

Deteksi Mata Katarak Berdasarkan Tekstur Gray Level Co-Occurrence Matrix Dengan Metode Self Organizing Map

Yosia Swastika Marcelino¹; Achmad Solichin^{1*})

1. Program Studi Teknik Informatika, Fakultas Teknologi Informasi, Universitas Budi Luhur, Jl. Ciledug Raya, RT.10/RW.2, Petukangan Utara, Pesanggrahan, Jakarta Selatan, DKI Jakarta 12260, Indonesia

^{*)}Email: achmad.solichin@budiluhur.ac.id

Received: 30 Juli 2023 | Accepted: 11 September 2023 | Published: 17 November 2023

ABSTRACT

Cataracts are a common eye problem in Indonesia. Untreated cataracts are the main cause of blindness and the most dominant vision impairment in Indonesia among people over 50 years old, with a proportion reaching 77.7%. Regular eye examinations are necessary to prevent cataracts, but there are obstacles due to the availability of equipment and the cost of eye examinations. Therefore, an efficient and effective cataract detection system is needed. This study aims to detect cataracts in the eyes by utilizing a dataset of eyes from the internet. This research uses RGB and HSV feature extraction combined with the GLCM extraction method. The Gray Level Co-occurrence Matrix (GLCM) method describes the spatial relationship between pixel intensities in an image. With the GLCM matrix, texture information can be extracted from eye images. The Self Organizing Map (SOM) method performs learning based on feature extraction obtained from previously labeled eye images. Based on the test results, this study successfully detects cataract and normal eyes. With the greatest accuracy achieved in the comparison of 80% training data and 20% test data with dimension size = [2 2] and maximum iterations of 100, the highest accuracy of 90% was obtained.

Keywords: Cataract, GLCM, SOM

ABSTRAK

Katarak merupakan masalah mata yang umum terjadi di Indonesia. Katarak yang tidak dioperasi merupakan penyebab utama kebutaan dan gangguan penglihatan paling dominan di Indonesia pada penduduk yang berusia di atas 50 tahun, dengan proporsi mencapai 77,7%. Untuk mencegah katarak diperlukan pemeriksaan mata secara rutin, namun terdapat kendala dari ketersediaan alat dan biaya pemeriksaan mata. Oleh karena itu, diperlukan sistem deteksi mata katarak yang efisien dan efektif. Penelitian ini bertujuan untuk mendeteksi penyakit katarak pada mata dengan memanfaatkan dataset mata yang bersumber dari internet. Penelitian ini menggunakan ekstraksi ciri RGB dan HSV yang dipadukan dengan metode ekstraksi GLCM. Metode Gray Level Co-occurrence Matrix (GLCM) menggambarkan hubungan spasial antara intensitas piksel dalam suatu citra. Dengan matriks GLCM, informasi tekstur dapat diekstrak dari citra mata. Metode Self Organizing Map (SOM) melakukan pembelajaran berdasarkan ekstraksi ciri yang diperoleh dari gambar mata yang diberi label sebelumnya. Berdasarkan hasil pengujian, penelitian ini berhasil mendeteksi mata katarak dan mata normal. Dengan akurasi terbesar diraih pada perbandingan data latih 80% dan data uji 20% dengan dimension size = [2 2] dan iterasi maksimum sebanyak 100, didapatkan akurasi tertinggi sebesar 90%.

Kata kunci: katarak, GLCM, SOM

1. PENDAHULUAN

Masalah kesehatan mata dan katarak di Indonesia menjadi salah satu isu kesehatan yang penting untuk dibahas. Penyakit katarak terjadi pada organ penglihatan manusia, umumnya pada individu yang sudah mencapai usia lanjut [1]. Katarak merupakan salah satu penyebab utama kebutaan di dunia, termasuk di Indonesia. Beberapa faktor penyebab tingginya angka katarak di Indonesia antara lain faktor usia, gaya hidup, dan lingkungan [2]. Katarak yang tidak dioperasi adalah faktor utama penyebab kebutaan dan gangguan penglihatan yang paling signifikan pada penduduk Indonesia, terutama pada usia di atas 50 tahun dengan proporsi sebesar 77,7%. Katarak juga menjadi penyebab utama kebutaan baik pada pria (71,7%) maupun wanita (81,0%) [3].

