

# *Identifikasi Sinyal EEG dari Pasien Pasca-Stroke Menggunakan Backpropagation dan Algoritma Genetika*

Mita Amara<sup>1</sup>, Esmeralda C. Djamal, Asri Maspupah S.

Jurusan Informatika  
Fakultas Sains dan Informatika  
Cimahi - Indonesia  
mitaamara75@gmail.com

Daswara Djajasasmita  
Fakultas Kedokteran  
Universitas Jenderal Achmad Yani  
Cimahi - Indonesia

**Abstrak**—Rehabilitasi terhadap pasien pasca-stroke dilakukan guna mengembalikan fungsi tubuh yang hilang. Pendekatan pada rehabilitasi stroke mencakup aktivitas fisik motorik, kognitif dan mental. Aktivitas listrik di otak yang direkam atau Elektroensefalogram (EEG) juga dapat digunakan dalam proses rehabilitasi untuk mengetahui perkembangan pasien. Dokter akan mengamati sinyal EEG yang direkam berdasarkan kerapatan, amplitudo, bentuk gelombang dan perbandingan sinyal pada setiap kanal, namun analisa tersebut tidaklah mudah. Oleh karena itu dibutuhkan model komputasi yang dapat mengidentifikasi sinyal EEG dari pasien pasca-stroke. Sinyal EEG diperoleh dari 50 pasien pasca-stroke, 25 orang normal menggunakan emotiv EEG 14 kanal. Sinyal EEG selama 120 detik dengan segmentasi per-tiga detik dan ekstraksi sinyal untuk mendapatkan gelombang Alfa, Beta, Teta, Delta dan Mu. Identifikasi dilakukan menggunakan Backpropagation dengan fitur masukkan kelima gelombang dan amplitudo. Pelatihan pada Backpropagation menggunakan bobot awal hasil optimalisasi Algoritma Genetika. Hal tersebut akan berpengaruh pada bobot akhir masing-masing kelas, no stroke, minor stroke dan moderate stroke. Representasi kromosom terdiri dari bobot  $v$  dan  $w$  sebanyak 46.224 gen dengan mengadopsi banyaknya neuron input dan hidden pada arsitektur Backpropagation. Individu terbaik hasil optimalisasi menjadi masukkan untuk proses pelatihan pada Backpropagation. Hasil penelitian menunjukkan akurasi yang diperoleh untuk data latih sebesar 73% dan untuk data baru sebesar 55%.

**Kata kunci**— *stroke; identifikasi sinyal eeg; ekstraksi wavelet; algoritma genetika; backpropagation*

## I. PENDAHULUAN

Stroke adalah kondisi ketika pasokan darah ke otak terganggu akibat penyumbatan atau pecahnya pembuluh darah. Stroke tidak hanya menjadi penyakit yang dapat menyerang fisik sehingga menyebabkan kecacatan, namun juga mental penderita. Hal tersebut membuat pasien pasca-stroke membutuhkan rehabilitasi guna mengembalikan fungsi tubuh semula. Pendekatan pada rehabilitasi stroke mencakup aktivitas fisik motorik, kognitif dan mental. *Monitoring* pada tahap rehabilitasi dilakukan oleh dokter untuk mengetahui perkembangan pasien.

Elektroensefalogram (EEG) merupakan suatu kegiatan untuk merekam aktivitas listrik di otak selama periode tertentu. EEG akan merepresentasikan aktivitas listrik di otak dalam bentuk garis gelombang. Sinyal EEG yang direkam menghasilkan informasi mengenai fitur, frekuensi dan gelombang pada pasien stroke [1]. Sinyal EEG terdiri dari beberapa gelombang dengan masing-masing frekuensi seperti Delta (1-4 Hz), Teta (4-8 Hz), Alfa (8-12 Hz), Beta (12-30 Hz) dan Gama (>30 Hz). Analisis sinyal EEG menghasilkan frekuensi dengan rentang 0-30 Hz pada pasien stroke untuk pemulihan. Sehingga gelombang yang digunakan untuk pasien stroke yaitu Delta, Teta, Alfa dan Beta [2] [3].

Berdasarkan skala untuk menentukan indikasi stroke pada pasien diperlukan sistem yang menjadi tolak ukur. Salah satunya menggunakan sistem *skoring* National Institutes of Health Stroke Scale (NIHSS). Skor NIHSS <20 mengindikasikan stroke dalam tingkat ringan. Skor NIHSS  $\geq$ 20 mengindikasikan stroke dalam tingkat menengah [1].

