjutnya adalah menganalisis data yang telah dikumpulkan. Setelah itu dilakukan perbandingan metode antara metode *otsu-thresholding* dan deteksi tepi *canny*. Selanjutnya dilakukan analisis hasil dimana apabila hasil tidak sesuai maka akan kembali ke tahap analisis data. Selanjutnya jika sistem telah berjalan dengan baik maka akan dilanjutkan ke tahap terakhir yaitu pembuatan laporan dari awal pengumpulan data sampai akhir pembuatan sistem.

C. Perancangan Sistem

Pada perancangan sistem ini, dijelaskan bagaimana sistem dirancang mulai dari tahap pelatihan sistem hingga sistem dapat mengklasifikasi penyakit glaukoma. Proses perancangan sistem digambarkan pada Gambar 4.



Gambar 4. Diagram Perancangan Sistem

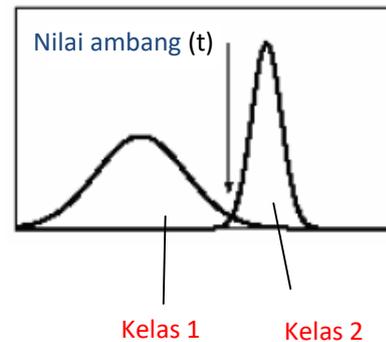
C1. Tahap Pre-processing

Untuk meningkatkan kualitas citra fundus masukan, pada tahap *pre-processing* ini dilakukan proses *cropping*, *resizing*, dan konversi warna. Proses *cropping* bertujuan untuk mengambil bagian citra fundus yang dibutuhkan dan membuang bagian citra fundus yang tidak dibutuhkan. Selanjutnya dilakukan *resizing* citra menjadi ukuran 300x300 piksel, ini dimaksudkan agar memberikan *dataset* yang seragam dan memudahkan pelatihan sistem. Proses *resizing* dan *cropping* dilakukan di luar sistem. Setelah melewati proses *resize*, dilakukan konversi citra RGB menjadi *grayscale*.

C2. Segmentasi

1. Otsu-Thresholding

Metode ini merupakan metode yang dikemukakan oleh Nobuyuki Otsu pada tahun 1979, yang menentukan nilai ambang dengan cara membedakan dua kelompok yaitu objek dengan latar belakang, yang memiliki bagian saling bertumpukan berdasarkan histogram seperti pada Gambar 5 [20].



Gambar 5. Penentuan Nilai Ambang

Prinsip metode *otsu* adalah sebagai berikut. Pertama-tama, probabilitas nilai intensitas *i* dalam histogram dihitung menggunakan Persamaan 1.

$$p(i) = \frac{n_i}{N}, p(i) \geq 0, \sum_1^{256} p(i) = 1 \tag{1}$$

Dengan *n_i* adalah jumlah piksel dengan intensitas *i* dan *N* adalah jumlah total piksel pada citra. Jika histogram dibagi menjadi objek dan latar belakang, maka pemberian bobot pada kedua kelas dinyatakan dengan Persamaan 2 dan 3.

$$w_1(t) = \sum_{i=1}^t p(i) \tag{2}$$

$$w_2(t) = \sum_{i=t+1}^L p(i) = 1 - w_1(t) \tag{3}$$

Dalam hal ini, *L* adalah jumlah aras ke abuan. Rata-rata kedua kelas dapat dihitung dengan menggunakan Persamaan 4 dan 5.

$$m_1(t) = \sum_{i=1}^t i \cdot p(i) / W_1(t) \quad (4)$$

$$m_2(t) = \sum_{i=1}^t i \cdot p(i) / W_2(t) \quad (5)$$

Varian kedua kelas dinyatakan dengan Persamaan 6 dan 7.

$$\sigma_1^2(t) = \sum_{i=1}^t (1 - m_1)^2 \cdot \frac{p(i)}{W_1(t)} \quad (6)$$

$$\sigma_2^2(t) = \sum_{i=t+1}^L (1 - m_2)^2 \cdot \frac{p(i)}{W_2(t)} \quad (7)$$

Varian total dapat dinyatakan dengan menggunakan Persamaan 8.

$$\sigma^2(t) = \sigma_W^2(t) + \sigma_B^2(t) \quad (8)$$

Dalam hal ini, σ_W^2 dinamakan sebagai *within-class variance* (WCV) dan σ_B^2 disebut dengan *between-class variance* (BCV). WVC dapat dinyatakan dengan menggunakan Persamaan 9.

