

INDIVIDUAL IDENTIFICATION BY IRIS USING HISTOGRAM OF ORIENTED GRADIENT (HOG) AND BACKPROPAGATION NEURAL NETWORK

Widya Alisyia Kusuma Ningrum^{*1}, Iwan Iwut Tritoasmoro², Sofia Saidah³

^{1,2,3}Program Studi S1 Teknik Telekomunikasi, Fakultas Teknik Elektro, Universitas Telkom, Indonesia
Email: ¹widyaalisya@student.telkomuniversity.ac.id, ²iwaniwut@telkomuniversity.ac.id,
³sofiasaidahsfi@telkomuniversity.ac.id

(Naskah masuk: 16 Agustus 2022, Revisi : 19 Agustus 2022, diterbitkan: 23 Maret 2023)

Abstract

The eye's iris biometrics is a type of biometric for individual identification that is more stable than other types of biometrics because a person's iris eye's has a delicate fiber pattern and unique characteristics. Especially with the rapid development of the times, the need for identity recognition systems is also increasing. Introducing individuals in traditional ways is still less effective than biometric systems because, compared to conventional methods, biometric systems are safer and are not easily stolen, imitated, or accessed by any unauthorized person. In this research has been carried out by designing a simulation system for individual identification through iris eyes images using the Histogram of Oriented Gradien (HOG) method for image extraction. They were continued with classification using Artificial Neural Network (ANN) Backpropagation. The dataset used is primary data taken directly through smartphone cameras from 30 individuals. Based on the test results and analysis of the Histogram of Oriented Gradien method using an image size of 128×128 pixels, parameters of Cell Size 16×16 cells, Bins Numbers 12, Size Block 2×2 cells, L2-Hys normalization scheme, and JST backpropagation classification with Random state value 1, Learning Rates 0.001, Epoch 200, Hidden Layer 100 with the system's sigmoid activation function can produce a performance system with the most significant performance accuracy of 91.93%, using 1500 training data and 1500 iris eyes image test data.

Keywords: Backpropagation Neural Network (BPNN), Biometrics, Histogram of Oriented Gradient, Iris eye's.

IDENTIFIKASI INDIVIDU MELALUI IRIS MATA DENGAN METODE HISTOGRAM OF ORIENTED GRADIENT (HOG) DAN JARINGAN SYARAF TIRUAN BACKPROPAGATION

Abstrak

Biometrik iris mata merupakan jenis biometrik untuk identifikasi individu yang terbukti lebih stabil dibandingkan dengan jenis biometrik lainnya, karena iris mata seseorang memiliki pola serat halus dan ciri khas yang unik. Perkembangan zaman yang semakin pesat, kebutuhan sistem pengenalan identitas juga semakin meningkat. Pengenalan individu dengan cara tradisional atau konvensional masih kurang efektif dibandingkan dengan sistem biometrik, karena dibandingkan dengan cara konvensional, sistem biometrik lebih aman dan tidak mudah dicuri atau ditiru maupun diakses oleh sembarang orang yang tidak sah. Dalam penelitian ini dilakukan perancangan sistem simulasi identifikasi individu melalui citra iris mata dengan menggunakan metode *Histogram of Oriented Gradient* (HOG) untuk ekstraksi ciri citra. Dilanjutkan dengan klasifikasi menggunakan Jaringan Syaraf Tiruan (JST) *Backpropagation*. Dataset yang digunakan adalah data primer yang diambil secara langsung melalui kamera *smartphone* dari 30 individu. Berdasarkan hasil pengujian dan analisis metode *Histogram of Oriented Gradient* menggunakan ukuran citra 128×128 piksel, parameter *Cell Size* 16×16 *cell*, *Bins Numbers* 12, *Size Block* 2×2 *cell*, skema normalisasi L2-Hys dan klasifikasi *JST backpropagation* dengan nilai *Random state* 1, *Learning Rates* 0.001, *Epoch* 200, *Hidden Layer* 100 dengan fungsi aktivasi sigmoid sistem mampu menghasilkan sistem kinerja dengan akurasi performansi terbesar 91.93%, dengan menggunakan 1500 data latih dan 1500 data uji citra iris mata.

Kata kunci: Biometrik, Histogram of Oriented Gradient, Iris mata, Jaringan Syaraf Tiruan Backpropagation.

