

KLASIFIKASI POLA PERGERAKAN BOLA MATA MENGGUNAKAN METODE MULTILAYER BACKPROPAGATION

Karina Amadea^{*1}, Fitra A. Bachtiar², Gusti Pangestu³

^{1,2}Universitas Brawijaya, Malang, ³Universitas Bina Nusantara, Malang
Email: ¹kaamadea@gmail.com, ²fitra.bachtiar@ub.ac.id, ³gusti.pangestu@binus.ac.id

*Penulis Korespondensi

(Naskah masuk: 10 Oktober 2021, diterima untuk diterbitkan: 18 Februari 2022)

Abstrak

Salah satu organ terpenting yang ada pada tubuh manusia yaitu indera penglihatan. Manusia dapat memperoleh informasi sebanyak 80% hanya dengan melihat. Pada bagian mata, terutama iris, terdapat wilayah-wilayah yang merepresentasikan tiap bagian dari tubuh. Dengan adanya jaringan syaraf yang ada pada iris, dapat diketahui respons terhadap semua perubahan yang ada di dalam tubuh termasuk perubahan semangat hidup hingga karakter atau sifat seseorang. Pada penelitian ini dibuat sebuah sistem untuk mengenali pola pergerakan mata. Salah satu caranya yaitu melalui pendeteksian pupil. Data citra yang digunakan pada penelitian ini berjumlah 65 citra wajah berukuran 1280 x 720 *pixel* yang akan diklasifikasikan menjadi 5 label yaitu, mata menghadap atas, bawah, depan, kanan, dan kiri. Data citra akan disegmentasi menggunakan *framework Deep-VOG* untuk kemudian didapatkan 107 hasil dari ekstraksi fitur pupil menggunakan metode *Sector Line Distance*. Dari hasil ekstraksi tersebut, selanjutnya akan diklasifikasikan menggunakan metode *Backpropagation*. Arsitektur *Backpropagation* yang digunakan yaitu menggunakan 1 *hidden layer* dengan 11 *neuron* pada *hidden layer*. Sedangkan untuk parameter-parameter yang digunakan yaitu *learning rate* sebesar 0,7 dan iterasi sebanyak 100 iterasi. Hasil dari klasifikasi pola pergerakan mata memperoleh tingkat akurasi sebesar 88,24% pada saat pelatihan dan 80,95% pada saat pengujian.

Kata kunci: pola pergerakan mata, ekstraksi pupil, klasifikasi, backpropagation, jaringan syaraf tiruan.

EYEBALL MOVEMENT CLASSIFICATION USING MULTILAYER BACKPROPAGATION METHOD

Abstract

Eye is one of the most important organs in the human body. By using the eye, humans can get as much as 80% of information just by looking. There are several regions that represent each part of the body in the iris of the eye. The presence of a neural network in the iris, helps humans to be able to find out the response to all changes in the body including changes in the spirit of life, character or even a person's nature. In this study, a system to recognize eye movement patterns will be created through pupil detection. A total of 65 facial image data used in this study measuring 1280 x 720 pixels which will be classified into 5 labels, those are eyes facing up, down, front, right, and left. The facial image will be segmented using the Deep-VOG framework and the pupil features will be extracted using the Sector Line Distance method. The results of the 107 pupil extraction data will be classified using the Backpropagation method and obtain an accuracy level of 88,24% in training and 80.95% in testing using 1 hidden layer with 11 hidden neurons, 0,7 of a learning rate, and 100 of the number of iterations.

Keywords: *eyeball movement patterns, pupil extraction, classification, backpropagation, neural networks.*

1 PENDAHULUAN

Mata merupakan organ penglihatan yang diciptakan Tuhan dan merupakan salah satu organ terpenting yang ada pada tubuh manusia. Dengan menggunakan mata, manusia dapat memperoleh informasi sebanyak 80% hanya dengan melihat (KURMASELA, SAERANG, & RARES, 2013). Beberapa kemampuan dari mata manusia yaitu mata

dapat menunjukkan ketertarikan, merespon, mengikuti sebuah obyek tertentu yang bergerak atau diam. Kemampuan tersebut dapat memberikan informasi mengenai keadaan keseluruhan dari manusia yang didapatkan dari pergerakan mata dan kemudian dapat disimpulkan menjadi beberapa pola gerakan mata (NURCAHYA, PURNAMA, & PURNOMO, 2012). Gerakan pada mata sendiri

disebabkan karena mata mempunyai otot yang dikendalikan oleh otak melalui syaraf motorik, sehingga setiap gerakan tersebut mengandung banyak informasi dari kondisi-kondisi manusia (CHAUDHURI, DASGUPTA, & ROUTRAY, 2012). Pada bidang kedokteran disebutkan bahwa terdapat suatu metode yang menyatakan bahwa tiap bagian pada tubuh dapat direpresentasikan dengan wilayah yang terdapat pada iris mata (bagian yang berwarna pada pupil) yang disebut dengan Iridiology atau yang biasa disebut dengan diagnosis iris (ROCHMAD, 2015). Maka dengan adanya jaringan syaraf pada iris mata, dapat diketahui respons terhadap semua perubahan yang ada di dalam tubuh termasuk perubahan semangat hidup dan keadaan psikologis seseorang. Sehingga dapat diketahui karakter atau sifat seseorang hanya dengan mendeteksi iris pada mata orang tersebut (PUSPASARI, 2011).

