

Klasifikasi Glaukoma Menggunakan *Artificial Neural Network*

Alva Rischa Qhithana Pratika¹, Rita Magdalena², R Yunendah Nur Fuadah³

^{1,2,3}Fakultas Teknik Elektro, Universitas Telkom

Jl. Telekomunikasi Jl. Terusan Buah Batu, Sukapura, Kec. Dayeuhkolot, Bandung, Jawa Barat 40257

E-mail : alvarischa@student.telkomuniversity.co.id¹, ritamagdalenat@telkomuniversity.ac.id²,
yunendah@telkomuniversity.ac.id³.

Abstract

Glaucoma is an eye disease caused by increased eyeball pressure resulting in damage to the optic nerve and the second leading cause of blindness after cataracts. Nerve damage often occurs without symptoms so that an early examination can reduce the risk of glaucoma. Therefore, the authors designed a glaucoma detection system through eye fundal images that can facilitate the detection of glaucoma by extracting various features like Rim to Disc Ratio, Cup to Disc Ratio (CDR), Vertical Cup to Disc Ratio (VCDR), Horizontal Cup to Disc Ratio (HCDR), and Horizontal to Vertical CDR (H-V CDR) with Morphological Operations dan Thresholding for segmentation of Optic Disc (OD) and Optic Cup (OC). Artificial Neural Network (ANN) is used as a classifier of glaucoma. Through this method, the test data can be divided into two classifications namely normal eyes and glaucoma eyes. 62 pieces of data will be trained and 62 pieces of data will be tested. The results obtained aim to facilitate early detection of glaucoma eyes. Accuracy on training data reaches 100% and accuracy in this study is reached 93.5484%.

Keyword: Glaucoma, Morphological Operation, Thresholding, Artificial Neural Network

Abstrak

Glaukoma adalah penyakit mata yang disebabkan oleh peningkatan tekanan bola mata sehingga terjadi kerusakan saraf optik dan dapat menyebabkan kebutaan nomor dua setelah katarak. Kerusakan saraf sering terjadi tanpa gejala sehingga pemeriksaan dini dapat mengurangi resiko dari glaukoma. Oleh karena itu, penulis merancang suatu sistem untuk mendeteksi glaukoma melalui citra fundus mata dengan mengekstraksi beberapa fitur yaitu Rim to Disc Ratio, Cup to Disc Ratio (CDR), Vertical Cup to Disc Ratio (VCDR), Horizontal Cup to Disc Ratio (HCDR), dan Horizontal to Vertical CDR (H-V CDR) dengan mengsegmentasi Optic Disc (OD) dan Optic Cup (OC) dengan menggunakan metode Morphological Operations dan Thresholding. Artificial Neural Network (ANN) digunakan sebagai metode klasifikasi glaukoma. Melalui metode tersebut, data uji dapat dibagi dalam dua klasifikasi yaitu mata normal dan mata glaukoma. Data latih yang akan diambil sebanyak 62 buah dan data uji yang akan diambil sebanyak 62 buah. Hasil yang diperoleh bertujuan untuk memudahkan mendeteksi secara dini mata glaukoma. Akurasi pada data latih mencapai 100% dan akurasi pada data uji mencapai 93,5484%.

Kata kunci: Glaukoma, Morphological Operation, Thresholding, Artificial Neural Network

I. Pendahuluan

Glaukoma adalah sebuah penyakit *neurodegenerative multi factorial*, yang seiring berjalannya waktu akan menurunkan daya penglihatan seseorang yang mengakibatkan kebutaan. Faktor utama dari glaukoma adalah peningkatan tekanan bola mata atau *Intra Ocular Pressure* (IOP) yang dapat menyebabkan kerusakan saraf optik sehingga otak tidak mendapatkan informasi gambar dari reseptor cahaya[1]. Perubahan retina dan saraf optik sering terjadi tanpa gejala dan tidak terdeteksi dengan tes diagnostik[2]. Sehingga pemeriksaan dini dan perawatan medis yang disarankan oleh dokter spesialis mata dapat membantu mengurangi resiko dari penyakit glaukoma[1].

Statistik yang telah dihasilkan, pada tahun 2013 jumlah orang dengan umur 40-80 tahun pengidap

glaukoma mencapai 64,3 juta. Di benua Asia pengidap glaukoma mencapai 60% dari total pengidap glaukoma di seluruh dunia dan di benua Afrika mencapai 13% pengidap glaukoma, dan diperkirakan akan meningkat menjadi 76,0 juta pada tahun 2020 dan akan menjadi 111,8 juta di tahun 2040[3].

Dokter mata biasanya mendeteksi glaukoma dengan menggunakan parameter *Cup to Disc Ratio* (CDR). Namun, untuk menentukan *Cup to Disc Ratio* (CDR) cukup sulit karena rendahnya kontras diantara cup dan daerah lingkungannya. Selain itu perhitungan CDR manual harus dilakukan oleh dokter terlatih dan perangkat yang mahal seperti *Heidelberg Retinal Tomograph* (HRT) yang relatif terbatas. Oleh sebab itu dibutuhkan adanya pendeteksian glaukoma secara otomatis[4].

Pada penelitian sebelumnya, telah dilakukan deteksi glaukoma dengan menggunakan *Cup to Disc Ratio* (CDR), rasio Rim Neuroretinal di inferior, superior, temporal dan nasal kuadran yaitu kuadran ISNT dengan database yang digunakan DROINS dengan klasifikasi yang digunakan adalah Artificial Neural Network (ANN) oleh Kurnika Choudhary and Shamik Tiwari dengan akurasi yang dihasilkan sebesar 96%[5]. Dan telah dilakukan deteksi glaukoma dengan menggunakan beberapa fitur berupa *Rim to Disc Ratio*, *Cup to Disc Ratio* (CDR), *Vertical Cup to Disc Ratio* (VCDR), dan *Horizontal to Vertical CDR* (H-V CDR) yang berasal dari gambar retina oleh Megha Lontakar, Kevin Noronha, dan Jayasudha Koti dari India dengan sampel 75 mata normal dan 75 mata glaukoma dengan perbandingan klasifikasi dari *K-Nearest Neighbor* (K-NN), *Naïve Bayes* (NB), *Support Vector Machine* (SVM). Dari ketiga metode klasifikasi tersebut, yang memiliki tingkat akurasi tertinggi yaitu pada metode K-NN, dengan akurasi, spesifitas, sensitivitas, *Positive Predictive Value* (PPV) dan *Negative Predictive Value* (NPV) masing-masing yaitu 99,22%, 84%, 86,66%, 84,41%, dan 86,30%[6].