Namun, masih terdapat kendala deteksi dini katarak di Indonesia. Beberapa faktor yang mempengaruhi antara lain kurangnya informasi masyarakat tentang gejala katarak dan pentingnya pemeriksaan mata secara rutin. Selain itu, ada kendala ketersediaan dan biaya pemeriksaan mata, terutama di pedesaan dan daerah terpencil di Indonesia [4]. Tidak semua rumah sakit dan klinik mata memiliki kelengkapan fasilitas untuk pemeriksaan mata konsisten [5]. Padahal, pemeriksaan mata rutin sangat penting untuk mendeteksi katarak sejak dini dan mencegah kebutaan akibat kondisi tersebut.

Oleh Karena itu, penelitian ini bertujuan untuk membuat sebuah sistem deteksi mata katarak berdasarkan fitur GLCM dan warna RGB-HSV dengan metode SOM, untuk membantu deteksi dini katarak secara efektif dan efisien. Terdapat beberapa penelitian terdahulu tentang sistem deteksi katarak telah dilakukan di Indonesia, diantaranya menggunakan metode *Support Vector Machine* (SVM) dengan akurasi hingga 93,33% [6]. Kemudian menggunakan Fitur Ekstraksi *Gray Level Co-occurrence Matrix* (GLCM) dengan akurasi mencapai 93% [7].

Gray Level Co-occurrence Matrix (GLCM) adalah sebuah metode yang digunakan untuk analisis tekstur atau ekstraksi ciri. Teknik *Gray Level Co-occurrence Matrix* (GLCM) merupakan salah satu teknik analisis tekstur yang telah ada sejak lama dan memiliki dua parameter penting yaitu jarak (d) dan sudut (θ) [8]. Ekstraksi ciri dalam GLCM dilakukan pada 4 arah sudut, masing-masing pada interval 0° , 45° , 90° dan 135° [9]. Ruang warna RGB adalah ruang warna yang melibatkan model warna *Red*, *Green* dan *Blue* (RGB) yang biasa digunakan untuk representasi warna digital. Sedangkan Ruang warna HSV adalah ruang warna yang dapat digunakan untuk mendeskripsikan warna secara lebih intuitif daripada ruang warna RGB. Ruang warna HSV membagi komponen warna menjadi *Hue* (H), *Saturation* (S) dan *Value* (V). *Self Organizing Map* (SOM) atau biasa disebut Kohonen adalah algoritme jaringan syaraf tiruan dengan *layer* tunggal yang menggunakan metode pembelajaran tanpa pengawasan (*unsupervised learning*) [10]. Metode ini memiliki kemampuan untuk mereduksi dimensi sehingga dapat memetakan data berdimensi tinggi ke dalam *grid* n -dimensi (biasanya 2 dimensi) [11].

2. METODE/PERANCANGAN PENELITIAN

2.1. Data Penelitian

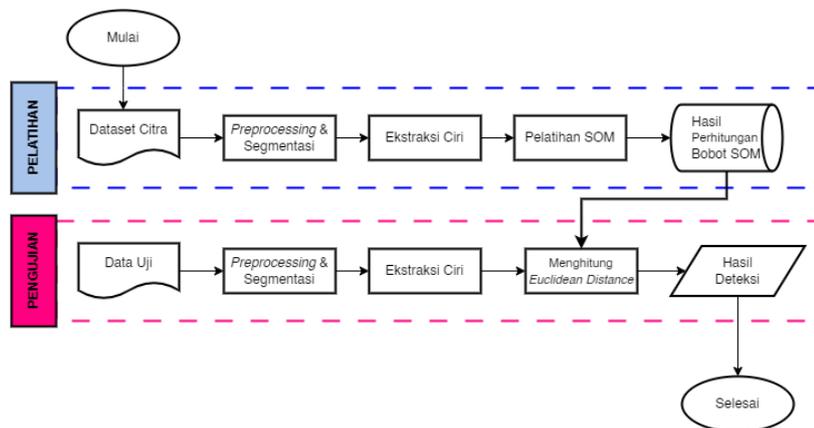
Pada penelitian ini dataset yang akan digunakan adalah dataset mata katarak dan mata normal, dataset diambil dari *public* dataset yang bersumber dari situs Kaggle dengan jumlah dataset sebanyak 200, yang terdiri dari 100 citra mata katarak dan 100 citra mata normal. Sampel dari dataset mata dapat dilihat pada Gambar 1.