Sampai saat ini, penerapan pendeteksian bola mata sudah banyak dilakukan dengan menggunakan berbagai aplikasi pada berbagai bidang. Pada bidang transportasi, pendeteksian pergerakan mata digunakan untuk mengetahui kondisi seseorang ketika mengemudi, apakah ia sedang dalam keadaan yang fit atau sedang dalam keadaan mengantuk (IMANUDDIN, ALHADI, OKTAFIAN, & IHSAN, 2019). Pada bidang psikologi, deteksi mata diperlukan untuk mengetahui tingkat semangat hidup dari seseorang (PUSPASARI, 2011), juga bisa untuk mendeteksi adanya kebohongan atau tidak pada manusia (NUGROHO, NASRUN, & NUGRAHAENI, 2018). Sedangkan pada bidang kesehatan, digunakan untuk mengetahui berbagai macam penyakit hanya dengan mendeteksi pergerakan bola mata, diantaranya untuk mendeteksi adanya gangguan pada lambung (DEWI, 2016), untuk mendeteksi kesehatan pada ginjal (GREGORIUS, 2016), dan khususnya untuk mendeteksi penyakit pada daerah mata itu sendiri (MAHARDIKA, WIDODO, & RAHMAN, 2020). Dari beberapa penelitian tersebut, ditemukan masalah yaitu pada latar belakang citra gambar yang dideteksi. Semakin kompleks latar belakang, maka semakin susah pula untuk mendeteksi keberadaan mata. Selain pada latar belakang, kondisi pencahayaan pun juga memengaruhi proses ekstraksi tersebut.

Maka dari itu, diperlukan penggunaan metode yang tepat untuk mengenali pola pergerakan bola mata. Baik dalam pendeteksian letak mata maupun dalam pengenalan pola dari arah gerak mata itu sendiri. Sebuah sistem cerdas yang dapat mendeteksi serta mengenali pola pergerakan bola mata secara efektif diharapkan dapat menjadi solusi dalam permasalahan ini sehingga informasi yang didapat jauh lebih akurat. Pada penelitian terdahulu sudah banyak yang mencoba untuk meneliti terkait klasifikasi pengenalan pola pergerakan mata. Penelitian pertama dilakukan oleh (TRYANTO,

NASRUN, & NUGRAHAENI, 2018) yang menggunakan pergerakan bola mata melalui pupil untuk mendeteksi kebohongan berbasis video kamera menggunakan metode Haar Cascade Classifier dan Jaringan Syaraf Tiruan (multilayer perceptron). Pada penelitian tersebut memperoleh akurasi hingga 87%. Penelitian kedua yaitu dilakukan oleh (NUGROHO, NASRUN, & NUGRAHAENI, 2018) yang juga mendeteksi kebohongan melalui gerakan mata namun menggunakan metode klasifikasi Backpropagation dan memperoleh akurasi sebesar 85,33%. Penelitian selanjutnya dilakukan oleh (PANGESTU & BACHTIAR, 2019) yang mendeteksi gerakan mata melalui letak pupilnya menggunakan metode *Sector Line Distance* dan mengklasifikasi menggunakan metode *Learning Vector Quantization*. Pada penelitian tersebut memperoleh akurasi sebesar 81,72% dikarenakan masih terdapat kekurangan pada optimasi bobot LVQ.

Dalam disiplin ilmu komputer, terdapat banyak metode yang digunakan untuk pengenalan dan pengklasifikasian. Salah satu metode yang dapat digunakan yaitu metode yang berbasis Jaringan Syaraf Tiruan, karena diketahui sangat baik dalam proses pengidentifikasian pola khususnya pada mata manusia (PUSPASARI, 2011). Maka dari itu, metode Jaringan Syaraf Tiruan *Backpropagation* diaplikasikan dengan menggunakan perseptron berlapis banyak (*multilayer perceptrons*) dan dikombinasikan dengan metode *Nguyen-Widrow* dengan harapan dapat mengoptimalkan bobot dan hasil dari klasifikasi pola pergerakan mata. Data citra yang didapat akan diproses untuk disegmentasi menggunakan *DeepVOG framework*. Kemudian diekstraksi menggunakan metode *Sector Line Distance* untuk selanjutnya dilakukan pelatihan dan pengujian menggunakan metode klasifikasi *Backpropagation*. Dari hasil dari klasifikasi tersebut akan diketahui seberapa pengaruh parameter jumlah *hidden neuron*, *learning rate*, *iterasi*, dan *hidden layer* terhadap akurasi dalam proses klasifikasi pola pergerakan bola mata.

Berdasarkan pemaparan latar belakang diatas, pada penelitian ini akan dirancang sebuah sistem berbasis komputer untuk memberikan solusi pada pengenalan pola bola mata. Struktur pembahasan paper ini adalah sebagai berikut: bab 2 akan dijelaskan mengenai dasar teori terkait penelitian. Bab 3 akan dijelaskan mengenai metodologi yang diusulkan pada penelitian ini. Pembahasan mengenai hasil akan dijelaskan pada Bab 4 dan sebagai penutup akan disampaikan pada Bab 5.