Cup to Disc Ratio (CDR) adalah metode ekstraksi yang paling banyak digunakan untuk mendeteksi glaukoma. CDR dihitung dengan menggunakan diameter *Optic Cup* dibagi dengan diameter *Optic Disc*. *Optic Disc* adalah area terang dari saraf *optic*, sementara *Optic Cup* adalah tempat paling terang di dalam *Optic Disc*[7].

Parameter okular lainnya yaitu *Rim To Disc Ratio* dihitung dan digunakan bersama dengan *Cup to Disc Ratio* (CDR) untuk mengklasifikasikan gambar sebagai glaukomatik atau normal. Ini adalah metode yang lebih efisien dan kuat karena meningkatkan keandalan dan akurasi sistem[8].

Artificial Neural Network (ANN) adalah pengklasifikasi yang banyak digunakan dalam diagnosis medis dan telah terbukti menjadi sangat efektif[9]. ANN adalah seperangkat algoritma pembelajaran yang digunakan untuk mengevaluasi fungsi yang tergantung pada banyak input dan tidak dikenal. ANN sebagai koleksi neuron yang terhubung. ANN digunakan untuk pengenalan pola dan klasifikasi[10].


Pada penelitian ini akan dirancang suatu sistem yang dapat membantu dunia medis untuk mendeteksi secara dini penyakit glaukoma melalui citra mata yaitu bagian fundus mata dengan menghitung *Rim to Disc Ratio*, *Cup to Disc Ratio* (CDR), *Vertical Cup to Disc Ratio* (VCDR), *Horizontal Cup to Disc Ratio* (HCDR), dan *Horizontal to Vertical CDR* (H-V CDR) pada *Optic Disc* (OD), *Optic Cup* (OC) dan *Neuroretinal Rim* (NRR) dengan menggunakan metode *Morphological Operations* dan *Thresholding*, metode klasifikasi yang digunakan adalah *Artificial Neural Network* (ANN).

II. Metodologi Dan Perancangan Sistem

2.1 Glaukoma

Glaukoma adalah penyakit mata yang menyebabkan ireversibel penurunan bidang *optic*[11]. Glaukoma menyebabkan perubahan struktural kepala saraf optik (ONH), lapisan serat saraf dan fungsional simultan kegagalan bidang visual yang mana perubahan struktural dimanifestasikan oleh pelek neuroretinal yang perlahan

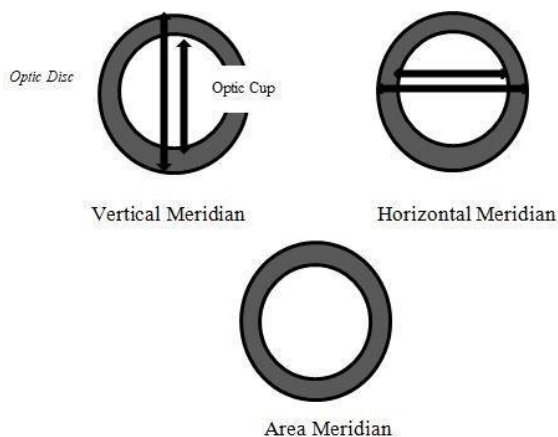
- lahan menandakan adanya degenerasi akson dan astrosit dari saraf *optic*[12]. Mata glaukoma terjadi peningkatan intra okular bola mata atau *Intra Ocular Pressure* (IOP). Karena peningkatan IOP, ukuran cup mulai meningkat yang sesuai meningkatkan CDR. Untuk disc normal CDR dianggap kurang dari 0,5 tetapi dalam kasus glaukoma, lebih besar dari 0,5. Ukuran cup yang meningkat, juga memengaruhi *neuroretinal rim* (NRR). NRR adalah wilayah yang terletak di antara tepi cakram optik dan cangkir optik. Dengan adanya glaukoma, rasio area yang dicakup oleh NRR di daerah hidung dan temporal menjadi tebal dibandingkan dengan daerah yang dicakup oleh NRR di wilayah *Inferior* dan *Superior*[13]. Gambar 1 menunjukkan perbedaan antara mata normal dan mata glaukoma.



Gambar 1. (a) Mata glaukoma dengan CDR>0.5, (b) Mata normal dengan CDR <0.5[13]

2.2 Optic Disc Dan Optic Cup

Optic Disc adalah *area* terang dari saraf optic, sementara *Optic Cup* adalah tempat paling terang di dalam *Optic Disc*[7]. Deteksi batas otomatis *Optic Disc* dan *Optic Cup* memainkan peran penting untuk diagnosis penyakit retina yang dibantu komputer dari gambar ophthalmi[14]. Dalam kasus OD sehat, ukuran cup sangat kecil karena mengandung lebih dari 1,2 juta serat. Dalam glaukoma, ukuran cup meningkat karena hilangnya serabut saraf optik. Peningkatan ukuran *cup* ini merupakan tanda penting dari glaukoma[2]. Oleh karena itu CDR vertikal dan CDAR adalah 2 fitur yang paling penting dan banyak digunakan dalam pendeteksian glaukoma[6]. Berikut ini adalah gambar 2 yang menunjukkan meridian untuk pengukuran CDR.



Gambar 2. Meridian *Cup to Disk Ratio* (CDR)

2.3 Neuroretinal Rim

Neuroretinal Rim adalah wilayah yang terletak di antara tepi disk optik dan gelas optik. Setelah segmentasi disk optik dan gelas optik, NRR diperoleh dengan mengurangi gelas optik dari disk optik. Perubahan tampilan area ini membantu dalam mengidentifikasi kerusakan pada disk akibat glaukoma. Ketebalan pelek adalah fitur penting untuk mendeteksi apakah fundus glaukomatik atau tidak[8]. Rim neuroretinal dapat dipartisi menjadi empat kuadran: *Inferior* (I), *Superior* (S), *Nasal* (N) dan *Temporal* (T). Dalam mata yang sehat, *Inferior* (I) yang lebih rendah adalah biasanya lebih tebal dari pada pelek *Superior* (S), yang lebih tebal dari pelek *Nasal* (N), dan pelek *Temporal* (T) adalah yang paling tipis[15]. Dalam mata glaukomatik, *cup* meningkat di daerahnya secara vertikal mengurangi ketebalan pelek dalam cakram *Inferior - Temporal*. Jadi rasio *rim-disk* untuk wilayah *Inferior - Temporal Rim* dapat dievaluasi untuk menentukan glaukoma[8].