$$\sigma_W^2(t) = W_1(t) \cdot \sigma_1(t)^2 + W_2(t) \cdot \sigma_2(t)^2 \quad (9)$$

Rumus di atas menunjukkan bahwa WCV adalah jumlah varian kelas secara individual yang telah diberi bobot dengan probabilitas kelas masing-masing. Adapun BCV dinyatakan dengan menggunakan Persamaan 10.

$$\sigma_B^2(t) = W_1 \cdot [m_1(t) - m_T]^2 + W_2 \cdot [m_2(t) - m_T]^2 \quad (10)$$

Dalam hal ini, m_T adalah rerata total yang dapat dihitung menggunakan Persamaan 11.

$$m_T = \sum_{i=1}^N i \cdot p(i) \quad (11)$$

Nilai ambang optimum dapat diperoleh dengan cara meminimalkan WCV atau dengan memaksimalkan BCV [26].

a) *Deteksi Tepi Canny*

Deteksi tepi pada citra digital berfungsi untuk memperoleh tepian objek yang memanfaatkan perubahan nilai intensitas yang drastis pada batas dua area. Deteksi ini memiliki beberapa langkah dalam implementasi-nya, seperti yang telah dijabarkan sebagai berikut [20]:

Pertama, dilakukan proses penghalusan citra (smoothing) menggunakan Gaussian Filter, dengan menggunakan Persamaan 12.

$$G(i, j) = \frac{1}{2\pi\sigma^2} \cdot e^{-\frac{(i-u)^2 + (j-v)^2}{2\sigma^2}} \quad (12)$$

di mana:

e = 2.71 (konstanta euler)

σ = standar deviasi (sigma)

π = 3.14 (pi)

Kemudian dilakukan proses untuk mendapatkan kekuatan tepi, selanjutnya gradien citra dapat dihitung menggunakan Persamaan 13.

$$|G| = |Gx| + |Gy| \quad (13)$$

Langkah selanjutnya adalah perhitungan arah tepi dengan menggunakan Persamaan 14.

$$theta = \tan^{-1}(Gy, Gx) \quad (14)$$

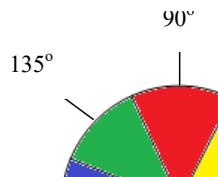
Kemudian setelah arah tepi diperoleh, perlu menghubungkan antara arah tepi dengan sebuah arah yang dapat dilacak dari citra. Sebagai contoh, terdapat susunan piksel berukuran 5x5 seperti pada Gambar 6. Dengan melihat piksel "a" tampak a memiliki 4 arah yaitu, 0°, 45°, 90°, dan 135°.

X	X	X	X	X
X	X	X	X	X
X	X	a	X	X
X	X	X	X	X
X	X	X	X	X

Gambar 6. Contoh Matriks Piksel Berukuran 5x5

Selanjutnya, arah tepi yang diperoleh dikelompokkan ke dalam salah satu dari keempat arah tersebut berdasarkan area yang tertera pada Gambar 7. Konversi yang berlaku dapat dilihat pada Persamaan 15.

$$arah = \begin{cases} 0 & y_i^{(H)} = f^{(H)} \left(\sum_j w_{ij}^{(H)} x_j \right) \\ 45 & \\ 90 & y_i = f^{(T)} \left(\sum_j w_{ij}^{(TH)} y_j^{(H)} \right) \\ 135 & \end{cases} \quad (15)$$



Gambar 7. Area untuk Mengonversi Arah Tepi

Semua arah tepi yang berada di kisaran 0° dan 22.5° serta 157.5° dan 180° (berwarna biru) diubah menjadi 0°. Semua arah tepi yang berada di kisaran 22.5° dan 67.5° (berwarna kuning) diubah menjadi 45°. Semua arah tepi yang berada di kisaran 67.5° dan 112.5° (berwarna merah) diubah menjadi 90°. Semua arah tepi yang berada di kisaran 112.5° dan 157.5° (berwarna hijau) diubah menjadi 135°.

Setelah memperoleh nilai tepi, dilakukan penghilangan non-maksimum. Penghilangan non-maksimum dilakukan sepanjang tepi pada arah tepi dan menghilangkan piksel-

piksel (mengatur piksel sebagai 0) yang tidak dianggap sebagai tepi sehingga diperoleh tepi yang tipis.

Terakhir adalah proses yang disebut hysteresis. Pada proses ini, garis yang terlihat putus-putus pada tepi objek dihilangkan dengan menggunakan dua ambang T1 dan T2. Semua piksel citra yang memiliki nilai lebih kecil dari T1 akan diubah menjadi hitam (nilai 0). Selanjutnya semua piksel yang terhubung dengan piksel tersebut yang bernilai lebih besar dari T2 akan diubah menjadi putih (nilai 255).