Gambar 1. Sampel Dataset Mata

2.2. Penerapan Metode

Pada Dalam penelitian ini, terdapat proses yang harus dilalui agar implementasi dapat berjalan dengan baik. Proses implementasi metode pada penelitian ini dapat dilihat pada Gambar 2.



Gambar 2. Proses Implementasi Metode

2.2.1. Dataset Citra

Langkah awal dalam proses penerapan metode dalam penelitian ini adalah pengumpulan dataset citra. Dataset citra yang digunakan dalam penelitian ini adalah data citra mata katarak dan mata normal, adapun dataset yang digunakan sebanyak 200 data, yang terdiri dari 100 citra mata katarak dan 100 citra mata normal. Data yang didapat bersumber dari *public* dataset yang di ambil dari situs Kaggle.

2.2.2. Pre-processing Data

Proses *pre-processing* data ini bertujuan untuk memaksimalkan hasil dari training dan dapat meningkatkan hasil akurasi dari pengujian. Pada penelitian ini terdapat dua tahap *pre-processing*, yaitu:

a. Cropping Area Iris Mata

Pada proses ini, dilakukan *cropping* pada *Region of Interest* (ROI) yaitu pada bagian iris mata, selain bagian iris mata maka bagian tersebut akan dibuang karena merupakan *noise*. Gambar 3 adalah proses *cropping* citra.



Gambar 3. Proses *Cropping* Citra

b. *Resize* Citra

Dalam penelitian ini citra iris mata yang sudah dilakukan *cropping* sebelumnya kemudian di-*resize* ke ukuran 200*200 piksel. *Resize* citra digunakan untuk menjaga konsistensi ukuran iris dan mempercepat proses pelatihan maupun pengujian sistem. Gambar 4 merupakan hasil citra yang telah melalui tahap *pre-processing*.



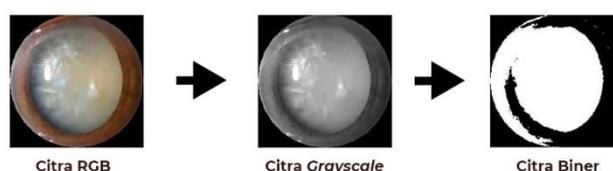
Gambar 4. Citra Hasil *Pre-processing*

2.2.3. Segmentasi Citra

Segmentasi citra adalah sebuah proses untuk mengidentifikasi dan membedakan objek atau wilayah tertentu pada suatu citra yang memiliki nilai atau karakteristik yang berbeda. Berikut adalah tahapan segmentasi citra pada penelitian ini:

a. *Thresholding* Citra

Pada proses ini, citra akan diubah menjadi citra biner yang dimana setiap piksel dalam citra akan diberi nilai 0 atau 1, tergantung apakah mereka melewati nilai ambang (*threshold*) tertentu atau tidak [10]. Tahapan pada *thresholding* citra yaitu dengan menkonversikan citra RGB menjadi citra *grayscale*, kemudian citra *grayscale* tersebut dikonversi menjadi citra biner sesuai dengan ambang piksel. Proses *Thresholding* Citra dapat dilihat pada Gambar 5.



Gambar 5. Proses *Thresholding* Citra

b. Morfologi *Filling Holes*

Proses Morfologi *Filling Holes* sangat penting dilakukan, karena proses ini digunakan untuk menghilangkan bias oleh refleksi cahaya yang terpantul pada bagian iris mata, agar area tersebut tidak dideteksi sebagai katarak. Proses ini dilakukan dengan cara mengisi lubang-

lubang yang terdapat pada citra biner untuk menyempurnakan hasil segmentasi. Proses Morfologi *Filling Holes* dapat dilihat pada Gambar 6.