2.4 Citra Digital

Citra digital merupakan pemrosesan citra dua dimensi yang berisi *array* dengan nilai riil maupun kompleks[16]. Citra digital dapat direpresentasikan dalam persamaan 1 dibawah ini:

$$f(x,y) = \begin{bmatrix} f(0,0) & f(0,1) & \dots & f(0,N-1) \\ f(1,0) & f(1,1) & \dots & f(1,N-1) \\ \vdots & \vdots & \ddots & \vdots \\ f(M-1,0) & f(M-1,1) & \dots & f(M-1,N-1) \end{bmatrix} \quad (1)$$


suatu gambar dapat didefinisikan sebagai fungsi dua dimensi, $f(x, y)$, di mana x dan y adalah koordinat spasial (bidang), dan amplitudo f pada setiap pasangan koordinat(x, y) disebut intensitas atau tingkat abu-abu dari gambar pada titik[17]. Citra digital dapat dinyatakan dengan matriks berukuran $N \times M$, yang mana N adalah kolom sedangkan M adalah baris[16]. Setiap elemen matriks ini (pada posisi x,y) disebut dengan *picture element, image element, pels*, atau *pixel*[17].

2.5 Pengolahan Warna

2.5.1 Citra RGB

Gambar digital yang direpresentasikan dalam bentuk RGB memiliki tiga komponen per piksel, masing-masing intensitas untuk merah, hijau dan biru[18]. Baris – Kolom – 3 *array* kelas *uint8, uint16, tunggal*, atau ganda yang nilai pikselnya menentukan nilai intensitas. Untuk *array* tunggal atau ganda,nilai berkisar dari [0,1]

sedangkan untuk *uint8*, nilainya berkisar dari [0, 255] dan untuk *uint16*, nilai berkisar dari [0, 65535][19]. Gambar 3 menunjukkan hasil dari proses RGB.



Gambar 3. (a) Original, (b) *Layer blue*, (c) *Layer green*, (d) *Layer red*

2.5.2 Ekualisasi Histogram

Ekualisasi Histogram adalah teknik peningkatan gambar yang dirancang untuk menyamakan frekuensi - frekuensi kemunculan nilai piksel abu-abu yang berbeda[20]. Persamaan untuk nilai hasil ekualisasi histogram direpresentasikan dalam persamaan 2[21] berikut:

$$K_o = \text{round}\left(\frac{C_i(2^k - 1)}{w \cdot h}\right) \quad (2)$$

yang mana C_i merupakan distribusi kumulatif, w merupakan lebar citra, h adalah tinggi citra.

2.5.3 Thresholding

Thresholding adalah suatu teknik yang memisahkan antara daerah terang dengan daerah gelap sehingga menghasilkan citra biner yaitu menjadi objek dan latar belakang[22]. Objek dan piksel *background* memiliki tingkat abu-abu yang dapat dikelompokkan ke dalam dua *mode* dominan. Cara mengekstrak objek dari *background* adalah dengan memilih ambang T [23]. Berikut ini nilai *Thresholding* yang didefinisikan dalam persamaan 3:

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

jika nilai *pixel* lebih besar dari *threshold* (T) diatur menjadi 1 sebaliknya jika kurang dari *threshold* (T) diatur menjadi 0[24].

2.5.4 Filling Holes

Filling holes adalah suatu operasi yang memberikan nilai 1 pada regionnya[25]. Operasi *Filling Holes* dilakukan dengan cara menandai salah satu titik yang kemudian dilakukan dilasi kondisional[26].

2.5.5 Operasi Morfologi

Operasi Morfologi merupakan operasi yang mengubah struktur bentuk objek, Operasi Morfologi banyak digunakan pada citra biner yaitu dilakukan dengan membedakan antara objek dan latar[26].

Kunci dari Operasi Morfologi adalah pemilihan *structuring element*, karena pemilihan *structuring element* dapat mempengaruhi hasil dari pengolahan citra[25]. *Structuring element* dapat diibaratkan dengan *mask* pada pemrosesan citra biasa (bukan secara morfologi). *Structuring element* juga memiliki titik poros (disebut juga titikorigin/ titik asal/titik acuan)[27].

Operasi morfologi memiliki 4 jenis, yaitu:

1. Dilasi

Operasi dilasi dilakukan untuk menambah ukuran objek dari suatu citra sehingga mempertebal citra[28].

Bentuk persamaan umum untuk Dilasi direpresentasikan dalam persamaan 4[29]:

$$g(x, y) = f(x, y)SE \quad (4)$$

2. Erosi

Operasi dilasi dilakukan untuk mengurangi ukuran objek dari suatu citra sehingga mempertipis citra hal ini berkebalikan dengan proses dilasi [27]. Bentuk persamaan umum untuk Erosi direpresentasi dalam persamaan 5 sebagai berikut [28]:

$$g(x, y) = f(x, y)\theta SE \quad (5)$$

3. Opening

Operasi *Opening* merupakan kombinasi dari operasi Erosi dan Dilasi, yaitu melakukan operasi Erosi terlebih dahulu kemudian operasi Dilasi[27]. Bentuk persamaan umum untuk *Opening* direpresentasikan dalam persamaan 6 berikut ini[28]:

$$f(x, y)\theta SE = (f(x, y)\theta SE) SE \quad (6)$$

4. Closing

Operasi *Closing* merupakan kombinasi operasi Erosi dan Dilasi dengan melakukan operasi Dilasi terlebih dahulu kemudian operasi Erosi[27]. Operasi *Closing* merupakan kebalikan dari operasi *Opening*. Bentuk persamaan umum *Closing* direpresentasikan dalam persamaan 7 berikut ini[28] :