C2. Ekstraksi Fitur

Ekstraksi fitur digunakan untuk memperoleh ciri dari suatu citra, dimana dalam penelitian ini digunakan ekstraksi fitur GLCM dan fitur berbasis histogram, yang kemudian hasil dari ekstraksi fitur ini akan digunakan sebagai masukan pada tahap klasifikasi. Adapun fitur-fitur tersebut meliputi 5 fitur GLCM yaitu *angular second moment, contrast, inverse different moment, entropy*, dan *correlation*. Dan 6 fitur statistik histogram yaitu rerata intensitas, deviasi standar, *skewness*, energi, entropi, dan kehalusan.

C3. Klasifikasi

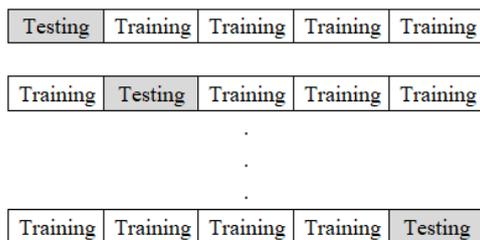
Pada tahap ini, dibuat sebuah model ANN yang kemudian akan dilakukan *training* dan *testing* dengan menggunakan *dataset* yang telah diekstrak pada tahap sebelumnya. Dimana hasil ekstraksi fitur yang didapatkan pada langkah sebelumnya akan digunakan sebagai *input* pada tahap klasifikasi.

C4. Pengujian Performa Klasifikasi

Pada tahap ini digunakan dua metode yaitu *k-fold cross validation* dan *shuffle sampling*.

a) K-fold Cross Validation

Metode ini membagi data menjadi dua bagian, yaitu data pelatihan dan data pengujian. Selanjutnya, sebuah subset data akan dijadikan data uji dan subset data lainnya akan dijadikan sebagai data latih, kemudian dilakukan proses silang dimana salah satu subset data pengujian sebelumnya akan dijadikan sebagai data pelatihan dan subset data pelatihan sebelumnya akan dijadikan sebagai data pengujian. Proses ini akan terus berlangsung hingga sebuah subset data akan menjadi data pelatihan masing-masing sebanyak satu kali dan proses akan diulangi sebanyak k, seperti pada Gambar 8 [21].



Gambar 8. Contoh K-fold Cross Validation dengan k=5

b) Shuffle Sampling

Metode pembagian data ini merupakan pengujian citra yang dilakukan dengan membagi data menjadi dua bagian,

yaitu data latih dan data uji. Pada skenario ini dilakukan pembagian data uji dan data latih dengan perbandingan 70:30, 80:20, dan 90:10 yang ditentukan secara acak [22].

C5. Evaluasi Performa Klasifikasi

Untuk mengetahui seberapa handal suatu *classifier* dalam mengenali objek-objek dalam kelas yang berbeda, digunakan matriks konfusi berbentuk tabel dengan ukuran *m* baris dan *m* kolom. Matriks konfusi untuk dua kelas dapat dilihat pada Tabel I [21].

TABEL I. TABEL KONFUSI

		Predicted class	
		C ₁	C ₂
Actual class	C ₁	True positive (TP)	False negative (FN)
	C ₂	False positive (FP)	True negative (TN)

Di mana C1 adalah kelas *positive* dan C2 adalah kelas *negative*. Pada tabel di atas terdapat empat kemungkinan yaitu, *true positive* (TP) adalah banyaknya hasil klasifikasi benar pada suatu kelas bernilai *positive* (glaukoma), *false positive* (FP) adalah banyaknya hasil klasifikasi salah pada suatu kelas bernilai *positive* (glaukoma), *false negative* (FN) adalah banyaknya hasil klasifikasi salah pada suatu kelas bernilai *negative* (normal), dan *true negative* (TN) adalah banyaknya hasil klasifikasi benar pada suatu kelas bernilai *negative* (normal) [21].