1. PENDAHULUAN

Proses identifikasi individu suatu proses identifikasi yang sulit dilakukan jika menggunakan

metode konvensional biasa, karena dinilai kurang efektif. Perkembangan era teknologi khususnya di dunia digital telah membawa perubahan yang signifikan. Kebutuhan sistem pengenalan identitas juga semakin meningkat seperti sistem untuk autentikasi, keamanan, maupun untuk mengetahui identitas seseorang. Salah satu cara yang sering dimanfaatkan ialah teknologi pengolahan citra digital yang mampu mengidentifikasi individu berdasarkan pengenalan biometrik. Biometrik dikenal sebagai satu aplikasi dalam pengolahan gambar yang mengacu pada teknologi yang digunakan fisiologis atau perilaku karakteristik tubuh manusia untuk autentikasi pengguna [1]. Cara kerja teknologi biometrik ini dengan deteksi pola, sehingga sering digunakan sebagai sistem keamanan yang berguna untuk menjaga kerahasiaan data identitas seseorang [2]. Salah satu sistem biometrik yang digunakan dalam penelitian ini adalah melalui iris mata (*iris recognition*).

Dengan menggunakan biometrik iris mata untuk sistem identifikasi individu ini telah terbukti lebih stabil dibandingkan dengan jenis biometrik lainnya [3]. Hal ini karena iris memiliki pola yang khas dan unik yang melingkari pupil mata. Setiap individu memiliki pola tekstur serat halus iris mata yang berbeda, dan bersifat permanen tidak dapat berubah, bahkan tekstur serat pola iris mata kanan dan kiri setiap orang tidak sama. Pola iris yang unik ini juga berbeda walaupun seseorang tersebut kembar identik [4].

Untuk mengenali pola iris, dibutuhkan sistem yang dapat memproses pengenalan iris mata dengan teknik metode yang tepat. Beberapa penelitian terdahulu terkait topik yang sama telah dilakukan dengan ekstraksi fitur dan klasifikasi yang digunakan yaitu, metode *Convolutional Neural Network* (CNN) dan klasifikasi *K-Nearest Neighbor* (KNN) dengan tingkat akurasi 90% [5]. Metode *Compound Local Binary Pattern* (CLBP) dan klasifikasi *Support Vector Machine* (SVM) dan K-NN sebagai pembanding dengan akurasi sebesar 89,71% untuk klasifikasi SVM dan 90% untuk KNN [6]. Metode *Hamming Distance* dan algoritma Daugman dengan tingkat *Genuine Acceptance Rate* (GAR) sebesar 82,5% [7].

Pada penelitian ini dibangun suatu sistem yang memudahkan dalam pengenalan individu melalui iris mata, dan menganalisis performansi sistem yang dibangun, dan mengetahui parameter-parameter yang mempengaruhi sistem. Dengan menggunakan metode *Histogram of Oriented Gradient* (HOG) dan klasifikasi *Backpropagation Neural Network*. Pada tahun 2018 Metode *Histogram of Oriented Gradient* (HOG) telah diuji untuk pengujian pengenalan iris mata, hasil dari penelitian tersebut menyatakan bahwa metode ekstraksi ciri HOG ini sangat berpengaruh terhadap hasil pengenalan dengan tingkat akurasi sebesar 96% [8]. Untuk klasifikasi iris mata memakai metode Jaringan Syaraf Tiruan (JST)

Backpropagation. Metode ini banyak digunakan karena metode ini sederhana namun mampu menyelesaikan pelatihan yang kompleks, dan mudah untuk diimplementasikan serta memiliki tingkat akurasi yang tinggi pada penelitian [9].

2. METODE PENELITIAN

2.1. Histogram of Oriented Gradient

Histogram of Oriented Gradient (HOG) yaitu metode ekstraksi ciri yang cocok untuk deskriptor dalam *computer vision* dan pemrosesan gambar untuk deteksi objek [10]. Metode ini diperkenalkan oleh Naveet Dalal dan Bill Trigs pada tahun 2005. Tahapan pertama dalam metode ini yaitu menghitung nilai gradien per piksel pada area tertentu pada gambar. Dimana setiap ciri ditunjukkan oleh distribusi gradien. Dengan membagi citra menjadi daerah-daerah kecil yang disebut *cell* yang tersusun suatu histogram dari suatu gradien [11]. Tahapan pada ekstraksi ciri menggunakan HOG adalah sebagai berikut:

1. Menentukan ukuran blok dan *cell*

Pada tahapan ini mencari ukuran *block* serta ukuran *cell* pada sebuah citra. Suatu *cell* terdiri dari sebagian piksel, dimana misalkan 2×2, 4×4, 6×6, 8×8 dan lainnya. Sementara itu suatu ukuran *block* terdiri dari sebagian *cell* dan saling *overlapping* antar *block*. Misalnya ukuran *cell* 4×4 piksel dan ukuran *block* 2×2 *cell* atau 8×8 piksel [10].