Sinyal EEG adalah sinyal *non-stasioner* dimana frekuensi berubah seiring perubahan waktu. Sinyal EEG pada pasien stroke yang direkam selama periode tertentu tidak semuanya diperlukan. Oleh karena itu, sinyal EEG harus melalui proses ekstraksi sinyal. Salah satu metode ekstraksi yang dapat digunakan yaitu Wavelet untuk mendapatkan gelombang Alfa, Beta, Teta, Gama dan Mu [4].

Identifikasi menggunakan Backpropagation telah dilakukan pada beberapa penelitian terdahulu dengan kombinasi metode lain seperti Algoritma Genetika. Algoritma Genetika digunakan untuk memperoleh bobot awal yang optimal [5] [6]. Bobot awal yang optimal berpengaruh menurunkan tingkat kesalahan [7] dan meningkatkan akurasi dari 77% menjadi 84% untuk optimalisasi arsitektur jaringan saraf tiruan [8]. Pada penelitian lain Algoritma Genetika digunakan sebagai model untuk optimalisasi nilai parameter, jumlah neuron dan jumlah kelas dari masing-masing dataset [9].

Penelitian ini bertujuan membuat model komputasi yang dapat mengidentifikasi sinyal EEG pada pasien pasca-stroke menggunakan Backpropagation dan Algoritma Genetika.

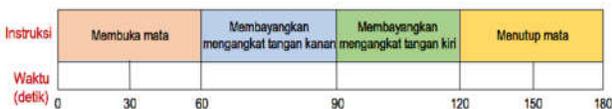
Bobot awal pelatihan dari *input layer* ke *hidden layer* dan dari *hidden layer* ke *output layer* pada Backpropagation diperoleh dari hasil optimalisasi menggunakan Algoritma Genetika. Hasil identifikasi sinyal EEG pada pasien pasca-stroke terdiri dari tiga kelas yaitu no stroke, minor stroke dan moderate stroke. Hal tersebut dikarenakan akuisisi data sinyal EEG pada pasien dilakukan pada posisi duduk rileks, sehingga ketiga kelas tersebut yang memungkinkan untuk digunakan. Sinyal EEG diekstraksi menggunakan Wavelet untuk mendapatkan gelombang Alfa, Beta, Teta, Delta dan Mu. Hasil ekstraksi sinyal EEG kelima gelombang dan perubahan amplitudo menjadi fitur masukkan pada proses identifikasi. Identifikasi dilakukan terhadap 50 pasien pasca stroke di RS Al-Islam dan 25 orang normal.

## II. METODE

### A. Akuisisi Data

Pada penelitian ini digunakan data hasil perekaman sinyal EEG pasien pasca-stroke di Rumah Sakit Al-Islam Bandung. Perekaman menggunakan *wireless* EEG Emotiv 14 kanal dengan frekuensi *sampling* 128 Hz. Perekaman dilakukan dengan naracoba sebanyak 75 naracoba, dimana 60 naracoba sebagai data latih dan 15 naracoba sebagai data uji.

Pengambilan data diambil pada saat pasien melakukan rehabilitasi stroke. Perekaman dilakukan dalam posisi duduk dan menghadap layar *monitor* yang kemudian dirangsang dengan instruksi pada video selama tiga menit. Menit pertama pasien diinstruksikan untuk membuka mata dan melihat layar *monitor*. Menit kedua terdiri dari dua instruksi, 30 detik pertama pasien diinstruksikan membayangkan mengangkat tangan kanan, 30 detik berikutnya pasien diinstruksikan membayangkan mengangkat tangan kiri. Menit ketiga pasien diinstruksikan menutup mata. Keseluruhan instruksi yang diberikan pada pasien dan orang normal diperlihatkan pada Gambar 1.



Gambar 1. Skenario Perekaman

Sinyal EEG yang berhasil direkam disimpan dalam bentuk *.csv*. Data yang diperoleh dalam satu set data latih sebanyak 322.560 titik data yang dihasilkan dari perkalian frekuensi *sampling* 128 Hz, durasi perekaman 3 menit dan 14 kanal pada alat EEG. 14 kanal pada alat EEG terdiri dari AF3, F7, F3, FC5, T7, O1, O2, P8, T8, FC6, F4, F8 dan AF4.

### B. Praproses

#### 1) Segmentasi

Segmentasi adalah proses membagi data menjadi beberapa bagian. Segmentasi dilakukan untuk membagi data sinyal menjadi 3 detik.