Pengukuran evaluasi performa klasifikasi terdiri dari akurasi, sensitivitas, dan spesifisitas. Akurasi merupakan presentasi kesuksesan dari sebuah klasifikasi yang dapat dihitung menggunakan Persamaan 16. Sensitivitas merupakan presentasi *classifier* dalam memprediksi kelas *positive* yang dapat dihitung dengan menggunakan Persamaan 17. Spesifisitas merupakan presentasi *classifier* dalam memprediksi kelas *negative* yang dapat dihitung menggunakan Persamaan 18 [3][21].

$$Akurasi = (TP + TN) / TP + TN + FP + FN \quad (16)$$

$$Sensitivitas = TP / (TP + FN) \quad (17)$$

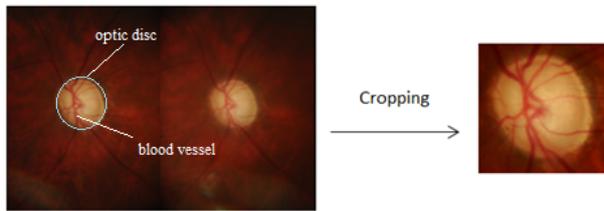
$$Spesifisitas = TN / (TN + FP) \quad (18)$$

IV. HASIL DAN PEMBAHASAN

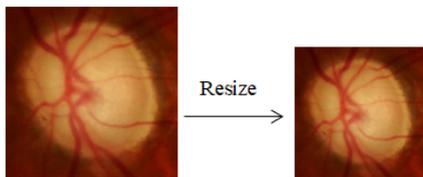
A. Tahap Pre-processing

Tahap awal yang dilakukan pada penelitian ini adalah tahap *cropping* citra. Pada tahap ini dilakukan *cropping* di luar sistem secara manual untuk mengambil bagian citra yang dibutuhkan. Dimana pada penelitian ini dilakukan *cropping* pada bagian *optic disc* dari citra fundus retina. Contoh hasil *cropping* citra dapat dilihat pada Gambar 9.

Setelah melewati proses *cropping* secara manual, citra fundus hasil *cropping* akan di-*resize* menjadi ukuran 300x300 piksel, ini dimaksudkan agar memberikan *dataset* yang seragam dan memudahkan pelatihan sistem. Contoh hasil *resize* dapat dilihat seperti pada Gambar 10.

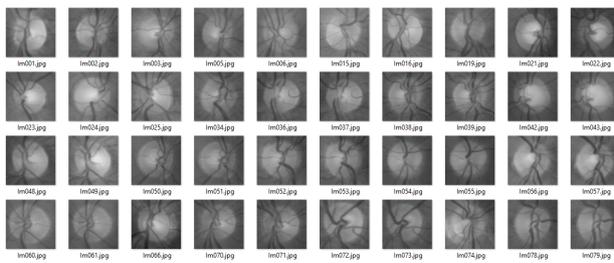


Gambar 9. Hasil *Cropping* Citra



Gambar 10. Citra Hasil *Resizing*

Kemudian setelah melakukan *resize* citra, dilakukan konversi citra RGB menjadi *grayscale* untuk memudahkan pada tahap selanjutnya. Contoh hasil konversi citra RGB menjadi *grayscale* dapat dilihat pada Gambar 11.



Gambar 11. Hasil Konversi Citra RGB ke *Grayscale*

B. Segmentasi

Setelah mengubah citra menjadi *grayscale*, selanjutnya dilakukan proses segmentasi *otsu-thresholding* dan deteksi tepi *canny*. Segmentasi *otsu* dilakukan untuk memisahkan pembuluh darah dengan latar belakang dan didapatkan hasil seperti pada Gambar 12, dan deteksi tepi *canny* digunakan untuk mendapatkan tepi dari pembuluh darah pada citra fundus sehingga didapatkan hasil seperti pada Gambar 13.



Gambar 12. Hasil Segmentasi *Otsu-thresholding*



Gambar 13. Hasil Deteksi Tepi *Canny*

Setelah dilakukan proses segmentasi dan deteksi tepi, citra hasil akan diubah menjadi *grayscale* agar dapat diproses pada tahap ekstraksi fitur menggunakan metode GLCM dan histogram. Hasil citra *grayscale* dapat dilihat pada Gambar 14 dan Gambar 15



Gambar 14. Konversi Hasil *Otsu-thresholding* ke *Grayscale*



Gambar 15. Konversi Hasil *Canny* ke *Grayscale*

C. Ekstraksi Fitur

Ekstraksi fitur digunakan untuk memperoleh ciri dari suatu citra, dimana dalam penelitian ini digunakan ekstraksi fitur GLCM dan fitur berbasis histogram, yang kemudian hasil dari ekstraksi fitur ini akan digunakan sebagai masukan pada tahap klasifikasi. Adapun fitur-fitur GLCM meliputi 5 fitur yaitu *angular second moment*, *contrast*, *inverse different moment*, *entropy*, dan *correlation*. Pada metode ini terdapat 4 matriks dengan orientasi sudut 0° , 45° , 90° , dan 135° . Dari keempat sudut tersebut akan diekstraksi ke-5 fitur sehingga didapatkan total 20 fitur.