2. Menghitung gradien citra

Agar intensitas ruang warna tidak ada perbedaan, terlebih dahulu mengkonversi gambar RGB ke gambar skala abu-abu. Sesudah diterapkan filtering citra *grayscale* [12]. Dilanjutkan dengan menghitung gradien horizontal dan vertikal pada setiap pikselnya dimana x dan y adalah gradien arah. Ditulis menggunakan rumus:

$$g_x = I(x + 1, y) - I(x - 1, y) \quad (1)$$

$$g_y = I(x, y + 1) - I(x, y - 1) \quad (2)$$

Dengan nilai piksel citra *grayscale* yaitu I . lalu mencari nilai gradien *magnitude* (m) dan nilai gradien orientasi (θ) dengan operasi sebagai berikut:

$$|m(x, y)| = \sqrt{(g_x)^2 + (g_y)^2} \quad (3)$$

$$\theta(x, y) = \tan^{-1}\left(\frac{g_y}{g_x}\right) \quad (4)$$

3. Menentukan *bin* orientasi

Menentukan perhitungan *bin* orientasi sangat diperlukan untuk mengkalkulasi bobot tiap piksel pada tepi-tepi orientasi histogram. Rentang nilai orientasi tiap piksel dikuantisasi menjadi 9 kanal dimana direpresentasikan dalam sudut dengan selisih

20°, yaitu 0°, 20°, 40°, 60°, 80°, 100°, 120°, 140°, 160° dan 180°.

4. Melakukan normalisasi blok

Tahapan terakhir ini yaitu melakukan normalisasi blok. Dimana proses dari normalisasi blok yaitu membagi masing-masing elemen vektor dengan panjang vektor hingga menghasilkan vektor satuannya. Dengan menggunakan operasi sebagai berikut:

$$V_n = \frac{v}{\sqrt{|v| + \epsilon}} \quad (5)$$

Dimana V_n adalah vektor gradien yang sudah dinormalisasi, v vektor gradien yang belum ternormalisasi, ϵ yaitu koefisien < 1 atau konstanta normalisasi untuk menghindari pembagi oleh nol, dan $|v|$ hasil mutlak dari nilai gradien.

2.2. Backpropagation

Backpropagation atau propagasi balik merupakan metode pelatihan dari jaringan syaraf tiruan. *Backpropagation* menggunakan arsitektur multilayer dengan metode *supervised training* [13]. Dengan menguji kontribusi kesalahan masing-masing *neuron* setelah satu set data diproses [14]. *Backpropagation* digunakan untuk memodifikasi bobot sehingga dapat melatih jaringan syaraf tiruan untuk menggambarkan *input* dengan benar ke *output* [15]. Pada pelatihan *backpropagation* meliputi tiga tahapan. Dimana tahapan ini akan diulang hingga kondisi penghentiannya seperti jumlah *epoch* terpenuhi [16]. Tahapan algoritma pelatih *backpropagation* yaitu sebagai berikut [17]:

1. Fase propagasi maju

Pada fase ini perhitungan pola *input* dimulai berdasarkan *input layer* sampai hasil *output layer*. Dimana tujuan dari propagasi maju yaitu untuk menghitung kesalahan antara *output* dengan target yang dicapai.

2. Fase propagasi mundur

Fase propagasi mundur digunakan untuk menghitung dan mencari nilai *error* dari lapisan keluaran yang menuju lapisan tersembunyi. *Error* yang terjadi antara *output* dengan sasaran dipropagasi mundur berdasarkan *neuron* yang terhubung langsung dengan bagian di dalam *output layer*.

3. Fase modifikasi bobot

Tahapan terakhir yaitu menentukan secara random nilai bobot antar *layer* yang sudah diketahui. Dengan menurunkan bobot *neuron* yang mengarah ke lapisan keluaran terhadap selisih pada unit *output*. Fase modifikasi bobot akan menghasilkan bobot-bobot baru yang disimpan untuk pengujian jaringan.