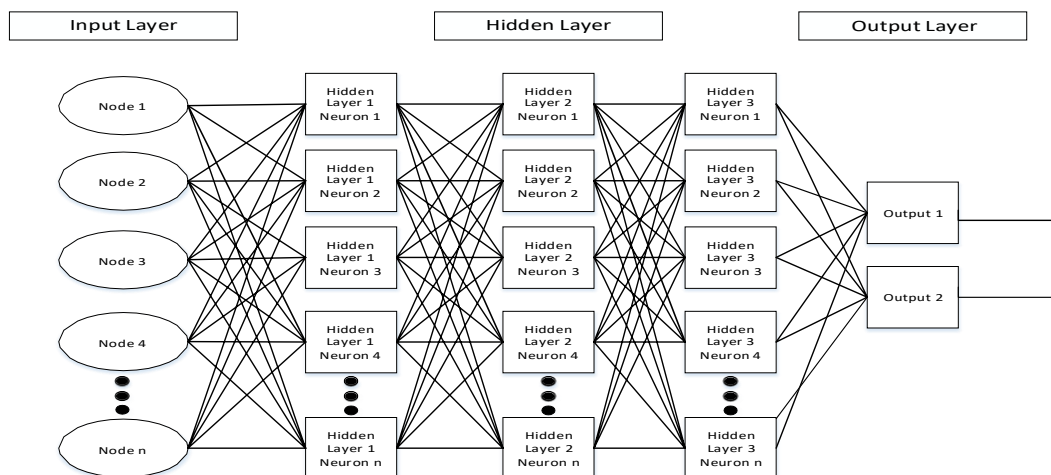
$$f(x, y)\theta SE = (f(x, y) SE)\theta SE \quad (7)$$

2.6 Ekstraksi Fitur

Ekstraksi ciri adalah suatu proses untuk mendapatkan ciri dari suatu citra. Yang dijadikan sebagai vektor ciri pada sistem ini adalah rasio. Rasio yang dihitung adalah rasio antara optic disk terhadap cup disk nya, yang mana antara lain *vertical CDR*, *horizontal CDR*, luas CDR, *Horizontal to Vertical CDR* dan *rim to disc rasio*. Perhitungan rasio dilakukan untuk mendiagnosa glukoma berdasarkan citra fundus mata. Nilai rasio ini yang nantinya digunakan sebagai acuan dalam proses klasifikasi.

2.7 Artificial Neural Network

Artificial Neural Network (ANN) adalah model matematika dari sistem saraf manusia yang disalin kemampuannya untuk dipelajari dan digeneralisasi. Karena sistem non-linear tidak dikenal atau sangat kompleks sehingga hubungan antar variabel dapat dengan mudah dimodelkan oleh ANN [9]. ANN memiliki *input layer*, *hidden layer*, dan *output layer*. Struktur ANN terlihat pada gambar 4 berikut ini:



Gambar 4. Struktur ANN

2.7.1 Backpropagation Neural Network

Jaringan Saraf Tiruan (JST) atau propagasi balik disebut juga dengan *multilayer feedforward*. *Multilayer feedforward* mempropagasi input ke arah depan secara bertahap yaitu lapisan demi lapisan *layer*[30].

Jika jaringan error yang dihasilkan oleh output maka sistem akan mempropagasi balik sinyal hingga menemukan *error* sekecil kecilnya. Dalam melakukan pelatihan jaringan, sistem akan melakukan propagasi maju ke arah depan dan propagasi balik terus menerus hingga menemukan *error* yang paling kecil atau nilainya adalah nol, hal ini disebut *epoch*[30].

2.7.2 Feed - Forward

Feed-forward network memiliki X sebagai *input*, H sebagai *hidden layer*, dan Y sebagai *output*. Jaringan adalah representasi grafis perhitungan, lapisan pertama dihitung dari input X_1, \dots, X_n , lapisan output dihitung dari aktivasi unit tersembunyi (*hidden layer*)[31]. Berikut ini persamaan 8,9,10 untuk merepresentasikan *feed - forward*:

$$X = H \sum_{l=1}^{n_l} w_{jl}^l X_l + W_{j0} \quad (8)$$

$$H = \frac{1}{(1+e^{-x})} \quad (9)$$

$$Y_k = \frac{1}{(1+e^{(x)})} \quad (10)$$

yang mana $X [1, x_1, \dots, x_n]$ adalah *input vector*, H merupakan fungsi aktivasi dan w_{jl}^l adalah penurunan dari *input l* ke *hidden neuron j*, w_{ij}^0 yaitu penurunan dari *hidden neuron j* ke *output l* serta $W_{j0}^l = W_{i0}^0$ adalah penurunan bias.

Fungsi aktivasi yang umum digunakan adalah *tangen*, *hiperbolik (tansig)*, *linier (purelin)* dan *logaritmik sigmoid (logsig)* fungsi[9]:

$$\text{tansig}(x) = \frac{(1-e^{-2x})}{(1+e^{-2x})} \quad (11)$$

$$\text{purelin}(x) = x \quad (12)$$

$$\text{logsig}(x) = \frac{1}{(1+e^{-x})} \quad (13)$$

$$\text{softmax} = \frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}} \quad (14)$$

pada *softmax* nilai z adalah *vector* pada layer output (jika ada 5 output maka aka nada 5 elemen z juga), dan j adalah indeks dari *output*, $j = 1, 2, \dots, K$.

2.7.2 Back – Forward

Nilai *error* akan dijadikan parameter dalam perhitungan *backpropagation*. Sistem akan terus menghitung mundur dan maju sampai ditemukan nilai *error* yang paling kecil[32]. Berdasarkan *error* Y_k dimana $k = 1$ hingga i , digunakan untuk mendistribusikan *error* di unit Y_k ke seluruh unit[31]. Persamaan 15 merupakan bentuk persamaan dari *back propagation*:

$$\delta_k = (T - Y_k)f(Y_k) = (T - Y_k) Y_k(1 - Y_k) \quad (15)$$

T merupakan target, Y_k merupakan output sebelumnya. Dan untuk melakukan perubahan bobot dilakukan dengan menggunakan persamaan 16 dibawah ini:

$$\Delta W_{jk} = a\delta_k Y_k \quad (16)$$

W_{jk} merupakan suku perubahan bobot dan k adalah unit *error* yang digunakan untuk merubah bobot.

Faktor j pada setiap *hidden layer* harus dihitung sebagai dasar perubahan bobot semua garis yang berasal dari unit *hidden layer* dibawahnya[31]. Persamaan

$$\delta_j = \sum_{k=1}^n \delta_k \Delta W_{jk} \quad (17)$$

dimana δ_j merupakan faktor *hidden layer* berdasarkan *error*, dan j adalah faktor *hidden layer*.