Selanjutnya untuk fitur statistik berbasis histogram dilakukan perhitungan terhadap 6 fitur yaitu rerata intensitas, deviasi standar, *skewness*, energi, entropi, dan kehalusan. Setelah dilakukan perhitungan terhadap ke-26 fitur tersebut, selanjutnya fitur-fitur dari hasil proses ini kemudian digabungkan dan disimpan dalam file .csv untuk kemudian menjadi data masukan dalam proses klasifikasi menggunakan metode ANN.

D. Klasifikasi

Pada tahap ini, dibuat sebuah model ANN yang kemudian akan dilakukan *training* dan *testing* dengan menggunakan *dataset* yang telah diekstrak pada tahap sebelumnya. Dimana ke-26 hasil ekstraksi fitur yang didapatkan pada langkah sebelumnya akan digunakan sebagai *input* pada tahap ini.

Arsitektur yang digunakan pada penelitian ini adalah *multilayer* yang terdiri dari 1 *input layer*, 3 *hidden layer* dan 1 *output layer*. Pada model tersebut terdapat 26 neuron pada *input layer*, kemudian terdapat 256 neuron pada *hidden layer* pertama, 1024 neuron pada *hidden layer* kedua, dan 128 neuron pada *hidden layer* ketiga, dan terakhir terdapat 1 neuron pada *output layer*.

E. Analisis Skenario Pengujian

1) Skenario 1

Segmentasi menggunakan *otsu-thresholding* dan deteksi tepi *canny*, kemudian dilakukan perhitungan berdasarkan parameter akurasi, sensitivitas, dan spesifisitas. Pada tahap ini, terdapat beberapa *dataset* yang tidak dapat dideteksi oleh metode *canny* (memiliki nilai 0 pada file csv), dengan jumlah *dataset* pada R2 sebanyak 5 citra normal, 27 citra glaukoma dan pada R3 sebanyak 1 citra normal dan 6 citra glaukoma, sehingga dilakukan pengurangan pada *dataset*. Adapun hasilnya dapat dilihat pada Tabel II dan Tabel III.

Dan dari pengujian ini, didapatkan akurasi tertinggi pada *otsu* sebesar 66% dengan nilai sensitivitas dan spesifisitas berurutan sebesar 58% dan 72% pada gabungan *dataset* R2 dan R3 dengan nilai $k=5$. Sedangkan pada deteksi tepi *canny* didapatkan akurasi tertinggi sebesar 62% dengan nilai sensitivitas dan spesifisitas berurutan sebesar 53% dan 68% pada *dataset* R2 dengan rasio perbandingan *dataset* sebesar 70:30 dengan hasil seperti pada tabel II dan tabel III.

2) Skenario 2

Berdasarkan pengujian pada skenario 1, dikarenakan terdapat beberapa citra fundus yang tidak dapat terdeteksi, maka tahap selanjutnya dilakukan pengujian untuk mengecek *dataset* yang terdeteksi berkurang atau bertambah jumlahnya dengan menambahkan satu tahapan *pre-processing* yaitu konversi RGB ke *grayscale* menggunakan *green channel*, dan metode perbaikan kontras yang terdiri dari *Contrast Limited Adaptive Histogram Equalization* (CLAHE), *Histogram Equalization* (HE), dan *Contrast Stretching* (CS). Setelah itu dilakukan perhitungan berdasarkan parameter akurasi, sensitivitas, dan spesifisitas. Adapun hasilnya adalah seperti Tabel IV.

Jika dilihat dari segi visual, citra yang melalui *pre-processing* dengan konversi RGB ke *grayscale* cenderung menghasilkan citra yang lebih gelap dibandingkan dengan metode lainnya, dan citra dengan perbaikan kontras menggunakan metode *Histogram Equalization* memiliki tingkat kecerahan paling tinggi dibandingkan dengan metode lain. Perbandingan kontras pada citra juga

berpengaruh terhadap hasil dari segmentasi dan deteksi tepi yang dilakukan. Hasil dari skenario 2 dapat dilihat pada Tabel V.