3. HASIL DAN PEMBAHASAN

Model sistem pada penelitian ini memaparkan secara umum terkait perancangan sistem perangkat lunak (*software*) untuk identifikasi individu melalui

citra biometrik iris mata. Dimana masukan sistem berupa citra iris mata berukuran 950×950, lalu masuk ke tahap *preprocessing*. Kemudian tahap ekstraksi ciri *Histogram of Oriented Gradient*. Lalu terakhir tahap klasifikasi menggunakan jaringan syaraf tiruan *backpropagation*. Dapat dilihat desain perancangan sistem pada Gambar 3.1 sebagai berikut:



Gambar 3. 1 Diagram umum desain sistem

Pengujian sistem dilakukan untuk mengetahui apakah sistem yang telah dirancang dapat melakukan pengenalan dengan baik dari hasil fokus sistem berdasarkan parameter yang telah ditentukan. Parameter yang memiliki hasil akurasi terbaik akan digunakan untuk pemilihan parameter berikutnya. Berikut adalah hasil pengujian sistem dari skenario:

3.1. Skenario Pengujian Cell Size pada HOG

Pada tahap ini dilakukan pengujian pengaruh parameter *Cell Size* dengan ukuran size citra 128×128 menggunakan parameter lainnya, dengan *default Block Size* 2×2, Bins 9, *Block Normalisasi L2-Hys* yang kemudian dimasukkan ke dalam model *machine learning Backpropagation* dengan inisial *weight* menggunakan *random_state* 1. Ukuran *cell* yang dicoba yaitu 2×2, 4×4, 8×8, dan 16×16. Hasil pemilihan dari pengujian dapat dilihat pada Tabel 1.

Tabel 1. Performansi pengujian *cell size* pada HOG

Cell size	Akurasi (%)	Waktu Komputasi (s)
2×2 piksel	53.266	889.775
4×4 pikse	67.866	337.750
8×8 piksel	86.733	97.303
16×16 piksel	88.733	34.242

Dapat dilihat pada Tabel hasil pemilihan parameter ukuran *cell* bahwa akurasi terbesar didapat oleh ukuran *cell* 16×16 piksel dengan akurasi sebesar 88.733% dan waktu komputasi 34.242 detik. Sedangkan pada ukuran *cell* 2×2 memiliki tingkat akurasi terendah sebesar 53.266% dengan waktu komputasi yang lebih lama sebesar 889.775 detik. Hal ini terjadi karena semakin kecil ukuran *cell* maka semakin banyak informasi ciri dari *cell* yang hilang dengan waktu komputasi yang lama. Sedangkan pada ukuran *cell* 16×16 akan menghasilkan jumlah fitur yang banyak sehingga akurasinya lebih tinggi dengan waktu komputasi yang lebih rendah.

3.2. Skenario Pengujian Bin Size pada HOG

Pada tahap skenario ini dilakukan pengujian pengaruh parameter *Bins Numbers*. Jumlah bin yang digunakan pada pengujian yaitu 9, 12, 15, 18, 24, dan 30 dengan ukuran citra 128×128, *Cell Size* 16×16, *Block Size* 2×2, *Block Normalisasi L2-Hys* yang kemudian dimasukkan ke dalam model *machine learning Backpropagation* dengan inisial *weight*

menggunakan *random_state* 1. Hasil pemilihan pengujian parameter bins dapat dilihat pada Tabel 2.

Tabel 2. Performansi pengujian *bin numbers* pada HOG

Bin Numbers	Akurasi (%)	Waktu Komputasi (s)
9	88.733	34.178
12	91.400	38.835
15	90.800	48.008
18	90.266	50.986
24	90.266	59.218
30	90.533	67.450

Dapat dilihat pada Tabel dari hasil pemilihan parameter jumlah bins menunjukkan bahwa akurasi tertinggi didapat oleh jumlah bins 12 dengan akurasi sebesar 91.400% dan waktu komputasi 38.835 detik, sedangkan akurasi terendah didapat oleh jumlah bins 9 dengan akurasi sebesar 88.733% dan waktu komputasi 34.178 detik. Pada jumlah bins diatas 12 memiliki selisih akurasi yang cukup dekat.

3.3. Skenario Pengujian *Block Size* pada HOG

Pada tahap skenario ini dilakukan pengujian pengaruh parameter *Block Size*. Ukuran *Block Size* yang digunakan pada pengujian yaitu 1×1, 2×2, dan 4×4, dengan ukuran citra 128×128, *Cell Size* 16×16, *Bins Numbers* 12, Panjang *block* Normalisasi L2-Hys yang kemudian dimasukkan ke dalam model *machine learning Backpropagation* dengan inisial *weight* menggunakan *random_state* 1. Hasil pemilihan pengujian parameter *Block Size* dapat dilihat pada Tabel 3.