Gambar 6. Proses *Thresholding* Citra

2.2.4. Ekstraksi Ciri

Ekstraksi ciri (*feature extraction*) adalah tahapan untuk mengekstrak informasi penting dari citra, yang nantinya informasi tersebut akan digunakan sebagai parameter atau nilai masukan untuk melakukan deteksi. Pada penelitian ini ada dua jenis ekstraksi ciri yang digunakan, yaitu ekstraksi ciri warna dan ekstraksi ciri tekstur. Teknik ekstraksi ciri yang digunakan antara lain:

a. Ekstraksi Ciri Ruang Warna RGB

Dalam tahapan ini, ciri yang diekstrak antara lain adalah ruang warna *Red* (R), ruang warna *Green* (G) dan ruang warna *Blue* (B) [12]. Nilai ekstraksi didapat dengan menjumlah nilai intensitas pada setiap ruang warna dibagi dengan jumlah biner yang bernilai 1. Berikut adalah persamaan untuk mencari nilai *Red*, *Green* dan *Blue*.

$$Red = \frac{\text{intensitas Red pada citra}}{\text{jumlah biner pada citra}} \quad (1)$$

$$Green = \frac{\text{intensitas Green pada citra}}{\text{jumlah biner pada citra}} \quad (2)$$

$$Blue = \frac{\text{intensitas Blue pada citra}}{\text{jumlah biner pada citra}} \quad (3)$$

b. Ekstraksi Ciri Ruang Warna HSV

Dalam tahapan ini, ciri yang diekstrak antara lain adalah *Hue* (H), *Saturation* (S) dan *Value* (V) [12]. Nilai ekstraksi didapat dengan menjumlah nilai intensitas pada setiap ruang warna dibagi dengan jumlah biner yang bernilai 1. Berikut adalah persamaan untuk mencari nilai *Hue*, *Saturation* dan *Value*.

$$Hue = \frac{\text{intensitas Hue pada citra}}{\text{jumlah biner pada citra}} \quad (4)$$

$$Saturation = \frac{\text{intensitas Saturation pada citra}}{\text{jumlah biner pada citra}} \quad (5)$$

$$Value = \frac{\text{intensitas Value pada citra}}{\text{jumlah biner pada citra}} \quad (6)$$

c. Ekstraksi Ciri Tekstur GLCM

Pada tahapan ini jarak (d) yang digunakan adalah 1 dan interval arah sudut (θ) yang digunakan antara lain adalah 0° , 45° , 90° dan 135° . Hal ini digunakan untuk menghitung seberapa sering

tingkat kemunculan pasangan piksel dengan skala keabuan (grayscale intensity) tertentu [9]. Pada penelitian ini, hanya 4 fitur yang diekstrak, yaitu *Contrast*, *Correlation*, *Energy* dan *Homogeneity* yang nantinya hasil perhitungan dari setiap arah sudut (θ) akan dirata-rata dan dijadikan sebagai nilai masukan. Berikut adalah persamaan untuk mencari nilai *Contrast*, *Correlation*, *Energy* dan *Homogeneity*.

$$Contrast = \sum_{i,j} |i - j|^2 p(i, j) \quad (7)$$

Kontras (*Contrast*) dalam GLCM adalah statistik yang mengukur perbedaan intensitas antara nilai tertinggi (terang) dan nilai terendah (gelap) antara pasangan piksel.

$$Corelation = \sum_{i,j} \frac{(i-\mu_i)(j-\mu_j)p(i,j)}{\sigma_i \sigma_j} \quad (8)$$

Korelasi (*Correlation*) dalam GLCM adalah statistik yang mengukur seberapa dekat atau berkorelasi antara pasangan piksel [13].

$$Energy = \sum_{i,j} p(i, j)^2 \quad (9)$$

Energi (*Energy*) dalam GLCM adalah statistik yang mengukur total intensitas kekuatan atau energi dari pasangan piksel dengan tingkat keabuan tertentu yang muncul dalam matriks GLCM.

$$Homogeneity = \sum_{i,j} \frac{p(i,j)}{1+|i-j|} \quad (10)$$

Homogenitas (*Homogeneity*) dalam GLCM adalah statistik yang mengukur tingkat homogenitas atau keseragaman variasi dalam intensitas keabuan pada matriks GLCM [9].