TABEL II. HASIL UJI OTSU SKENARIO 1

Pengujian performa klasifikasi	Dataset					
	R2+R3 (N:340, G:274)					
	Acc	Sen	Spe	Acc	Sen	Spe
K:10	65%	60%	70%			
K:5	66%	58%	72%			
70:30	64%	58%	68%			
80:20	63%	59%	67%			
90:10	64%	56%	69%			
	Dataset					
	R2 (N:255, G:200)			R3 (N:85, G:74)		
	Acc	Sen	Spe	Acc	Sen	Spe
K:10	65%	61%	68%	55%	52%	59%
K:5	64%	58%	68%	58%	54%	62%
70:30	63%	58%	67%	58%	55%	62%
80:20	64%	57%	70%	61%	58%	63%
90:10	63%	64%	63%	59%	62%	58%

TABEL III. HASIL UJI CANNY SKENARIO 1

Pengujian performa klasifikasi	Dataset					
	R2+R3 (N:334, G:241)					
	Acc	Sen	Spe	Acc	Sen	Spe
K:10	60%	53%	65%			
K:5	60%	52%	66%			
70:30	60%	49%	68%			
80:20	60%	51%	67%			
90:10	55%	49%	60%			
	Dataset					
	R2 (N:250, G:173)			R3 (N:84, G:68)		
	Acc	Sen	Spe	Acc	Sen	Spe
K:10	61%	54%	66%	46%	43%	52%
K:5	60%	46%	70%	49%	49%	52%
70:30	62%	53%	68%	50%	50%	50%
80:20	59%	50%	66%	54%	52%	56%
90:10	60%	53%	66%	53%	54%	53%

TABEL IV. PERBANDINGAN HASIL PREPROCESSING

Citra asli					
Pre processing		Green Channel	CLAHE	Histogram Equalization	Contrast Stretching
					
Hasil	Otsu				
	Canny				

TABEL V. PERBANDINGAN AKURASI SEBELUM DAN SESUDAH PRE-PROCESSING

	Normal	glaukoma	Akurasi tertinggi	
			Otsu	Canny
Sebelum pre-processing	6	33	66%	62%
RGB to green channel	4	24	66%	63%
CLAHE	1	11	67%	63%
Histogram Equalization	0	2	66%	69%
Contrast Stretching	4	22	63%	62%

Berdasarkan hasil pengujian skenario 2, didapatkan kesimpulan bahwa hasil paling baik didapatkan ketika dilakukan perbaikan kontras dengan metode *Histogram Equalization* (HE). Dengan metode ini, hasil citra tidak terdeteksi mengalami pengurangan jumlah, dari total 39 citra fundus menjadi 2 citra fundus retina, dan mengalami peningkatan akurasi dibandingkan dengan skenario 1 dengan akurasi tertinggi sebesar 66% untuk *otsu-thresholding* dan 69% untuk deteksi tepi canny.

3) Skenario 3

Berdasarkan percobaan pada skenario 2, pada tahap ini digunakan *dataset* yang telah dilakukan perbaikan kontras dengan metode *Histogram Equalization* (HE). dan dilakukan penyeimbangan *dataset* agar jumlah citra fundus normal dan glaukoma seimbang dengan menambahkan *dataset* menggunakan metode augmentasi pada *dataset* gabungan R2+R3. Pada tahap ini dilakukan beberapa percobaan dengan penambahan *dataset* dengan jumlah *dataset* yaitu pertama dengan jumlah total N=340, dan G=340, kedua dengan jumlah total N=370, dan G=370, ketiga dengan jumlah total N=400, dan G=400.

Berdasarkan percobaan pada skenario 3, didapatkan hasil bahwa penambahan *dataset* dilakukan berpengaruh terhadap nilai akurasi, sensitivitas, dan spesifisitas dimana pada percobaan ini, nilai akurasi mengalami kenaikan seiring dengan bertambahnya *dataset* yang digunakan, dan didapatkan akurasi paling tinggi pada jumlah *dataset* 400 citra normal dan 400 citra glaukoma yaitu dengan tingkat akurasi sebesar 76% untuk metode *otsu-thresholding* dan sebesar 79% untuk deteksi tepi canny. Adapun hasilnya dapat dilihat pada Tabel VI.