2.8 Perancangan Sistem


Pada penelitian ini akan dirancang suatu sistem yang digunakan untuk mendeteksi mata glaukoma dan mata normal. Input sistem berupa citra fundus digital sebanyak 124 buah, yaitu 62 sebagai data latih dan 62 buah sebagai data uji yang diambil dari database RIM-ONE. Dalam sistem ini akan menggunakan 5 ekstraksi fitur dan metode *Artificial Neural Network* untuk pengklasifikasiannya.

2.8.1 Diagram Alur Sistem

Penulis merancang suatu sistem yang digunakan untuk mendeteksi mata glaukoma yang menggunakan aplikasi MATLAB, dengan metode *Morphological Operations* dan *Thresholding* untuk ekstraksi ciri dan metode *Artificial Neural Network* untuk klasifikasinya, dimana secara umum memiliki tahapan sebagai berikut :

1. Tahap Input Citra
2. Tahap Preprocessing
3. Tahap Ekstraksi Fitur
4. Tahap Klasifikasi

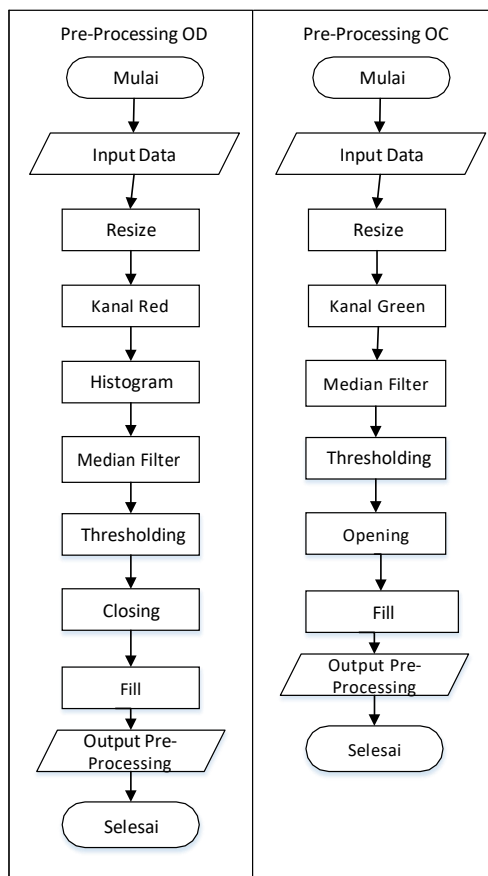
Perancangan sistem secara umum, dapat di representasikan dengan menggunakan blok alir pada gambar 5 sebagai berikut:



Gambar 5. Diagram Alir Sistem

2.8.2 Pre – Processing

Pre – Processing adalah tahap awal yang bertujuan untuk meningkatkan kualitas dari citra masukan yang diperoleh agar memudahkan pada proses ekstraksi fitur. Berikut ini gambar 6 yang mana merupakan gambar diagram alir *pre-processing* dari pengklasifikasi mata normal dan mata glaukoma:



Gambar 6. Diagram Alir Pre-Processing

2.8.3 Ekstraksi Fitur

Setelah melakukan segmentasi maka akan mendapatkan nilai ekstraksi fitur, fitur ekstraksi yang dilakukan :

$$1. \text{ Cup to Disc Area Ratio (CDR)} = \frac{(\text{Luas Optic Disc})}{(\text{Luas Optic Cup})} \quad (18)$$

$$2. \text{ Vertical to CDR} = \frac{(\text{Vertical Cup Diameter})}{(\text{Vertical Cup Diameter})} \quad (19)$$

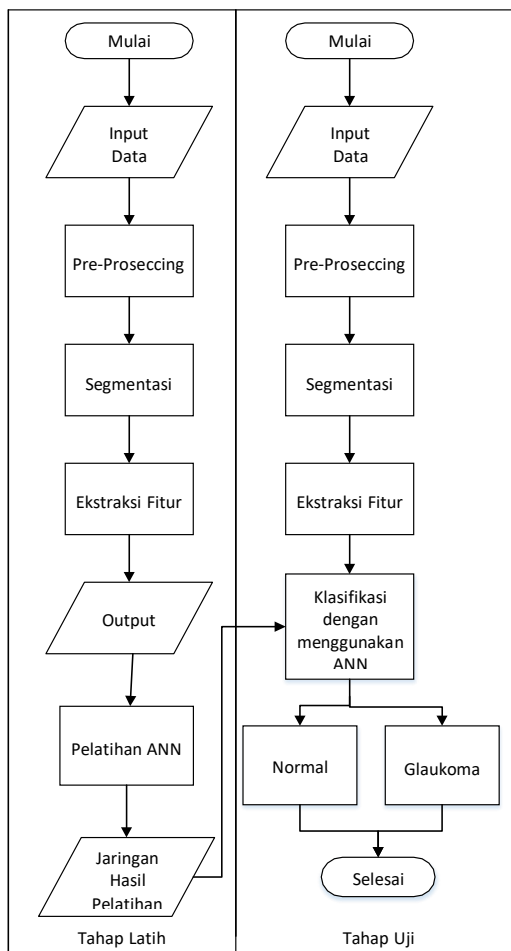
$$3. \text{ Horizontal to CDR} = \frac{(\text{Horizontal Cup Diameter})}{(\text{Horizontal Cup Diameter})} \quad (20)$$

$$4. \text{ Horizontal to Vertical CDR} = \frac{(\text{Horizontal CDR})}{(\text{Vertical Diameter})} \quad (21)$$

$$5. \text{ Rim to Disc Ratio} = \frac{(\text{Luas Rim})}{(\text{Luas CDR})} \quad (22)$$

2.8.4 Klasifikasi

Secara garis besar sistem terbagi menjadi 2 proses, yaitu proses latih dan proses uji. Proses latih adalah proses pembentukan database yang mengambil dan menyimpan nilai ciri dari setiap citra mata yang akan dijadikan referensi pada proses uji. Data uji tersebut akan di input ke dalam sistem untuk ekstraksi ciri kemudian hasil data uji tersebut akan diklasifikasikan berdasarkan database nilai fitur dari data latih dengan menggunakan metode *Artificial Neural Network*. Berikut ini adalah diagram alir klasifikasi sistem dari pendeteksi glaukoma dengan menggunakan citra mata, yang terdapat pada Gambar 7 berikut ini:



Gambar 7. Diagram Alir Klasifikasi

III. Pengujian Dan Analisis

3.1 Analisis Parameter Pada Artificial Neural Network

Pada penelitian ini diujikanan parameter dari ANN untuk mengetahui jumlah *hidden layer* 1, 2, 3, 4 dengan jumlah *neuron* 5, 10, 15, 20 dan jumlah *epoch* 150, 250, 350, 450 dengan jumlah *error goal* 0,000001 sehingga mendapat hasil manakah yang paling tepat. Berikut ini adalah tabel 1 yang mana hasil pengujian parameter *Artificial Neural Network*.