2.2.5. Metode *Self Organizing Map* (SOM)

Setelah tahapan ekstraksi ciri berhasil dilakukan, maka tahap selanjutnya adalah pelatihan metode *Self Organizing Map* (SOM). Metode ini digunakan untuk mendeteksi citra mata yang akan di periksa apakah termasuk mata katarak atau normal, berdasarkan hasil pelatihan dari ekstraksi ciri yang telah dilakukan. Proses pembelajaran model SOM dilakukan pada masing-masing kelas [14]. Berikut adalah tahapan pembelajaran dari metode *Self Organizing Map* (SOM):

- a. Inisialisasi nilai input
- b. Inisialisasi Model SOM (*Topology*, *Dimension Size*, dll. Sesuai Atribut)
- c. Inisialisasi Bobot (*weight*) secara acak
- d. Inisialisasi *Max Epoch*
- e. Hitung bobot setiap *neuron* menggunakan *euclidean distance*. Kemudian nilai dengan jarak terkecil akan menjadi *neuron* pemenang atau *Best Matching Unit* (BMU). Berikut adalah persamaan perhitungan *euclidean distance*.

$$D(i, j) = \sqrt{\sum_{t=1}^n (x_t - w_{i,j})^2} \quad (11)$$

- f. *Neuron* pemenang (BMU) diperbarui nilai bobotnya, begitu juga pada bobot tetangganya. Sesuai dengan jarak *neighborhood size* . Berikut adalah persamaan perhitungan pembaruan bobot.

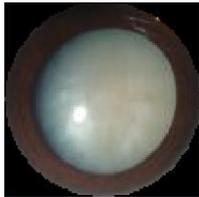
$$w_{i,j}(baru) = w_{i,j}(lama) + \alpha[x_i - w_{i,j}(lama)] \tag{12}$$

- g. Ulangi tahapan pada poin e dan f hingga iterasi mencapai nilai maksimum.
- h. Buat data *output* yang berisi bobot jaringan atau jarak dari titik pusat cluster yang didapat.
- i. Simpan nilai bobot jaringan (*output*) untuk nilai pengetahuan pada data baru

2.2.6. Deteksi Mata

Proses deteksi dilakukan untuk memprediksi apakah citra citra mata yang di *input* termasuk kedalam kelas katarak atau kelas normal. Setiap pengetahuan SOM yang berisi bobot jaringan dari masing-masing kelas, dijadikan nilai acuan untuk memprediksi data baru. Deteksi dilakukan dengan cara menghitung jarak *euclidean* terdekat antara ekstraksi ciri data baru dan setiap titik pusat pada pengetahuan bobot SOM [15]. Jika hasil ekstraksi ciri data baru tersebut lebih dekat jaraknya pada pengetahuan bobot SOM katarak, maka data baru tersebut akan dideteksi sebagai katarak. Sebaliknya, jika jaraknya lebih dekat pada pengetahuan bobot SOM normal, maka data baru tersebut akan dideteksi sebagai normal. Dari perhitungan pada Tabel 1, perlu diketahui bahwa wnet1 adalah pengetahuan bobot SOM katarak dan wnet2 adalah pengetahuan bobot SOM normal. Dari citra pertama pada Tabel 1, jarak terdekat dimenangkan oleh wnet1, yaitu sebesar 0,1435, maka hasil pendeteksiannya adalah Katarak. Sedangkan dari citra ke dua didapati jarak terdekat dimenangkan oleh wnet2, yaitu sebesar 0,2665, maka hasil pendeteksiannya adalah Normal.