TABEL VI. HASIL AKURASI SKENARIO 3

	Dataset R2+R3 (N:400, G:400)					
	<i>Otsu-thresholding</i>			Canny		
	Acc	Sen	Spe	Acc	Sen	Spe
K:10	76%	80%	73%	79%	83%	75%
K:5	75%	76%	74%	79%	83%	76%
70:30	72%	73%	71%	71%	74%	69%
80:20	73%	74%	72%	75%	78%	71%
90:10	76%	76%	76%	76%	83%	70%

V. KESIMPULAN DAN SARAN

A. Kesimpulan

Dari penelitian yang telah dilakukan, dapat disimpulkan bahwa akurasi yang didapatkan dengan menggunakan metode deteksi tepi canny lebih tinggi

dibandingkan dengan metode *otsu-thresholding*, dan banyaknya *dataset* yang digunakan berpengaruh pada tingkat akurasi yang didapatkan. Dimana akurasi tertinggi pada deteksi tepi canny didapatkan pada nilai k=5 dengan tingkat akurasi, sensitivitas, dan spesifisitas berurutan sebesar 79%, 83%, dan 76%, kemudian pada nilai k=10 dengan tingkat akurasi, sensitivitas, dan spesifisitas berurutan sebesar 79%, 83%, dan 75%. Sedangkan pada segmentasi *otsu*, akurasi tertinggi didapatkan pada nilai k=10 dengan tingkat akurasi, sensitivitas, dan spesifisitas berurutan sebesar 76%, 80%, dan 73%, kemudian pada perbandingan *dataset* 90:10 dengan tingkat akurasi, sensitivitas, dan spesifisitas yang sama yaitu sebesar 76%.

Akurasi yang dihasilkan pada penelitian ini relatif rendah dibandingkan dengan kinerja ANN pada umumnya, ini dikarenakan hasil dari proses *pre-processing* yang kurang optimal, sehingga dibutuhkan penelitian lebih lanjut dan penambahan metode pada tahap *pre-processing* sehingga pendeteksian pembuluh darah lebih optimal. Kontras yang beragam antara citra hasil juga berpengaruh terhadap akurasi yang didapatkan.

Metode *otsu-thresholding* lebih baik dalam mengsegmentasikan objek yang besar seperti pembuluh darah pada citra dilihat dari hasil segmentasi yang menunjukkan bahwa *otsu-thresholding* dapat melakukan segmentasi pada semua citra masukan, sedangkan pada metode deteksi tepi canny dibutuhkan penambahan tahap *pre-processing* untuk membantu dalam deteksi tepi pembuluh darah pada citra fundus retina. Penambahan tahap *pre-processing* berupa perbaikan kontras juga berpengaruh terhadap tingkat akurasi, sensitivitas dan spesifisitas yang dihasilkan.

B. Saran

Dari penelitian yang sudah dilakukan terdapat beberapa saran pada penelitian selanjutnya, antara lain: melakukan *cropping* dan *resizing* dalam sistem, penghilangan *background/area* luar *optic disc* secara otomatis, mengkombinasikan metode di atas dengan menggunakan metode lain untuk meningkatkan keberhasilan pendeteksian pembuluh darah dan menambah jumlah dan sumber *dataset* yang digunakan.

DAFTAR PUSTAKA

- [1] K. Thakkar, K. Chauhan, A. Sudhalkar, R. Gulati, and M. S. Ophthalmologist, "Detection of Glaucoma from Retinal Fundus Images by analysing ISNT Measurement and features of Optic Cup and Blood Vessels," *Int. J. Eng. Technol. Sci. Res. IJETS* www.ijetsr.com ISSN, vol. 4, no. 7, pp. 2394–3386, 2017.
- [2] A. A. Salam, T. Khalil, M. U. Akram, A. Jameel, and I. Basit, "Automated detection of glaucoma using structural and non structural features," *Springerplus*, vol. 5, no. 1, 2016.
- [3] E. Deepika and S. Maheswari, "Earlier glaucoma detection using blood vessel segmentation and classification," *Proc. 2nd Int. Conf. Inven. Syst. Control. ICISC 2018*, no. Icisc, pp. 484–490, 2018.