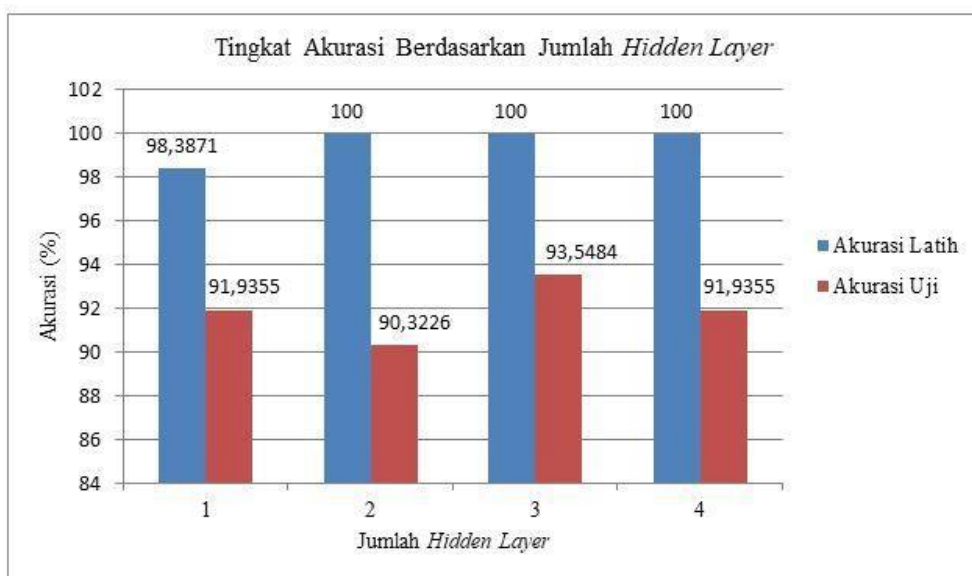
Tabel 1. Pengujian Parameter ANN

No	Hidden Layer	Neuron	Epoch	Akurasi Latih	Akurasi Uji
1	1	5	150	96,7742	85,4839
2	1	5	250	93,5484	91,9355
3	1	5	350	95,1613	75,8065
4	1	5	450	96,7742	82,2581
5	1	10	150	96,7742	80,6452
6	1	10	250	95,1613	90,3226
7	1	10	350	98,3871	91,9355
8	1	10	450	98,3871	87,0968
9	1	15	150	95,1613	87,0968
10	1	15	250	98,3871	91,9355

No	Hidden Layer	Neuron	Epoch	Akurasi Latih	Akurasi Uji
11	1	15	350	98,3871	90,3226
12	1	15	450	96,7742	82,2581
13	1	20	150	96,7742	90,3226
14	1	20	250	98,3871	83,871
15	1	20	350	100	90,3226
16	1	20	450	98,3871	87,0968
17	2	5	150	98,3871	85,4839
18	2	5	250	96,7742	80,6452
19	2	5	350	100	90,3226
20	2	5	450	98,3871	82,2581
21	2	10	150	96,7742	88,7097
22	2	10	250	100	82,2581
23	2	10	350	98,3871	80,6452
24	2	10	450	98,3871	85,4839
25	2	15	150	100	82,2581
26	2	15	250	98,3871	82,2581
27	2	15	350	100	77,4194
28	2	15	450	100	80,6452
29	2	20	150	98,3871	83,871
30	2	20	250	100	83,871
31	2	20	350	100	88,7097
32	2	20	450	100	83,871
33	3	5	150	100	85,4839
34	3	5	250	98,3871	87,0968
35	3	5	350	100	82,2581
36	3	5	450	100	79,0323
37	3	10	150	98,3871	90,3226
38	3	10	250	100	93,5484
39	3	10	350	100	85,4839
40	3	10	450	100	85,4839
41	3	15	150	100	74,1935
42	3	15	250	100	82,2581
43	3	15	350	100	90,3226
44	3	15	450	100	82,2581
45	3	20	150	100	88,7097
46	3	20	250	100	82,2581
47	3	20	350	100	80,6452
48	3	20	450	100	82,2581
49	4	5	150	98,3871	90,3226
50	4	5	250	98,3871	80,6452
51	4	5	350	98,3871	82,2581

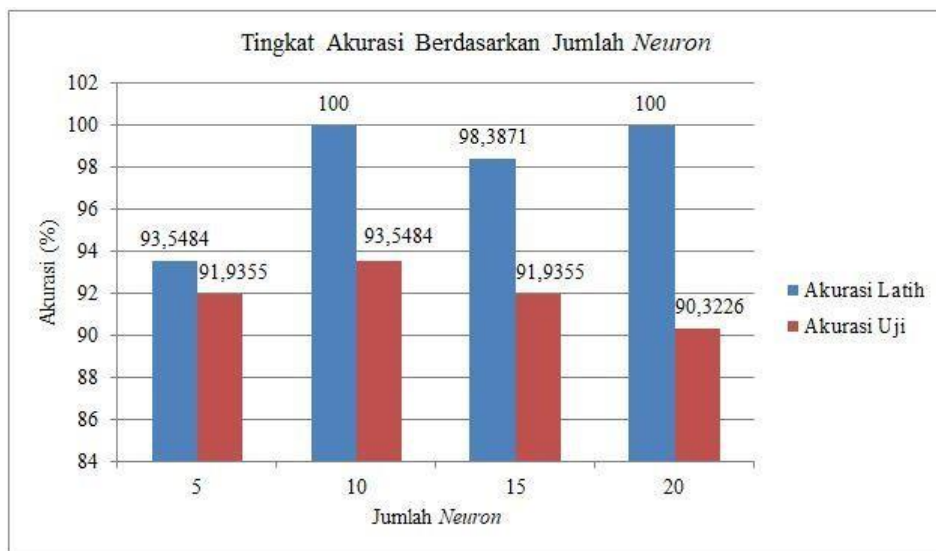
No	Hidden Layer	Neuron	Epoch	Akurasi Latih	Akurasi Uji
52	4	5	450	100	70,9677
53	4	10	150	98,3871	82,2581
54	4	10	250	100	90,3226
55	4	10	350	100	91,9355
56	4	10	450	100	90,3226
57	4	15	150	98,3871	82,2581
58	4	15	250	100	87,0968
59	4	15	350	100	85,4839
60	4	15	450	100	74,1935
61	4	20	150	100	79,0323
62	4	20	250	100	90,3226
63	4	20	350	100	82,2581
64	4	20	450	96,7742	70,9677