2 DASAR TEORI

2.1 *Deep-VOG*

DeepVOG merupakan suatu *framework* yang mengintegrasikan jaringan saraf konvolusional penuh (FCNN) dengan metode *Ellipse Segmentation* (Ellseg) yang ditingkatkan dengan

mempertimbangkan ukuran *confidence* pada segmentasi FCNN. Arsitektur yang digunakan dalam *DeepVOG* ini diadaptasi dari U-Net dasar untuk segmentasi pupil dalam gambar skala abu-abu 2D. U-Net terdiri dari beberapa lapisan ekstraksi fitur, yang disusun secara jalur *down-sampling* di sisi kiri dan jalur *up-sampling* di sisi kanan. Dibandingkan dengan U-Net asli, telah dilakukan beberapa perubahan arsitektur pada V-Net (MILLETARI, NAVAB, & AHMADI, 2016), yang sebagian juga diadopsi dalam *DeepVOG*. Pada setiap tahap jalur *up-* dan *down-sampling*, digunakan lapisan konvolusional dengan filter 10×10 yang menghasilkan peta fitur dengan ukuran input yang sama dengan *padding* yang sesuai. Jalur *down-sampling* mengurangi ukuran peta fitur dan meningkatkan ukuran bidang reseptif *filter* konvolusional pada setiap tahap, sehingga dapat mengekstraksi fitur yang lebih kompleks dalam konteks yang lebih besar seperti yang ditampilkan pada Gambar 2.

Penggabungan FCNN dengan metode EllSeg tersebut memungkinkan *DeepVOG* dapat melakukan pelokalan pusat pupil dengan akurasi median sekitar 1,0 piksel, estimasi tatapan akurat hingga 0,5 derajat, estimasi kontur elips, dan deteksi kedip dengan menggunakan satu jaringan dan nilai *confidence* yang ditetapkan. FCNN mampu menyegmentasikan pupil dengan baik dalam beragam kumpulan data baru yang sebelumnya tidak digunakan pada saat pelatihan (YIU, et al., 2019). Penerapan *framework DeepVOG* pada penelitian ini bersumber dari laman github: <https://github.com/pydsgz/DeepVOG>. Ilustrasi hasil dari *DeepVOG* ditampilkan pada Gambar 1.

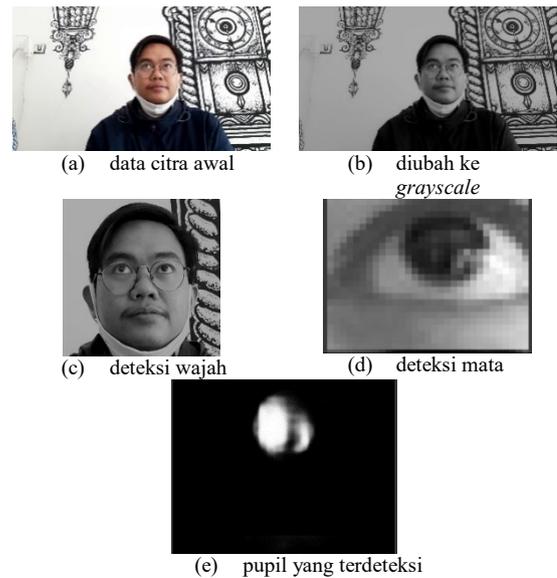
2.2 Backpropagation

Backpropagation merupakan salah satu metode *supervised learning* dari jaringan syaraf tiruan yang cukup baik digunakan dalam masalah pengenalan dan klasifikasi. Dalam proses pelatihan pada metode *Backpropagation*, akan selalu dilakukan *update* bobot yang digunakan pada penghubung antar lapisan untuk mendapatkan bobot yang sesuai dengan permasalahan yang diangkat (KHOLILI, SETIAWAN, & WIHANDIKA, 2019).

Pada proses metode *Backpropagation* terdapat tiga fase (WURYANDARI & AFRIANTO, 2012), yaitu:

1. Feedforward (Propagasi maju)

Perhitungan yang dilakukan dari *input layer* menuju *hidden layer* terjadi. Kemudian dilanjutkan ke *output layer* menggunakan fungsi aktivasi yang sudah ditetapkan.



Gambar 1 Ilustrasi hasil *DeepVOG*

2. Backpropagation (Propagasi mundur)

Fase ini merupakan fase perhitungan *error* yang dihasilkan dari perhitungan *feedforward*. Nilai keluaran pada *feedforward* akan dibandingkan dengan nilai target yang sudah ditentukan sebelumnya. Kemudian, semua yang berhubungan dengan *output layer* akan dilakukan perhitungan *error*.

3. Weight Update (Perubahan bobot)

Bobot yang dihasilkan secara acak pada inialisasi bobot akan dilakukan perubahan berdasarkan nilai *error* yang dihasilkan pada saat *feedforward*.

Menurut (FAUSETT, 1994), tahapan-tahapan proses pada *Backpropagation* adalah sebagai berikut:

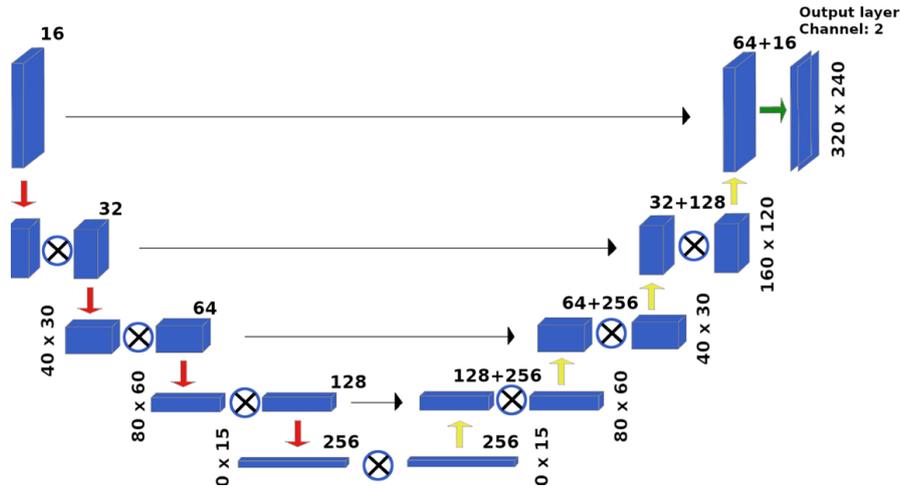
1. Inialisasi bobot dengan nilai acak yang kecil.
2. Selama kondisi berhenti salah, lakukan Langkah 3-10.