- [4] S. Maheshwari, R. B. Pachori, and U. R. Acharya, "Automated Diagnosis of Glaucoma Using Empirical Wavelet Transform and Correntropy Features Extracted from Fundus Images," *IEEE J. Biomed. Heal. Informatics*, vol. 21, no. 3, pp. 803–813, May 2017.
- [5] C. C. Chang, C. C. Lin, P. Y. Pai, and Y. C. Chen, "A novel retinal blood vessel segmentation method based on line operator and edge detector," *IIH-MSP 2009 - 2009 5th Int. Conf. Intell. Inf. Hiding Multimed. Signal Process.*, pp. 299–302, 2009.
- [6] K. BahadarKhan, A. A. Khaliq, and M. Shahid, "A Morphological Hessian Based Approach for Retinal Blood Vessels Segmentation and Denoising Using Region Based Otsu Thresholding," *PLoS One*, vol. 11, no. 9, pp. 1–19, 2016.
- [7] J. Dash and N. Bhoi, "Retinal Blood Vessel Segmentation Using Otsu Thresholding With Principal Component Analysis," *Proc. 2nd Int. Conf. Inven. Syst. Control. ICISC 2018*, no. Icisc, pp. 933–937, 2018.
- [8] Ali Abdo Mohammed Al-Kubati, J. A. M. Saif, A. Taher, and M. A., "Evaluation of Canny and Otsu Image Segmentation," *Int. Conf. Emerg. Trends Comput. Electron. Eng.*, pp. 23–25, 2012, [Online]. Available: <http://psrcentre.org/images/extraimages/312651.pdf>.
- [9] W. X. Kang, Q. Q. Yang, and R. P. Liang, "The Comparative Research on Image Segmentation Algorithms," *Proc. 1st Int. Work. Educ. Technol. Comput. Sci. ETCS 2009*, vol. 2, pp. 703–707, 2009.
- [10] R. Gayathri, P. V. Rao, and S. Aruna, "Automated glaucoma detection system based on wavelet energy features and ANN," *Proc. 2014 Int. Conf. Adv. Comput. Commun. Informatics, ICACCI 2014*, pp. 2808–2812, 2014.
- [11] S. Sarangi, A. Mohapatra, and S. K. Sabut, "A Comparative Evaluation of Diabetic Retinal Vascular Structures Using Edge Detection Techniques," *Int. J. Telemed. Clin. Pract.*, vol. 1, no. 1, p. 111, 2015.
- [12] S. Chakraborty, S. Chatterjee, N. Dey, A. S. Ashour, and F. Shi, "Gradient approximation in retinal blood vessel segmentation," *2017 4th IEEE Uttar Pradesh Sect. Int. Conf. Electr. Comput. Electron. UPCON 2017*, pp. 618–623, 2017.
- [13] O. Ali, N. Muhammad, Z. Jadoon, B. M. Kazmi, N. Muzamil, and Z. Mahmood, "A Comparative Study of Automatic Vessel Segmentation Algorithms," *2020 3rd Int. Conf. Comput. Math. Eng. Technol. Idea to Innov. Build. Knowl. Econ. iCoMET 2020*, pp. 1–6, 2020.
- [14] N. R. Sabri, H. Yazid, and S. A. Rahim, "Performance comparison using thresholding based method for diabetic retinopathy," *ISCAIE 2019 - 2019 IEEE Symp. Comput. Appl. Ind. Electron.*, pp. 228–233, 2019.
- [15] C. Nivetha, S. Sumathi, and M. Chandrasekaran, "Retinal Blood Vessels Extraction and Detection of Exudates Using Wavelet Transform and PNN Approach for the Assessment of Diabetic Retinopathy," *Proc. 2017 IEEE Int. Conf. Commun. Signal Process. ICCSP 2017*, pp. 1962–1966, 2018.
- [16] L. Abdel-Hamid, "Glaucoma Detection from Retinal Images Using Statistical and Textural Wavelet Features," *J. Digit. Imaging*, vol. 33, no. 1, pp. 151–158, 2020.
- [17] E. Permata, R. Munarto, and G. A. Indra, "Klasifikasi Glaukoma Menggunakan Neural Network Backpropagation," in *Prosiding SENTIA 2016*, 2016, vol. 8, pp. 158–163.
- [18] C. Pena-Betancor *et al.*, "Estimation of the relative amount of hemoglobin in the cup and neuroretinal rim using stereoscopic color fundus images," *Investig. Ophthalmol. Vis. Sci.*, vol. 56, no. 3, pp. 1562–1568, 2015.
- [19] F. Fumero, T. DIAZ-ALEMA, J. Sigu, S. Alayo, R. Arna, and D. Angel-Pereir, "Rim-One DL: A Unified Retinal Image Database for Assessing Glaucoma Using Deep Learning," *Image Anal. Stereol.*, vol. 39, no. 3, pp. 161–167, 2020.
- [20] A. Kadir and A. Susanto, *Teori dan Aplikasi Pengolahan Citra*. 2013.
- [21] G. S. Nugraha, I. Soesanti, and S. Wibirama, "Deteksi Glaukoma Berdasarkan Kesamaan Ciri Tekstur Optic Cup dan Optic Disc pada Citra Fundus Retina," Universitas Gadjah Mada, 2017.
- [22] A. Bisri and R. Rachmatika, "Integrasi Gradient Boosted Trees dengan SMOTE dan Bagging untuk Deteksi Kelulusan Mahasiswa," *J. Nas. Tek. Elektro dan Teknol. Inf.*, vol. 8, no. 4, p. 309, 2019.