Tabel 1. Perhitungan Deteksi Mata

| Citra | Ekstraksi Ciri | Nilai | Jarak Terdekat dari wnet1 | Jarak Terdekat dari wnet2 | Hasil Deteksi |
|---|--------------------|--------|---------------------------|---------------------------|----------------|
|  | <i>Red</i> | 0,5782 | 0,1435 | 0,4775 | Katarak |
| | <i>Green</i> | 0,6077 | | | |
| | <i>Blue</i> | 0,5642 | | | |
| | <i>Hue</i> | 0,2953 | | | |
| | <i>Saturation</i> | 0,1116 | | | |
| | <i>Value</i> | 0,6111 | | | |
| | <i>Contrast</i> | 0,2893 | | | |
| | <i>Correlation</i> | 0,9689 | | | |
| | <i>Energy</i> | 0,4013 | | | |
| | <i>Homogeneity</i> | 0,9753 | | | |
|  | <i>Red</i> | 0,2554 | 0,6903 | 0,2665 | Normal |
| | <i>Green</i> | 0,1271 | | | |
| | <i>Blue</i> | 0,0583 | | | |
| | <i>Hue</i> | 0,0733 | | | |
| | <i>Saturation</i> | 0,7181 | | | |
| | <i>Value</i> | 0,2555 | | | |
| | <i>Contrast</i> | 0,0755 | | | |
| | <i>Correlation</i> | 0,9082 | | | |
| | <i>Energy</i> | 0,4337 | | | |
| | <i>Homogeneity</i> | 0,9659 | | | |

2.3. Rancangan Pengujian

Tujuan utama dari proses ini, adalah untuk mengetahui tingkat akurasi dan mendapatkan model dengan akurasi terbaik. Tahapan dalam proses *testing* ini hampir sama dengan proses *training* hanya saja pada proses *testing*, hanya mengukur jarak terdekat dari setiap titik pusat dalam bobot jaringan SOM. Dari total dataset mata yang berjumlah 200 data, akan dibagi menjadi 3 jenis pembagian dalam bentuk persen, yaitu 80:20, 70:30 dan 60:40. Setiap pengujian dibedakan berdasarkan parameter *Dimension Size* dan *Max Epoch*. Rencana pengujian dapat dilihat pada Tabel 2.

Tabel 2. Rancangan Pengujian

| Pembagian Data (Latih/Uji) | Dimension Size | Max Epoch |
|----------------------------|----------------|-----------|
| 80% / 20% | [2 2] | 100 |
| | | 200 |
| | | 300 |
| | [2 3] | 100 |
| | | 200 |
| | | 300 |
| | [2 4] | 100 |
| | | 200 |
| | | 300 |
| 70% / 30% | [2 2] | 100 |
| | | 200 |
| | | 300 |
| | [2 3] | 100 |
| | | 200 |
| | | 300 |
| | [2 4] | 100 |
| | | 200 |
| | | 300 |
| 60% / 40% | [2 2] | 100 |
| | | 200 |
| | | 300 |
| | [2 3] | 100 |
| | | 200 |
| | | 300 |
| | [2 4] | 100 |
| | | 200 |
| | | 300 |

Dan dilakukan juga perhitungan dengan tabel *confusion matrix* agar performa pengujian dapat diukur dengan maksimal. Terdapat 4 bagian utama dalam *confusion matrix*, yaitu *True Positive* (TP), *True Negative* (TN), *False Positive* (FP) dan *False Negative* (FN).

3. HASIL DAN PEMBAHASAN

Tabel 3 adalah hasil pengujian akurasi dari sistem deteksi mata katarak. Dilakukan juga perhitungan terhadap *accuracy*, *precision*, *recall* dan *F1-Score* dengan menggunakan tabel *confusion matrix*.