Pada tabel 1 merupakan hasil pengujian terhadap jumlah *hidden layer*, jumlah *neuron* dan jumlah *epoch* pada *Artificial Neural Network*. Hasil pengujian pada *neuron* 5, 10, 15, dan 20 dengan jumlah *hidden layer* 1, 2, 3, 4 dan jumlah *epoch* sebesar 150, 250, 350, 450, akurasi terbaik menunjukkan nilai akurasi latih 100% dan nilai akurasi uji 93,484% yaitu dengan jumlah *hidden layer* 3, jumlah *neuron* 10, dan jumlah *epoch* 250. Berikut ini merupakan Gambar 8 yang merepresentasikan hasil akurasi dari tabel 1 berdasarkan jumlah *hidden layer* 1, 2, 3, 4. Gambar 9 merupakan gambar yang merepresentasikan hasil akurasi dari tabel 1 berdasarkan jumlah *neuron* 5, 10, 15, 20. Dan Gambar 10 merupakan hasil akurasi dari tabel 1 berdasarkan jumlah *epoch* 150, 250, 350, 450.




Gambar 8. Tingkat Akurasi Berdasarkan Jumlah Hidden Layer

Pada jumlah *hidden layer* 1 mencapai akurasi latih 98,3871% dan akurasi uji 91,9355%, jumlah *hidden layer* 2 mencapai akurasi latih 100% dengan akurasi uji 90,3226%, Pada jumlah *hidden layer* 3 mencapai akurasi latih 100% dan akurasi uji sebesar 93,5484%, dan pada jumlah *hidden layer* 4 mencapai akurasi latih 100% dan akurasi uji 91,9355%



Gambar 9. Tingkat Akurasi Berdasarkan Jumlah Neuron

Pada *neuron* 5 mencapai akurasi latih 93,5484% dan akurasi uji 91,9355%, pada *neuron* 10 mencapai akurasi latih 100% dan akurasi uji 93,5484%, *neuron* 15 mencapai akurasi latih 98,3871% dan akurasi uji 91,9355% dan *neuron* 20 mencapai akurasi latih 100% dan akurasi uji 9,3226%.



Gambar 10. Tingkat Akurasi Berdasarkan Jumlah Epoch

Berdasarkan gambar 10 jumlah *epoch* 150 menghasilkan akurasi latih sebesar 98,3871% dan akurasi uji 90,3226%, jumlah *epoch* 250 menghasilkan akurasi latih 100% dan akurasi uji 93,5484%, dengan *epoch* 350 menghasilkan akurasi latih 100% dan akurasi uji 91,9355%, serta epoch 450 menghasilkan akurasi latih 98,3871% dan akurasi uji 90,3226%.

IV. KESIMPULAN

Perancangan sistem yang di buat mampu mendeteksi dengan baik mata normal dan glaukoma dengan menggunakan ekstraksi fitur *vertical CDR*, *horizontal CDR*, *CDR*, *Horizontal to Vertical CDR* dan *rim to disc ratio* dengan metode *Morphological Operations* dan *thresholding* Dengan menggunakan metode klasifikasi *Artificial Neural Network* dengan akurasi 93,5484% terdapat pada *neuron* 10 dengan jumlah *hidden layer*nya 3 dan jumlah *epoch* sebesar 250.

Penggunaan jumlah *hidden layer* berpengaruh pada akurasi sistem, yang mana semakin banyak jumlah *hidden layer* maka akan menunjukkan peningkatan kemampuan sistem untuk belajar, sehingga *network* dapat

memetakan data latih dan target lebih tepat. Namun sistem bisa saja mengalami *overfitting*.

Jumlah *neuron* yang digunakan mempengaruhi fungsi aktivasi dari suatu sistem. Jumlah *neuron* akan berbanding lurus dengan fungsi aktivasinya, artinya ketika jumlah *neuron* semakin banyak maka akan semakin baik pula fungsi aktivasiya. Fungsi aktivasi dapat mempengaruhi *hyperplane* dalam memisahkan antar kelas. Namun jumlah *neuron* yang banyak tidak menjamin sistem memiliki akurasi terbaik, hal ini dikarenakan adanya *overfitting* pada sistem.