#### 2) Ekstraksi Wavelet

Seminar Nasional Aplikasi Teknologi Informasi (SNATi) 2019  
Yogyakarta, 03 Agustus 2019

Ekstraksi adalah proses mengambil gelombang Delta, Teta, Alfa, Mu dan Beta dari sinyal asli.

### C. Wavelet

Wavelet merupakan metode ekstraksi yang merepresentasikan informasi frekuensi sinyal dan waktu. Dua proses yang dilakukan pada ekstraksi Wavelet yaitu dekomposisi dan rekonstruksi. Proses dekomposisi dilakukan untuk mengekstraksi sinyal. Proses rekonstruksi dilakukan untuk mengembalikan sinyal ke dalam domain waktu.

Pada proses wavelet sinyal yang dihasilkan terbagi menjadi dua yaitu aproksimasi dan detil. Aproksimasi adalah sinyal yang diperoleh dari proses konvolusi sinyal asli terhadap *low-pass filter*, sedangkan detil adalah sinyal yang diperoleh dari proses konvolusi sinyal asli terhadap *high-pass filter* [10]. Aproksimasi dan detil dapat dilihat pada Persamaan 1 dan 2.

$$\frac{1}{\sqrt{|s|}} \left( \frac{\sigma, \tau}{\sigma} \right) \text{Aproksimasi } x[n].g[2k - n]$$

$$\text{Detail } x[n].h[2k - n]$$

dimana :

$x(n)$  = sinyal asli

$g(n)$  = koefisien *low-pass filter*

$h(n)$  = koefisien *high-pass filter*

$k, n$  = index 1 – panjang sinyal asli

Pada penelitian ini menggunakan Wavelet Symlet 3 yang memiliki enam koefisien pada *low-pass filter* dan enam koefisien pada *high-pass filter* seperti pada Tabel 1.

TABEL 1. KOEFISIEN WAVELET SYMLET3

Aproksimasi g(n)		Detil h(n)	
g(0)	0,035226292	h(0)	-0,332670553
g(1)	-0,085441274	h(1)	0,806891509
g(2)	-0,135011020	h(2)	-0,459877502
g(3)	0,459877502	h(3)	-0,135011020
g(4)	0,806891509	h(4)	0,085441274
g(5)	0,332670553	h(5)	0,035226292

Proses dekomposisi Wavelet dilakukan dengan menggunakan frekuensi *sampling* 128 Hz untuk mendapatkan gelombang Delta, Teta, Alfa, Mu, Beta dan perubahan amplitudo selama satu segmen sebagai berikut.

#### a) Ekstraksi Gelombang Delta

Pada gelombang Delta menggunakan koefisien *high-pass filter*. Kemudian dilakukan proses *downsampling* dengan mengambil data setengahnya, begitu juga pada konvolusi kedua dan ketiga. Pada konvolusi keempat dilakukan detil dan proses *downsampling*. Sehingga diperoleh 336 titik data.

#### b) Ekstraksi Gelombang Teta

Proses dekomposisi untuk memperoleh gelombang Teta menggunakan koefisien *low-pass filter* pada konvolusi kesatu sampai ketiga. Selanjutnya konvolusi keempat

menggunakan koefisien *high-pass filter*. Sehingga diperoleh 336 titik data.

c) *Ekstraksi Gelombang Alfa*

Pada gelombang Alfa menggunakan koefisien *low-pass filter* pada konvolusi kesatu sampai kedua. Pada konvolusi ketiga menggunakan koefisien *high-pass filter*, pada konvolusi keempat menggunakan koefisien *low-pass filter* dan *high-pass filter*. Selanjutnya pada konvolusi kelima menggunakan koefisien *low-pass filter*. Sehingga diperoleh 504 titik data.

d) *Ekstraksi Gelombang Mu*

Pada gelombang Mu menggunakan koefisien *low-pass filter* pada konvolusi kesatu sampai kedua. Pada konvolusi ketiga menggunakan koefisien *high-pass filter*, pada konvolusi keempat menggunakan koefisien *low-pass filter* dan *high-pass filter*. Selanjutnya pada konvolusi kelima menggunakan koefisien *low-pass filter*. Sehingga diperoleh 72 titik data.

e) *Ekstraksi Gelombang Beta*

Proses dekomposisi pada gelombang Beta menggunakan koefisien *low-pass filter* pada konvolusi kesatu, ketiga dan keempat, koefisien *high-pass filter* pada konvolusi kedua dan kelima. Sehingga diperoleh 1.512 titik data.

f) *Ekstraksi Amplitudo*

Perubahan amplitudo diperoleh dari sinyal asli yang disegmentasi per-16 data untuk diambil nilai mutlak rata-ratanya. Sehingga diperoleh 13.440 titik data.