Tabel 3. Hasil Pengujian

| Pembagian Data (Latih/Uji) | Dimension Size | Max Epoch | Akurasi | Precision | Recall | F1-Score |
|----------------------------|----------------|-----------|---------------|---------------|---------------|---------------|
| 80% / 20% | [2 2] | 100 | 90,00% | 90,00% | 90,00% | 90,00% |
| | | 200 | 85,00% | 85,00% | 85,00% | 85,00% |
| | | 300 | 85,00% | 80,00% | 88,89% | 84,21% |
| | [2 3] | 100 | 87,50% | 90,00% | 85,71% | 87,80% |
| | | 200 | 80,00% | 85,00% | 77,27% | 80,95% |
| | | 300 | 82,00% | 85,00% | 80,95% | 82,93% |
| | [2 4] | 100 | 82,50% | 85,00% | 80,95% | 82,93% |
| | | 200 | 85,00% | 80,00% | 88,89% | 84,21% |
| | | 300 | 87,50% | 90,00% | 85,71% | 87,80% |
| 70% / 30% | [2 2] | 100 | 83,33% | 73,33% | 91,67% | 81,48% |
| | | 200 | 83,33% | 76,67% | 88,46% | 82,14% |
| | | 300 | 83,33% | 76,67% | 88,46% | 82,14% |
| | [2 3] | 100 | 78,33% | 63,33% | 90,48% | 74,51% |
| | | 200 | 88,33% | 83,33% | 92,59% | 87,72% |
| | | 300 | 81,67% | 76,67% | 85,18% | 80,70% |
| | [2 4] | 100 | 86,67% | 83,33% | 89,29% | 86,21% |
| | | 200 | 80,00% | 70,00% | 87,50% | 77,78% |
| | | 300 | 83,33% | 73,33% | 91,67% | 81,48% |
| 60% / 40% | [2 2] | 100 | 82,50% | 70,00% | 93,33% | 80,00% |
| | | 200 | 87,50% | 82,50% | 91,67% | 86,84% |
| | | 300 | 87,50% | 82,50% | 91,67% | 86,84% |
| | [2 3] | 100 | 81,25% | 70,00% | 90,32% | 78,87% |
| | | 200 | 85,00% | 85,00% | 85,00% | 85,00% |
| | | 300 | 85,00% | 82,50% | 86,84% | 84,61% |
| | [2 4] | 100 | 86,25% | 77,50% | 93,94% | 84,93% |
| | | 200 | 87,50% | 85,00% | 89,47% | 87,18% |
| | | 300 | 82,50% | 75,00% | 88,23% | 81,08% |

Dari hasil pengujian akurasi pada Tabel 3, didapati bahwa model pengujian terbaik diraih pada pembagian data 80:20. Dimana dari total 200 dataset dilakukan pembagian kepada data latih sebesar (80%) atau 160 data dan data uji sebesar (20%) atau 40 data. Dan Model SOM dengan *Dimension Size* = [2 2] dan *Max Epoch* = 100. Didapatkan tingkat akurasi terbaik mencapai 90%. Gambar 7 adalah hasil perhitungan *Confusion Matrix* dari model terbaik yang didapat.

| | | | |
|------------|---|-----------------|----|
| True Class | 1 | 18 | 2 |
| | 2 | 2 | 18 |
| | | 1 | 2 |
| | | Predicted Class | |

Gambar 7. Hasil Perhitungan *Confusion Matrix*

Dari tabel *confusion matrix* pada Gambar 7, Maka diketahui bahwa dari 40 data uji terdapat data *True Positive* (TP) sebesar 18, *True Negative* (TN) sebesar 18, *False Positive* (FP) sebesar 2 dan *False Negative* (FN) Sebesar 2. Berikut adalah perhitungan *Accuracy*, *Precision*, *Recall* dan *F1-Score* pada model yang didapat.

$$Accuracy = \frac{18+18}{18+18+2+2} * 100\% = 90,00\%$$

$$Precision = \frac{18}{18+2} * 100\% = 90,00\%$$

$$Recall = \frac{18}{18+2} * 100\% = 90,00\%$$

$$F1 - Score = 2 * \frac{0,9*0,9}{0,9+0,9} * 100\% = 90,00\%$$

4. KESIMPULAN DAN SARAN

Berdasarkan hasil dari analisis, implementasi dan pengujian pada Sistem Deteksi Mata Katarak ini, dapat ditarik kesimpulan berikut. Sistem deteksi mata katarak ini dapat digunakan untuk melakukan pengecekan mata secara efisien. Pada pengujian sistem, didapati bahwa akurasi terbaik dari sistem deteksi mata katarak ini mencapai angka 90%. Kemudian, dari perhitungan *confusion matrix* pada model terbaik dari pengujian sistem, didapati bahwa dari 40 data uji terdapat 4 data yang dideteksi salah, yaitu 2 data *False Positive* (FP) dan 2 data *False Negative* (FN). Penelitian selanjutnya diharapkan dapat menggunakan dataset mata yang diperoleh dari pasien di rumah sakit atau dokter spesialis mata, agar kualitas citra lebih baik, serta dapat medeteksi jenis dan tingkat keparahan katarak, seperti imatur, matur dan hiper matur.