Fase Feedforward

Untuk setiap pasangan data latih, lakukan Langkah 4-8.

Setiap *hidden* neuron ($Z_j, j = 1, \dots, p$) menjumlahkan *input* yang diterima beserta bobotnya

$$z_{in_j} = v_{0j} + \sum_{i=1}^n x_i v_{ij} \quad (1)$$



Gambar 2 Arsitektur DeepVOG (Yiu, et al., 2019)

Selanjutnya *output* dari *hidden* neuron dihitung menggunakan fungsi aktivasi

$$z_j = f(z_{in_j}) \quad (2)$$

3. Setiap *output* neuron ($Y_k, k = 1, \dots, m$) menjumlahkan *input* yang diterima beserta bobotnya

$$y_{in_k} = w_{0k} + \sum_{j=1}^p z_j w_{jk} \quad (3)$$

Selanjutnya, fungsi aktivasi digunakan untuk menentukan *output* dari Y_k

$$y_k = f(y_{in_k}) \quad (4)$$

Fase Backpropagation

4. Perhitungan faktor *error* pada *output layer* dengan turunan *loss function*

$$\delta_k = y_k - t_k \quad (5)$$

Hitung faktor *error* pada *output layer* dengan turunan fungsi aktivasi

$$\delta_{in_k} = y_{in_k} \times f'(y_{in_k}) \quad (6)$$

Hitung perubahan bobot untuk menghitung bobot baru

$$\Delta w_{jk} = z_j \times \delta_k \times w_{ij} \quad (7)$$

5. Setiap *hidden* neuron ($Z_j, j = 1, \dots, p$) menghitung *delta error* dari *output* neuron

$$\delta_j = \delta_k \times \delta_{in_k} \times w_{ij} \quad (8)$$

Delta error pada *hidden* neuron diperoleh dengan persamaan (6).

$$\delta_{in_j} = z_j \times f'(z_j) \quad (9)$$

Perubahan bobot diperoleh dengan persamaan (7).

$$\Delta v_{ij} = l_i \times \delta_j \times \delta_{in_j} \quad (10)$$

Fase kalkulasi dan perbarui bobot

6. Bobot pada *output* neuron diperbarui dengan persamaan:

$$w_{jk}(baru) = w_{jk}(lama) - (\alpha \times \Delta w_{jk}) \quad (11)$$

Bias pada *output* neuron diperbarui dengan persamaan:

$$w_0(baru) = w_0(lama) - (\alpha \times \delta_k \times \delta_{in_k}) \quad (12)$$

Bobot pada *hidden* neuron diperbarui dengan persamaan:

$$v_{ij}(baru) = v_{ij}(lama) - (\alpha \times \Delta v_{ij}) \quad (13)$$

Bias pada *hidden* neuron diperbarui dengan persamaan:

$$v_0(baru) = v_0(lama) - (\alpha \times \delta_j \times \delta_{in_j}) \quad (14)$$

7. Cek kondisi berhenti

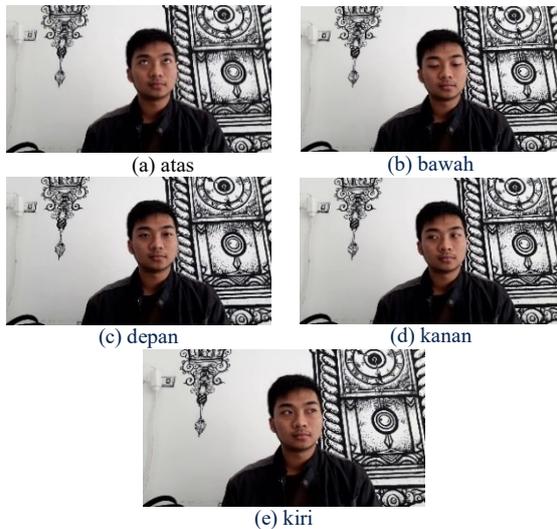
Dimana x merupakan vektor *input*, y adalah vektor *output*, δ_k merupakan bagian dari koreksi *error* perubahan bobot w_{jk} , δ_j merupakan bagian dari koreksi *error* perubahan bobot v_{ij} , a untuk *learning rate*, w sebagai nilai bobot *output layer*, w_0 merupakan nilai bias *output layer*, v merupakan nilai bobot *hidden layer*, v_0 yaitu nilai bias *hidden layer*, z_{in_j} untuk total *input* neuron ke- j , z_j untuk hasil aktivasi neuron ke- j , y_{in_k} untuk total *output neuron* ke- k , dan y_k untuk hasil aktivasi *neuron* ke- k .

3 KLASIFIKASI POLA PERGERAKAN BOLA MATA

3.1 Teknik Pengumpulan Data

Teknik pengumpulan data yang dilakukan pada penelitian ini yaitu menggunakan studi dokumen data sekunder dari penelitian oleh Pangestu dan Bachtiar (2019) dengan jumlah label pada data sebanyak lima label. Data sekunder yang digunakan berjumlah 65 citra wajah berukuran 1280 x 720 *pixel* yang diambil dari 13 orang dengan masing-masing bola matanya menghadap kelima arah (atas, bawah, depan, kanan, dan kiri). Ilustrasi dataset citra yang digunakan dapat dilihat pada Gambar 3. Pada

gambar tersebut terlihat bahwa pergerakan bola mata hanya dapat dideteksi pada dimana letak pupil tersebut berada.