Tabel 3. Performansi pengujian blok *size* pada HOG

Block Size	Akurasi (%)	Waktu Komputasi (s)
1×1 cell	83.133	17.157
2×2 cell	91.400	40.889
4×4 cell	88.866	62.134

Dapat dilihat pada Tabel 3 dari hasil pemilihan pengujian parameter *Block Size* menunjukkan bahwa akurasi tertinggi didapat pada ukuran *Block* 2×2 dengan tingkat akurasi sebesar 91.400% dan waktu komputasi 40.889. Pada ukuran *Block* 1×1 memiliki akurasi terendah sebesar 83.133% dan waktu komputasi 17.157 detik. Hal ini terjadi karena *block size* 2×2 dapat menangkap perbedaan piksel dengan baik. Sedangkan *block size* 1×1 kurang mampu menangkap perbedaan piksel dengan baik.

3.4. Skenario Pengujian Panjang *Block Normalisasi*

Pada tahap skenario terakhir ini dilakukan pengujian pengaruh skema panjang *Block* Normalisasi. Skema normalisasi yang diujikan pada penelitian ini yaitu panjang L1-Norm, panjang L1-Sqrt, panjang L2-Norm, dan panjang L2-Hys, dengan ukuran citra 128×128, *Cell Size* 16×16, *Bin Number* 12, *Block Size* 2×2, yang kemudian dimasukkan ke dalam model *machine learning Backpropagation* dengan inisial *weight* menggunakan *random_state* 1.

Hasil pemilihan pengujian skema *Block* Normalisasi dapat dilihat pada Tabel 4.

Tabel 4. Performansi pengujian skema normalisasi pada HOG

Normalization Block Scheme	Akurasi (%)	Waktu Komputasi (s)
L1-Norm	88.733	39.709
L1_sqrt	87.866	40.335
L2-Norm	90.466	34.980
L2-Hys	91.400	39.944

Dapat dilihat pada Tabel dari hasil pemilihan skema *Block* Normalisasi menunjukkan bahwa akurasi tertinggi didapat oleh skema L2-Hys dengan tingkat akurasi sebesar 91.400% dan waktu komputasi 39.944 detik. Pemilihan skema L2-Hys ini dapat meningkatkan akurasi kinerja sistem.

3.5. Analisis akurasi BPNN terhadap *random state*

Pada tahap pengujian ini akan dilihat pengaruh *Random State* terhadap akurasi dan waktu komputasi sistem. Banyaknya nilai *Random State* yang diujikan pada penelitian ini yaitu: 1, 2, 7, dan 10. Untuk parameter lainnya yaitu: *cell size* 16×16, *block size* 2×2, *bin numbers* 12, *block* normalisasi L2-Hys, *learning rates* 0,001, *epoch* 200, *hidden layer* satu dengan jumlah neuron 100, dan fungsi aktivasi relu. Dari hasil pengujian keempat nilai *random state* didapat hasil performansi seperti pada Tabel 5.

Tabel 5. Pengaruh nilai *random state* terhadap performansi sistem

Random State	Akurasi (%)	Waktu Komputasi (s)
1	91.400	40,277
2	90,200	47,710
7	89,666	44,777
10	90,066	43,696

Dapat dilihat pada Tabel bahwa nilai akurasi tertinggi didapatkan pada nilai *random state* 1 sebesar 91.400% dengan waktu komputasi 40.277 detik. Untuk nilai akurasi terendah yaitu pada *random state* 7 dengan nilai akurasi sebesar 89.666% dan waktu komputasi 44.777 detik.

3.6. Analisis akurasi BPNN terhadap *learning rates*

Pada tahap ini dilakukan pengujian nilai *learning rates* terhadap akurasi dan waktu komputasi sistem. Nilai *learning rates* yang akan diujikan pada penelitian ini yaitu: 0.1, 0.01, 0.001 dan 0.0001. Menggunakan parameter lainnya yaitu: *cell size* 16×16, *block size* 2×2, *bin numbers* 12, *block* normalisasi L2-Hys, *random state* 1, *epoch* 200, *hidden layer* satu dengan jumlah neuron 100, dan fungsi aktivasi relu. Dari hasil pengujian keempat nilai *learning rates* yang diujikan didapat hasil performansi seperti pada Tabel 6.