DAFTAR PUSTAKA

- [1] R. Permana, R. Sovia, and M. Reza, "Sistem Pakar Certainty Factor Dalam Mendiagnosis Indikasi Penyakit Katarak Pada Anak," 2020.
- [2] P. Astari, "Katarak: Klasifikasi, Tatalaksana, dan Komplikasi Operasi," *Cermin Dunia Kedokteran*, vol. 45, no. 10, 2018.
- [3] Pusat Data dan Informasi Kementerian Kesehatan RI, "Situasi Gangguan Pengelihatian," *InfoDATIN*, 2018.

- [4] R. W. Hutabri, R. Magdalena, and R. Y. N. Fu'adah, "Perancangan Sistem Deteksi Katarak Menggunakan Metode Principal Component Analysis (PCA) dan Knearest Neighbor (K-NN)," 2018.
- [5] M. Safaat, A. Sahari, and D. Lusiyanti, "Implementasi Metode K-Nearest Neighbor Untuk Mengklasifikasi Jenis Penyakit Katarak," *JURNAL ILMIAH MATEMATIKA DAN TERAPAN*, vol. 17, no. 1, pp. 92–99, Jun. 2020, doi: 10.22487/2540766x.2020.v17.i1.15184.
- [6] R. Z. Ihram, R. D. Atmaja, and I. Widjayanto, "Deteksi dan Klasifikasi Stadium Katarak Senilis Berdasarkan Citra Mata Menggunakan Metode Support Vector Machine (SVM)," 2018.
- [7] R. N. Sari, "Identifikasi penyakit Mata pada citra mata dengan menggunakan Fitur Ekstraksi Gray Level Co-occurrence Matrix (GLCM)," *Jurnal VOI (Voice Of Informatics)*, vol. 12, no. 1, 2023.
- [8] R. Munarto, Yudono, and Muchtar Ali Setyo, "Klasifikasi Katarak Objek Optic Disc Citra Fundus Retina Menggunakan Support Vector Machine," *Jurnal Ilmiah Setrum Article In Press*, vol. 8, no. 1, pp. 84–95, 2019.
- [9] R. A. Rizal et al., "Analisis Gray Level Co-Occurrence Matrix (GLCM) Dalam Mengenali Citra Ekspresi Wajah," 2019. [Online]. Available: <https://iocscience.org/ejournal/index.php/mantik/index>
- [10] G. F. Fitriana, "Pengenalan Tulisan Tangan Angka menggunakan Self Organizing Maps (SOM)," *Building of Informatics, Technology and Science (BITS)*, vol. 3, no. 1, pp. 31–42, Jun. 2021, doi: 10.47065/bits.v3i1.1002.
- [11] R. E. Nanda and Y. D. Prabowo, "Pengembangan Model Pembelajaran Mesin untuk Klasifikasi Citra Lukisan Menggunakan Self-Organizing Map dengan Library Minisom," 2022.
- [12] E. F. Himmah, M. Widyaningsih, and M. Maysaroh, "Identifikasi Kematangan Buah Kelapa Sawit Berdasarkan Warna RGB Dan HSV Menggunakan Metode K-Means Clustering," *Jurnal Sains dan Informatika*, vol. 6, no. 2, pp. 193–202, Dec. 2020, doi: 10.34128/jsi.v6i2.242.
- [13] R. Nuraini, "Implementasi Jaringan Syaraf Tiruan Menggunakan Metode Self-Organizing Map Pada Klasifikasi Citra Jenis Ikan Kakap," *Technology and Science (BITS)*, vol. 4, no. 3, pp. 1325–1333, 2022, doi: 10.47065/bits.v4i3.2558.
- [14] H. Maharani, E. Suhartono, and S. Darana, "Analisis Estimasi Berat Telur Ayam Ras Berdasarkan Masa Penyimpanan Menggunakan Metode Histogram of Oriented Gradient Dengan Klasifikasi Self-Organizing Maps," 2019.
- [15] H. Khairunnisa, E. Suhartono, and R. Rahmanisa, "Deteksi Anemia Melalui Citra Sel Darah Merah Menggunakan Metode Discrete Wavelet Transform dan Self Organizing Map," 2019.