Gambar 3 Ilustrasi Dataset Citra

3.2 Ekstraksi Fitur

Pada proses ekstraksi fitur, dilakukan proses segmentasi pada data citra menggunakan *DeepVOG*. Hal pertama yang dilakukan yaitu mendeteksi wajah dan pupil mata. Pendeteksian pupil dilakukan pada masing-masing mata kanan dan kiri. Hasil dari pendeteksian pupil tersebut didapatkan 107 citra pupil dari total 135 pupil mata kanan dan mata kiri. Sedangkan untuk 28 citra sisanya tidak digunakan dikarenakan kurangnya sistem dalam mengenali pupil. Setelah dilakukan proses deteksi pupil, proses selanjutnya yaitu ekstraksi fitur untuk mendapatkan titik tengah pupil yang nantinya digunakan untuk menghitung empat bobot vektor yaitu atas, bawah, kanan, dan kiri pada setiap pupil mata menggunakan persamaan pada metode *Sector Line Distance*. Bobot tersebut digunakan sebagai fitur referensi klasifikasi menggunakan metode *Backpropagation*.

3.3 Teknik Analisis Data

Data hasil ekstraksi yang telah didapatkan sebanyak 107 data seluruhnya akan diproses melalui tahapan normalisasi untuk selanjutnya dibagi menjadi data latih dan data uji dengan perbandingan 80:20. Data latih akan digunakan untuk menguji parameter-parameter terbaik dengan menggunakan arsitektur dasar yang telah ditentukan. Sedangkan data uji akan digunakan untuk proses validasi data atau pengujian terhadap metode yang digunakan.

3.4 Implementasi Algoritme

Algoritme yang diterapkan pada penelitian ini yaitu metode *Backpropagation*. Secara konsep, metode ini bekerja untuk mempelajari suatu pola pada data latih yang kemudian dapat diimplementasikan pada data uji. Pada kasus klasifikasi, metode ini mempelajari pola data

sebelumnya lalu melakukan pelatihan sehingga mendapatkan sebuah prediksi hasil klasifikasi dengan parameter-parameter yang sudah ditentukan. Langkah-langkah implementasi algoritme dapat dilihat pada Gambar 4.

Langkah pertama pada implementasi algoritme dimulai dari membagi data ekstraksi menjadi data latih dan data uji. Data latih digunakan untuk melakukan pelatihan pengenalan pola menggunakan *Backpropagation* sekaligus melakukan perbaikan bobot dan pengujian parameter terbaik. Perbaikan bobot dan parameter terbaik nantinya digunakan dalam implementasi propagasi maju menggunakan data uji sehingga didapatkan hasil keluaran klasifikasi.

3.5 Rancangan Pengujian

Pada tahap ini parameter pada *Backpropagation* akan dicari terlebih dahulu untuk mendapatkan nilai akurasi terbaik. Pengujian parameter untuk mendapatkan nilai terbaik dilakukan pada parameter jumlah *hidden neuron*, *learning rate*, jumlah iterasi, dan jumlah *hidden layer*.

Selanjutnya pengujian algoritme dilakukan dengan menggunakan data uji. Data uji akan diprediksi labelnya menggunakan arsitektur dari parameter-parameter optimal yang telah didapatkan dari pengujian parameter sebelumnya, lalu dievaluasi dengan *confusion matrix* untuk melihat ketepatan dalam memprediksi dan *F1-Score* untuk melihat performa dari metode yang digunakan.