Tabel 6. Pengaruh nilai *learning rate* terhadap performansi sistem

Learning Rates	Akurasi (%)	Waktu Komputasi (s)
----------------	-------------	---------------------

0,1	33,333	24,162
0,001	91,400	39,859
0,0001	86,600	43,009
0,00001	44,333	45,635

Dapat dilihat pada Tabel bahwa performansi terbaik didapatkan saat nilai *learning rates* 0.001 sebesar 91.400% dengan waktu komputasi 39.859 detik. Sedangkan nilai *learning rates* dengan nilai akurasi terendah saat 0.1 sebesar 33.333% dan waktu komputasi 24.162 detik. Hal ini terjadi karena saat *learning rate* 0.001 ketelitian jaringan akan semakin besar dan bertambah sehingga menghasilkan akurasi yang besar dengan waktu komputasi yang lebih lama.

3.7. Analisis akurasi BPNN terhadap jumlah epoch

Pada tahap ini dilakukan pengujian jumlah *epoch* terhadap nilai akurasi dan waktu komputasi sistem. Jumlah *epoch* yang diujikan pada penelitian ini yaitu: 10, 50, 100, dan 200. Menggunakan parameter lainnya yaitu: *cell size* 16×16, *block size* 2×2, *bin numbers* 12, *block* normalisasi L2-Hys, *random state* 1, *learning rates* 0.001, *hidden layer* 100, dan fungsi aktivasi relu. Dari hasil pengujian keempat jumlah *epoch* ini didapat hasil performansi pada Tabel 7.

Tabel 7. Pengaruh jumlah *epoch* terhadap performansi sistem

Epoch	Akurasi (%)	Waktu Komputasi (s)
10	66.000	8.316
50	89.000	16.102
100	90.666	25.574
200	91.400	39.883

Dapat dilihat bahwa hasil akurasi performansi terbaik didapatkan saat jumlah *epoch* 200 sebesar 91.400% dengan waktu komputasi 39.883 detik. Sedangkan saat jumlah *epoch* 10 memiliki performa yang rendah sebesar 66.000% dan waktu komputasi 8.316.

3.8. Analisis akurasi BPNN terhadap jumlah hidden layer

Pada tahap ini dilakukan pengujian jumlah *Hidden Layer* terhadap nilai akurasi dan waktu komputasi. Jumlah *Hidden Layer* yang diujikan pada penelitian ini untuk 3 buah *layer hidden layer* dengan nilai [100 50 30], untuk 2 buah *layer hidden layer* dengan nilai [26 25], [20 30], dan untuk 1 buah *layer hidden layer* dengan nilai [100]. Menggunakan parameter lainnya yaitu: *cell size* 16×16, *block size* 2×2, *bin numbers* 12, *block* normalisasi L2-Hys, *random state* 1, *learning rates* 0.001, *epoch* 200, dan fungsi aktivasi relu. Dari hasil pengujian jumlah *hidden layer* dapat dilihat pada Tabel 8.

Tabel 8. Pengaruh jumlah *hidden layer* terhadap performansi sistem

Hidden layer	Akurasi (%)	Waktu Komputasi (s)
[100 50 30]	81.933	41.310
[26 25]	80.933	22.854

[20 30]	77.400	17.251
[100]	91.400	40.708

Dapat dilihat bahwa nilai performansi akurasi terbaik didapatkan saat menggunakan 1 buah *layer* dengan jumlah *hidden layer* satu dengan nilai neuron [100] dengan nilai akurasi 91.400% namun dengan waktu komputasi yang lama sebesar 40.708. Untuk akurasi terendah yaitu saat menggunakan 2 buah *layer* dengan jumlah *hidden layer* dua dengan nilai neuron [20 30] sebesar 77.400% dengan waktu komputasi 17.251 detik yang lebih cepat.

3.9. Analisis akurasi BPNN terhadap fungsi aktivasi

Pada tahap ini dilakukan pengujian Fungsi Aktivasi terhadap nilai akurasi dan waktu komputasi. Fungsi Aktivasi yang diujikan pada penelitian ini yaitu: fungsi aktivasi *logsig*, *tansig*, dan ReLu. Menggunakan parameter lainnya yaitu: *cell size* 16×16, *block size* 2×2, *bin numbers* 12, *block* normalisasi L2-Hys, *random state* 1, *learning rates* 0.001, *epoch* 200, dan *hidden layer* 100. Dari hasil pengujian Fungsi Aktivasi dapat dilihat pada Tabel 9.