V. DAFTAR PUSTAKA

- [1] S. M. Nikam and C. Y. Patil, "Glaucoma detection from fundus images using MATLAB GUI," *Proc. - 2017 3rd Int. Conf. Adv. Comput. Commun. Autom. (Fall), ICACCA 2017*, pp. 1–4, 2018.
- [2] N. N. Osborne, *Glaucoma: An Open-Window to Neurodegeneration and Neuroprotection*. 2008.
- [3] Y. Tham *et al.*, "Global Prevalence of Glaucoma and Projections of Glaucoma Burden through 2040 A Systematic Review and Meta-Analysis," *Ophthalmology*, vol. 121, no. 11, pp. 2081–2090, 2020.
- [4] R. Munarto, E. Permata, and I. G. A. T, "Klasifikasi Glaucoma Menggunakan Cup-To-Disk Ratio Dan Neural Network," *Simp. Nas. RAPI XV - 2016 FT UMS*, pp. 370–378, 2016.
- [5] K. Choudhary, "ANN Glaucoma Detection using Cup-to-Disk Ratio and Neuroretinal Rim," *Int. J. Comput. Appl. (0975 – 8887)*, vol. 111, no. 11, pp. 8–14, 2015.
- [6] M. Lotankar, K. Noronha, and J. Koti, "Detection of optic disc and cup from color retinal images for automated diagnosis of glaucoma," *2015 IEEE UP Sect. Conf. Electr. Comput. Electron. UPCON 2015*, 2016.
- [7] W. Ruengkitpinyo, P. Vejjanugraha, W. Kongprawechnon, T. Kondo, P. Bunnun, and H. Kaneko, "An automatic glaucoma screening algorithm using cup-to-disc ratio and ISNT rule with support vector machine," in *IECON 2015 - 41st Annual Conference of the IEEE Industrial Electronics Society*, 2015, pp. 000517–000521.
- [8] A. Agarwal, S. Gulia, S. Chaudhary, M. K. Dutta, C. M. Travieso, and J. B. Alonso-Hernandez, "A novel approach to detect glaucoma in retinal fundus images using cup-disk and rim-disk ratio," *IWOBI 2015 - 2015 Int. Work Conf. Bio-Inspired Intell. Intell. Syst. Biodivers. Conserv. Proc.*, pp. 139–144, 2015.
- [9] S. Vlad, S. Demea, H. Demea, and R. Holonec, "Neural network classifier for glaucoma diagnosis," *2015 E-Health Bioeng. Conf. EHB 2015*, pp. 1–4, 2016.
- [10] T. M. Gayathri Devi, S. Sudha, and P. Suraj, "Artificial neural networks in retinal image analysis," *2015 3rd Int. Conf. Signal Process. Commun. Networking, ICSCN 2015*, 2015.
- [11] A. Soltani, T. Battikh, I. Jabri, Y. Mlouhi, and M. N. Lakhroua, "Study of contour detection methods as applied on optic nerve's images for glaucoma diagnosis," *Int. Conf. Control. Decis. Inf. Technol. CoDIT 2016*, pp. 83–87, 2016.
- [12] R. Bock, J. Meier, L. G. Nyúl, J. Hornegger, and G. Michelson, "Glaucoma risk index:Automated glaucoma detection from color fundus images," *Med. Image Anal.*, vol. 14, no. 3, pp. 471–481, Jun. 2010.
- [13] H. Ahmad, A. Yamin, A. Shakeel, S. O. Gillani, and U. Ansari, "Detection of Glaucoma Using Retinal Fundus Images," *2014 Int. Conf. Robot. Emerg. Allied Technol. Eng.*, pp. 321–324, 2014.
- [14] M. S. Haleem *et al.*, "A Novel Adaptive Deformable Model for Automated Optic Disc and Cup Segmentation to Aid Glaucoma Diagnosis," *J. Med. Syst.*, vol. 42, no. 1, 2018.
- [15] P. Das, S. R. Nirmala, and J. P. Medhi, "Detection of glaucoma using neuroretinal Rim information," *2016 Int. Conf. Access. to Digit. World, ICADW 2016 - Proc.*, pp. 181–186, 2017.
- [16] D. Putra, *Pengolahan Citra Digital - Darma Putra - Google Books*. C.V Andi Offset, 2010.
- [17] R. C. Gonzalez, R. E. Woods, and P. Hall, *Digital Image Processing*. Prentice Hall, 2002.
- [18] S. J. Sangwine, "Colour in image processing," *Electron. Commun. Eng. J.*, no. October, pp. 211–219, 2000.
- [19] T. Kumar and K. Verma, "A Theory Based on Conversion of RGB image to Gray image A Theory Based on Conversion of RGB image to Gray image," *Int. J. Comput. Appl. (0975 – 8887)*, vol. 7, no. April 2016, pp. 6–10, 2010.
- [20] I. Onur and A. Celebi, "IMAGE HISTOGRAM EQUALIZER HARDWARE," *Proc. Acad. Int. Conf. Istanbul, Turkey*, no. October, pp. 6–10, 2017.
- [21] U. Membantu and P. Mikroaneurisma, "Segmentasi citra retina digital retinopati diabetes untuk membantu pendeteksian mikroaneurisma 1)," *Tekno. Elektro*, vol. 9, no. 1, 2010.
- [22] D. M. Ra, I. Setiawan, W. Dewanta, H. A. Nugroho, and H. Supriyono, "Pengolah Citra Dengan

- Metode Thresholding,” *J. Media Infotama*, vol. 15, no. 2, 2019.
- [23] A. T. R. I. Utami, P. S. Informatika, F. Komunikasi, D. A. N. Informatika, and U. M. Surakarta, “Implementasi metode otsu thresholding untuk segmentasi citra daun,” 2017.
- [24] J. Rogowska, *Overview and Fundamentals of Medical Image Segmentation*. Academic Press.
- [25] F. Fahrianto, A. Agusta, and A. T. Muharam, “PENDETEKSIAN POSISI PLAT NOMOR MOBIL MENGGUNAKAN METODE MORFOLOGI DENGAN OPERASI DILASI, FILLING HOLES, DAN OPENING,” *J. Tek. Inform.*, vol. 8, no. 1, pp. 10–15, 2015.
- [26] E. Putri, “PENGUJIAN CITRA JERUK BABY UNTUK MENGETAHUI AREA CACAT MENGGUNAKAN KLASIFIKASI PIXEL,” *J. Nas. Pendidik. Tek. Inform.*, vol. 7, pp. 73–79, 2018.
- [27] S. H. Anwariningsih, A. Z. Arifin, and A. Yuniarti, “Estimasi bentuk,” vol. 5, no. 3, pp. 157–165, 2010.
- [28] R. Srisha and A. Khan, “Morphological Operations for Image Processing: Understanding and its Applications,” no. December, 2013.
- [29] S. Zahrah, R. Saptono, and E. Suryani, “Identifikasi Gejala Penyakit Padi Menggunakan Operasi Morfologi Citra,” no. Snik, pp. 100–106, 2016.
- [30] B. R. Suteja, “Penerapan Jaringan Saraf Tiruan Propagasi Balik Studi Kasus Pengenalan Jenis Kopi,” *J. Inform.*, vol. 3, no. 1, pp. 49–62, 2007.
- [31] J. Larsen, “Introduction to Artificial Neural Networks,” in *Department Of Mathematical Modelling Technical University Of Denmark*, no. November, 1999.
- [32] Z. F. M. Ramli, I. Wijayanto, and S. Hadiyoso, “DETEKSI KONDISI KONSENTRASI BERDASARKAN SINYAL EEG DENGAN STIMULASI MENGHAFAL AI-QURAN DETECTION OF CONCENRATION CONDITIONS BASED ON EEG SIGNALS WITH THE STIMULATION OF AL-QURAN RECITATION Prodi S1 Teknik Telekomunikasi , Fakultas Teknik Elektro , Univers,” *e- Proceeding Eng.*, vol. 5, no. 3, pp. 4683–4690, 2018.