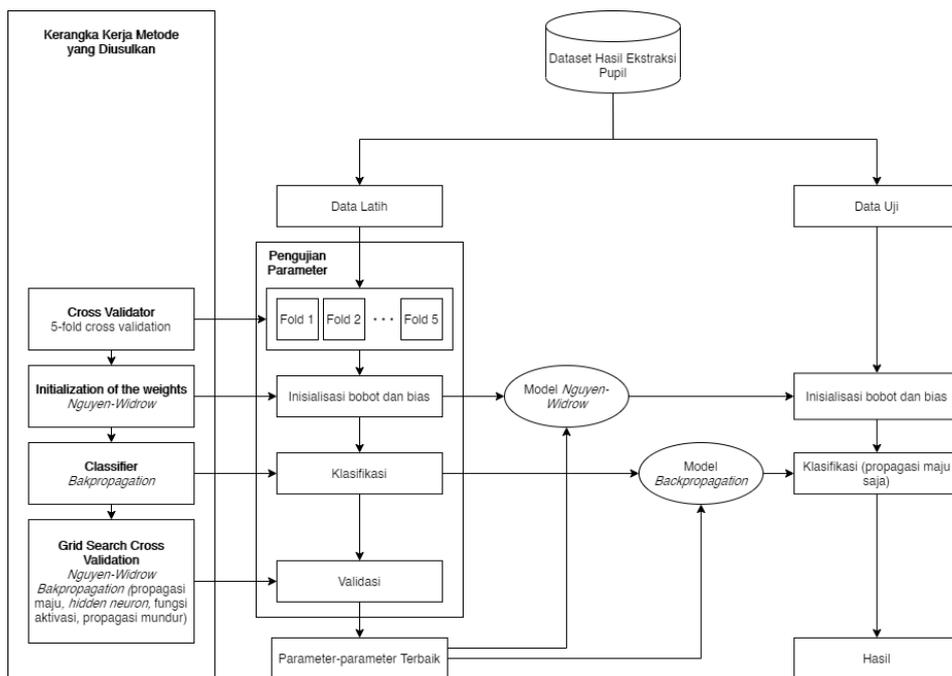
4 HASIL DAN PEMBAHASAN

4.1 Pengujian Jumlah Hidden Neuron

Hasil pengujian jumlah *hidden neuron* diperoleh nilai akurasi terbaik pada saat percobaan yang ke-6 yaitu menggunakan jumlah *hidden neuron* sebanyak 11. Semakin banyak jumlah *hidden neuron* yang digunakan maka nilai akurasinya akan semakin besar. Jumlah dari *hidden neuron* berpengaruh terhadap cepat atau lambatnya konvergensi data. Jika menggunakan terlalu sedikit *hidden neuron*, maka jaringan sulit untuk dapat mengenali pola. Namun jika terlalu banyak *hidden neuron*, maka akan mengakibatkan *overfitting* atau jaringan akan mengenali terlalu dalam.

4.2 Pengujian Learning Rate

Hasil pengujian nilai *learning rate* diperoleh nilai akurasi terbaik pada saat percobaan yang ke-8 yaitu menggunakan nilai *learning rate* sebesar 0,7. Semakin besar jumlah *learning rate* yang digunakan maka nilai akurasinya cenderung semakin besar. Nilai dari *learning rate* juga berpengaruh terhadap cepat atau lambatnya konvergensi data. Semakin besar nilai *learning rate*, menyebabkan perubahan bobot yang besar dan berakibat semakin lambat juga konvergensi data untuk tercapai.



Gambar 4 Diagram Alur Implementasi Algoritme

4.3 Pengujian Jumlah Iterasi

Hasil pengujian jumlah iterasi diperoleh nilai akurasi terbaik pada saat percobaan yang ke-5 yaitu menggunakan jumlah iterasi sebanyak 100 iterasi. Semakin banyak jumlah iterasi yang digunakan maka nilai akurasinya cenderung semakin besar. Sebaliknya, semakin dikit akurasi yang digunakan untuk proses pelatihan, maka model akan sedikit belajar dan akurasi cenderung semakin kecil.

4.4 Pengujian Jumlah Hidden Layer

Hasil pengujian jumlah *hidden layer* diperoleh nilai akurasi terbaik pada saat percobaan pertama yaitu hanya menggunakan satu *hidden layer*. Semakin banyak jumlah *hidden layer* yang digunakan maka nilai akurasinya cenderung semakin kecil. Hal tersebut dikarenakan penggunaan *hidden layer* yang semakin banyak, akan membuat jaringan semakin rumit.

4.5 Analisis Global

Parameter-parameter optimal yang telah didapatkan dari pengujian sebelumnya digunakan untuk pengujian terakhir sebagai evaluasi kinerja algoritma *Backpropagation*. Pengujian ini menggunakan data uji yaitu sebanyak 21 data yang diambil dari 107 data hasil ekstraksi. Hasil *confusion matrix* dari data uji ditampilkan pada Tabel 1.

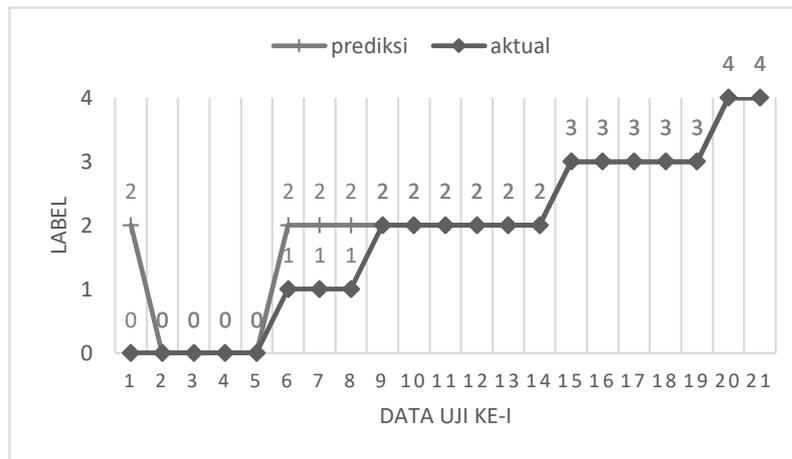
Tabel 1 Confusion Matrix pada Data Uji

aktual \ prediksi	Data Uji				
	atas	bawah	depan	kanan	kiri
atas	4	0	1	0	0
bawah	0	0	3	0	0
depan	0	0	6	0	0
kanan	0	0	0	5	0
kiri	0	0	0	0	2

Dari Tabel 1 didapatkan penjelasan akurasi dari pengenalan data untuk setiap kelas. *Cell* berwarna abu-abu menjelaskan jumlah data yang dikenali benar oleh sistem (*True*). Sedangkan *cell* lain menjelaskan mengenai jumlah data yang dikenali salah atau tidak dikenali oleh sistem (*False*). Jika dihitung nilai akurasinya berdasarkan rumus, akan menjadi:

$$\begin{aligned}
 accuracy &= \frac{4 + 0 + 6 + 5 + 2}{21 \text{ data}} \times 100\% \\
 &= \frac{17}{21 \text{ data}} \times 100\% \\
 &= 80,952\%
 \end{aligned}$$

ditunjukkan pada Gambar 5. Label 0 pada grafik menunjukkan label atas, 1 untuk label bawah, 2 untuk label depan, 3 untuk label kanan, dan 4 untuk label kiri. Berdasarkan grafik tersebut, disimpulkan bahwa pola dari hasil prediksi dengan menggunakan *Backpropagation* hampir mendekati data asli. Penyimpangan yang paling besar yaitu terjadi pada data pertama dimana seharusnya menunjukkan label 0 (atas) namun yang terdeteksi adalah 2 (depan). Grafik hasil pengujian menggunakan data uji