Tabel 9. Pengaruh fungsi aktivasi terhadap performansi sistem

Activation Function	Akurasi (%)	Waktu Komputasi (s)
Logsig	91,933	40,581
Tansig	91,666	33,135
ReLu	91,400	43,554

Dapat dilihat bahwa nilai akurasi rata-rata yang dihasilkan pada pengujian ini sebagian besar sudah diatas 90%. Akurasi pengujian parameter fungsi aktivasi *logsig* mendapatkan nilai akurasi terbaik dibandingkan dengan fungsi aktivasi *tansig* dan ReLu. Dengan nilai akurasi sebesar 91.933% dan waktu komputasi 40.548 detik. Sehingga performansi sistem yang dihasilkan juga semakin baik.

4. DISKUSI

Dilakukan analisis terhadap parameter *cell size*, *bins numbers*, *block size*, skema normalisasi pada ekstraksi ciri HOG. Pencarian parameter terbaik yang mempengaruhi hasil performansi sistem dalam menghasilkan fitur ciri terbaik yaitu dengan menggunakan size citra 128×128, *cell size* 16×16 piksel, *bins numbers* 12, *block size* 2×2 *cell*, dan skema normalisasi L2-Hys. Menghasilkan akurasi tertinggi sebesar 91.400%. Pada klasifikasi *Backpropagation Neural Network* pencarian parameters terbaik yaitu dengan menggunakan nilai *random_state* 1, *learning rate* 0.001, *epoch* 200, *hidden layer* satu dengan jumlah neuron 100, dan fungsi aktivasi *logsig* menghasilkan hasil performansi sistem terbaik sebesar 91,933%. Penelitian [6] dengan topik yang sama melakukan pengujian dengan menggunakan size citra 32×32, dengan ekstraksi ciri *Compound Local Binary Pattern* dan klasifikasi Support Vector Machine menghasilkan

akurasi sebesar 90%. Dilihat dari analisis berikut ini terbukti bahwa performansi akurasi sistem yang dibangun pada penelitian ini memiliki akurasi tetinggi. Semakin besar ukuran citra maka informasi yang di dapat juga semakin banyak. Selain itu penggunaan metode HOG sebagai ekstrasi ciri cocok untuk menghasilkan ciri fitu iris mata dibandingkan dengan metode ekstrasi ciri CLBP dan klasifikasi SVM.

5. KESIMPULAN

Berdasarkan hasil analisis pada pengujian yang sudah dilakukan pada sistem identifikasi individu melalui iris mata dengan metode HOG dan JST *backpropagation*. Sistem berhasil mengidentifikasi iris mata individu dengan menggunakan parameter ekstrasi ciri terbaik HOG pada ukuran *cell* 16×16 piksel, jumlah bin 12, ukuran *block* 2×2 cell dan skema panjang normalisasi L2-Hys. Menggunakan parameter terbaik metode klasifikasi JST *backpropagation* pada nilai *random state* 1, *learning rate* 0.001, *epoch* 200, *hidden layer* satu dengan jumlah neuron 100, dan fungsi aktivasi *logsig*.

Kinerja terbaik performansi sistem dalam mengidentifikasi individu melalui iris mata yang didapatkan dari semua pengujian mencapai akurasi sebesar 91,93% dengan waktu komputasi 40,548 detik. Dengan 1.379 data teridentifikasi benar dan 121 data teridentifikasi salah. Hal ini terbukti bahwa penggunaan metode HOG dan JST *backpropagation* dalam penelitian ini menghasilkan akurasi yang sangat memuaskan.