Gambar 5 Grafik Pengujian Akhir

Tabel 2 Evaluasi *F1-Score*

	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
<i>atas</i>	100%	80%	88,89%
<i>bawah</i>	0%	0%	0%
<i>depan</i>	60%	100%	75%
<i>kanan</i>	100%	100%	100%
<i>kiri</i>	100%	100%	100%

Berdasarkan Tabel 2, ditunjukkan bahwa nilai *F1-Score* terbaik secara urut yaitu ada pada label depan dan kanan sebesar 100%, lalu label atas sebesar 88,89%, label depan sebesar 75%, dan label bawah sebesar 0%. Nilai *F1-Score* digunakan untuk mengukur keseimbangan antara nilai *false positif* dan *false negatif* pada hasil klasifikasi tiap label. Pada label bawah menunjukkan nilai yang kurang memuaskan dikarenakan tidak meratanya pembagian antara data latih dan data uji yang menyebabkan ketidakseimbangan komposisi antar label data seperti yang terlihat pada Tabel 3. Pada data uji tersebut terlihat bahwa jumlah antar label data berbeda dikarenakan pembagian acak antara data latih dan data uji yang dapat mempengaruhi hasil pengujian global.

Tabel 3 Data Uji

<i>I1</i>	<i>I2</i>	<i>I3</i>	<i>I4</i>	<i>label</i>
0,3914	0,3100	0,6009	0,4831	atas
0,5850	0,1442	0,4896	0,7304	atas
0,4162	0,1929	0,6341	0,6478	atas
0,4128	0,2426	0,6075	0,5719	atas
0,7561	0,4259	0,2292	0,6238	atas
0,6173	0,5315	0,3138	0,2744	bawah
0,5561	0,6315	0,3874	0,0783	bawah
0,5655	0,4365	0,3797	0,3484	bawah
0,3314	0,3690	0,6510	0,4387	depan
0,3470	0,3965	0,6233	0,3839	depan
0,4392	0,3769	0,5244	0,3759	depan
0,3613	0,4255	0,5999	0,3327	depan

<i>I1</i>	<i>I2</i>	<i>I3</i>	<i>I4</i>	<i>label</i>
0,4571	0,4064	0,4981	0,3366	depan
0,3626	0,3740	0,6116	0,4061	depan
0,0951	0,6179	0,8801	0,4162	kanan
0,0960	0,5902	0,8851	0,4623	kanan
0,1725	0,5052	0,8096	0,4484	kanan
0,1921	0,5318	0,7777	0,3663	kanan
0,0456	0,6578	0,9339	0,4640	kanan
0,8135	0,5579	0,1295	0,5623	kiri
1	1	0	0,4121	kiri

5 KESIMPULAN DAN SARAN

Berdasarkan hasil pengujian yang telah dilakukan, menunjukkan bahwa parameter jumlah *hidden neuron*, *learning rate*, iterasi, dan *hidden layer* berpengaruh terhadap hasil implementasi metode *multilayer Backpropagation* pada klasifikasi pola pergerakan bola mata. Pada parameter jumlah *hidden neuron* dan *hidden layer*, semakin banyaknya *neuron* atau *layer* yang digunakan, maka akan semakin rumit arsitektur yang dibangun sehingga menyebabkan jaringan terlalu rumit dan terjadi *overfitting*. Selanjutnya pada parameter iterasi dan *learning rate*, semakin banyaknya jumlah iterasi dan besarnya nilai *learning rate*, maka tingkat akurasi yang didapatkan cenderung semakin meningkat. Akurasi yang paling optimal didapatkan dengan menggunakan 1 *hidden layer* dengan 11 *neuron*, nilai *learning rate* sebesar 0,7, dan jumlah iterasi sebanyak 100 iterasi yaitu sebesar 80,952%.

Saran yang diberikan agar penelitian lanjutan menghasilkan akurasi yang lebih baik yaitu diharapkan pada penelitian selanjutnya dapat mengumpulkan data yang lebih banyak dan *balance*. Hal ini berguna agar jaringan lebih baik dalam mengenali pola data sehingga dapat menghasilkan akurasi yang lebih baik. Selain itu diharapkan juga untuk menguji metode klasifikasi selain *multilayer*

Backpropagation untuk mengetahui metode klasifikasi mana yang paling cocok untuk kasus ini.