DAFTAR PUSTAKA

- [1] M. M. H. Ali, "Study Of Edge Detection Methods Presented by," no. August, 2018, doi: 10.13140/RG.2.2.20662.60482.
- [2] N. D. Miranda, L. Novamizanti, and S. Rizal, "Convolutional Neural Network Pada Klasifikasi Sidik Jari Menggunakan Resnet-50," *J. Tek. Inform.*, vol. 1, no. 2, pp. 61–68, 2020, doi: 10.20884/1.jutif.2020.1.2.18.
- [3] J. Daugman and C. Downing, "Broken symmetries, random morphogenesis, and biometric distance," *IEEE Trans. Biometrics, Behav. Identity Sci.*, vol. 2, no. 3, pp. 271–278, 2020, doi: 10.1109/TBIOM.2020.2993225.
- [4] S. Sujana and D. V. Reddy, "An Effective CNN based Feature Extraction Approach for Iris Recognition System," *Turkish J. Comput. Math. Educ.*, vol. 9, no. 1, pp. 1–5, 2021, doi: 10.17485/ijst/2016/v9i47/106827.
- [5] O. Visaliny *et al.*, "Pengenalan Iris Mata Manusia Menggunakan Metode Klasifikasi K- Nearest Neighbor (Knn) Human Iris Recognition Using K-Nearest Neighbor (Knn) Classification Methods."
- [6] G. S. F. Wahid, R. Purnamasari, and S. Saidah, "Identifikasi Personal Melalui Iris Mata Dengan Menggunakan Metode Compound Local Binary Pattern Dan Klasifikasi Support Vector Machine Personal Identification Based on Compound Local Binary," *JEPIN (Jurnal Edukasi dan Penelit. Inform.*, vol. 6, no. 2, pp. 3959–3966, 2019.
- [7] A. Rezika, Ernawati, and A. Elansari, "Identifikasi pola iris mata dengan algoritme daugman dan metode hamming distance," *Rekursif J. Inform.*, vol. 6, no. 2, 2018.
- [8] S. Devella, "Pengenalan Iris menggunakan Ekstraksi Fitur Histogram of Oriented Gradient," *J. Tek. Inform. dan Sist. Inf.*, vol. 4, pp. 124–134, 2018.
- [9] M. A. Abuzneid, A. Mahmood, and S. Member, "Enhanced Human Face Recognition Using LBPH Descriptor , Multi-KNN , and Back-Propagation Neural Network," *IEEE Access*, vol. 6, pp. 20641–20651, 2018, doi: 10.1109/ACCESS.2018.2825310.
- [10] T. Surasak, I. Takahiro, C. H. Cheng, C. E. Wang, and P. Y. Sheng, "Histogram of oriented gradients for human detection in video," *Proc. 2018 5th Int. Conf. Bus. Ind. Res. Smart Technol. Next Gener. Information, Eng. Bus. Soc. Sci. ICBIR 2018*, no. 2006, pp. 172–176, 2018, doi: 10.1109/ICBIR.2018.8391187.
- [11] W. Zhou, S. Gao, L. Zhang, and X. Lou, "Histogram of Oriented Gradients Feature Extraction from Raw Bayer Pattern Images," *IEEE Trans. Circuits Syst. II Express Briefs*, vol. 67, no. 5, pp. 946–950, 2020, doi: 10.1109/TCSII.2020.2980557.
- [12] S. Nigam, R. Singh, and A. K. Misra, "Efficient facial expression recognition using histogram of oriented gradients in wavelet domain," *Multimed. Tools Appl.*, vol. 77, no. 21, pp. 28725–28747, 2018, doi: 10.1007/s11042-018-6040-3.
- [13] A. Irianti, P. H. Rantelinggi, A. Taufik, and N. Zulkarnaim, "Implementation Of Backpropagation Artificial Neural Network For Food Price Prediction In Majene Central Market," *J. Tek. Inform.*, vol. 3, no. 3, pp. 681–688, 2022.
- [14] U. Shruthi, V. Nagaveni, and B. K. Raghavendra, "A Review on Machine Learning Classification Techniques for Plant Disease Detection," *2019 5th Int. Conf. Adv. Comput. Commun. Syst. ICACCS 2019*, pp. 281–284, 2019, doi: 10.1109/ICACCS.2019.8728415.
- [15] J. Amrutha and A. S. Remya Ajai, "Performance analysis of backpropagation

- algorithm of artificial neural networks in verilog,” *2018 3rd IEEE Int. Conf. Recent Trends Electron. Inf. Commun. Technol. RTEICT 2018 - Proc.*, pp. 1547–1550, 2018, doi: 10.1109/RTEICT42901.2018.9012614.
- [16] R. A. Surya, A. Fadlil, and A. Yudhana, “Identification of Pekalongan Batik Images Using Backpropagation Method,” *J. Phys. Conf. Ser.*, vol. 1373, no. 1, 2019, doi: 10.1088/1742-6596/1373/1/012049.
- [17] T. P. Lillicrap, A. Santoro, L. Marris, C. J. Akerman, and G. Hinton, “Backpropagation and the brain,” *Nat. Rev. Neurosci.*, vol. 21, no. 6, pp. 335–346, 2020, doi: 10.1038/s41583-020-0277-3.