DAFTAR PUSTAKA

- CHAUDHURI, A., DASGUPTA, A., & ROUTRAY, A. 2012. Video & EOG Based Investigation of Pure Saccades in Human Subjects. doi:10.1109/IHCI.2012.6481872
- DEWI, A. K. 2016. Deteksi Gangguan pada Organ Lambung melalui Iris Mata dengan menggunakan Metode Jaringan Syaraf Tiruan Backpropagation. *Telkom University*, 3(1). doi:https://doi.org/10.30811/v1i1.286
- FAUSETT, L. V. 1994. *Fundamentals of Neural Networks: Architectures, Algorithms, and Applications*. Upper Sadle River, New Jersey: Prentice Hall. Retrieved Mei 17, 2021, from https://openlibrary.telkomuniversity.ac.id/pustaka/136000/fundamentals-of-neural-networks-architectures-algorithms-and-applications.html
- GREGORIUS, W. 2016. Deteksi Kesehatan Ginjal melalui Mata Menggunakan Metode Principal Component Analysis dan Jaringan Syaraf Tiruan Backpropagation. *Telkom University*, 3(1). Retrieved Mei 17, 2021, from https://openlibrary.telkomuniversity.ac.id/home/catalog/id/95955/slug/deteksi-kesehatan-ginjal-melalui-mata-menggunakan-metode-principal-component-analysis-dan-jaringan-syaraf-tiruan-backpropagation.html
- IMANUDDIN, I., ALHADI, F., OKTAFIAN, R., & IHSAN, A. 2019. Deteksi Mata Mengantuk pada Pengemudi Mobil menggunakan Metode Viola Jones. *Jurnal Matrik*, 18(2), 321-329. doi:https://doi.org/10.30812/matrik.v18i2.389
- KHOLILI, M. R., SETIAWAN, B. D., & WIHANDIKA, R. C. 2019. Implementasi Metode Jaringan Saraf Tiruan Backpropagation Pada Prediksi Payload 4G di Telkomsel Jember. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 3(4), 3838-3844. Retrieved Mei 17, 2021, from https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/5048
- KURMASELA, G. P., SAERANG, J. S., & RARES, L. 2013. Hubungan Waktu Penggunaan Laptop dengan Keluhan Penglihatan pada Mahasiswa Fakultas Kedokteran Universitas Sam Ratulangi. *Jurnal e-Biomedik (eBM)*, 1(1), 291-299. doi:https://doi.org/10.35790/ebm.1.1.2013.4361
- MAHARDIKA, A. N., WIDODO, A. W., & RAHMAN, M. A. 2020. Diagnosis Penyakit Mata menggunakan Metode Improved K-Nearest Neighbor. Retrieved from https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/6707
- MILLETARI, F., NAVAB, N., & AHMADI, S.-A. 2016. V-Net: Fully Convolutional Neural Networks for Volumetric Medical Image Segmentation. *2016 Fourth International Conference on 3D Vision (3DV)*. doi:https://doi.org/10.1109/3DV.2016.79
- NUGROHO, H. A., NASRUN, M., & NUGRAHAENI, R. A. 2018. Detektor Kebohongan dengan Analisa Gerakan Mata dan Jumlah Kedipan Mata menggunakan Metode Viola-Jones dan Jaringan Saraf Tiruan Backpropagation. *e-Proceeding of Engineering*, 5(3), 6134. Retrieved Mei 17, 2021, from https://openlibrarypublications.telkomuniversity.ac.id/index.php/engineering/article/view/7985
- NURCAHYA, E. D., PURNAMA, I. K., & PURNOMO, M. H. 2012. Ekstraksi Fitur Secara Otomatis untuk Pengenalan Pola Gerakan Mata. *Seminar Nasional Informatika 2012*, 1(1). Retrieved Oktober 15, 2020, from http://www.jurnal.upnyk.ac.id/index.php/semnasif/article/view/1001
- PANGESTU, G., & BACHTIAR, F. A. 2019. Eyeball Movement Detection Using Sector Line Distance Approach and Learning Vector Quantization. *5th International Conference on Science in Information Technology (ICSITech)*. doi:10.1109/ICSITech46713.2019.8987443
- PUSPASARI, R. 2011. Deteksi Semangat Hidup Seseorang Melalui Pengenalan Pola Iris Mata Berbasis Artificial Neural Network. *STMIK Potensi Utama*, 3, 23-38.
- ROCHMAD, M. 2015. Identifikasi Kerusakan Pankreas Melalui Iridology Menggunakan Metode Bayes Untuk Pengenalan Diabetes Mellitus. *Seminar Nasional Informatika (SEMNASIF)*, 1(1). Retrieved April 11, 2021, from http://jurnal.upnyk.ac.id/index.php/semnasif/article/view/800/679
- TRYANTO, B., NASRUN, M., & NUGRAHAENI, R. A. 2018. Detektor Kebohongan dengan Analisa Gerakan Mata dan Perubahan Diameter Pupil Berbasis Video Kamera Dan Image Processing Menggunakan Metode Haar Cascade Classifier dan Neural Network (Multilayer Perceptron). *Telkom University*, 5(3), 6139. Retrieved Mei 17, 2021, from https://openlibrarypublications.telkomuniversity.ac.id/index.php/engineering/article/view/7985

- rsity.ac.id/index.php/engineering/article/view/7989
- WURYANDARI, M. D., & AFRIANTO, I. 2012. Perbandingan Metode Jaringan Syaraf Tiruan Backpropagation Dan Learning Vector Quantization Pada Pengenalan Wajah. *Jurnal Komputer dan Informatika (KOMPUTA)*. Retrieved from http://komputa.if.unikom.ac.id/_s/data/jurnal/volume-01/komputa-1-1-perbandingan-metode-jaringan-irawan-7.pdf/pdf/komputa-1-1-perbandingan-metode-jaringan-irawan-7.pdf
- YIU, Y. H., ABOULATTA, M., RAISER, T., OPHEY, L., FLANAGIN, V. L., EULENBURG, P. Z., & AHMADI, S. A. 2019. DeepVOG: Open-source pupil segmentation and gaze estimation in neuroscience using deep learning. *Journal of Neuroscience Methods*, 324. doi:<https://doi.org/10.1016/j.jneumeth.2019.05.016>

Halaman ini sengaja dikosongkan