D. *Algoritma Genetika*

Algoritma Genetika adalah teknik pengoptimalan yang terinspirasi oleh seleksi alam dan genetika alami. Algoritma Genetika secara acak menghasilkan populasi awal yang dikodekan dengan cara tertentu [11]. Langkah pertama yang dilakukan dalam Algoritma Genetika menentukan populasi awal dari individu. Individu di ruang genetik disebut kromosom. Representasi kromosom yaitu proses yang mewakili solusi dari permasalahan yang akan diselesaikan menggunakan Algoritma Genetika [8]. Representasi kromosom terdiri dari bobot v dan bobot w seperti diperlihatkan pada Gambar 2.

Kromosom								
Individual	Bobot V					Bobot W		
	g1	g2	g3	...	g45120	g45121	...	g46224

Gambar 2. Representasi Kromosom

Keterangan :

- g1 : representasi nilai bobot ( $v_1$ )
- g2 : representasi nilai bobot ( $v_2$ )
- g3 : representasi nilai bobot ( $v_3$ )
- ⋮
- g46.224 : representasi nilai bobot ( $w_{46224}$ )

Dalam Algoritma Genetika terdapat fungsi kecocokan atau *fitness function* yang digunakan untuk menghitung jarak setiap

gen pada kromosom dalam mengukur kesesuaian solusi terhadap kriteria yang ada. Fungsi kecocokan mengevaluasi seberapa baik sebuah individu dalam suatu populasi [12]. Fungsi kecocokan didefinisikan sebagai  $1/MSE$  dimana *Mean Squared Error* (MSE) yaitu kesalahan *error* yang dihitung untuk mengevaluasi nilai kecocokan setiap individu seperti pada Persamaan 3.

$$MSE = \frac{1}{2} \sum_{i,j} (w_{ij} - v_{ij})^2$$

dimana :

w == = bobot awal dari neuron *hidden* ke *output*

v == = bobot awal dari neuron *input* ke *hidden*

Pemilihan kromosom diseleksi untuk dijadikan induk pada proses selanjutnya dengan harapan menghasilkan keturunan yang lebih baik. Teknik yang digunakan dalam penelitian ini adalah *Rank Based Selection* dengan mengurutkan individu yang memiliki nilai kecocokan tertinggi ke terendah.

Proses selanjutnya persilangan atau *crossover* dimana dua kromosom yang dipilih dengan nilai kecocokan tertinggi saling bertukar bagian isi gen untuk menghasilkan pasangan kromosom baru. Isi gen akan diubah terlebih dulu kedalam biner. Teknik persilangan menggunakan *one point crossover* dengan melakukan penukaran isi gen dari satu kromosom dengan kromosom yang lain. Setelah didapatkan kromosom baru dilakukan proses mutasi dengan menerapkan perubahan ke satu individu dalam generasi saat ini untuk membuat generasi baru. Mutasi dilakukan untuk menambah keragaman populasi [13] dan kemungkinan besar menghasilkan individu dengan nilai kecocokan yang lebih baik.

Generasi pada Algoritma Genetika akan berhenti jika kriteria penghentian terpenuhi. Penghentian generasi dilakukan apabila mencapai batas maksimum generasi atau kondisi dimana nilai fungsi kecocokan yang tidak berubah setelah beberapa generasi.

E. *Backpropagation*

Backpropagation merupakan algoritma pembelajaran yang terawasi dengan banyak lapisan untuk mengubah bobot-bobot yang terhubung dengan neuron-neuron yang ada pada lapisan tersembunyi. Algoritma Backpropagation menggunakan *error output* untuk mengubah nilai bobot-bobotnya dalam arah mundur atau *backward* [14]. Backpropagation memiliki kemampuan ramalan *non-linear* yang kuat, kemampuan generalisasi dan toleransi kesalahan, sehingga banyak digunakan dalam prediksi dan pendekatan dalam penerapan bidang teknik [15]. Teknik yang digunakan pada Backpropagation yaitu *supervised learning* sebagai metode pembelajaran jaringan [16].

Data latih yang diambil dari 60 naracoba pasien stroke dan orang normal yang sudah diekstraksi, selanjutnya akan mulai diproses sebagai pelatihan. Dan 15 naracoba pasien stroke dan orang normal diproses sebagai data uji. Vektor fitur yang

digunakan sebagai data masukkan pada sistem identifikasi sinyal dapat dilihat pada Tabel 2.

TABEL II. VEKTOR FITUR DALAM SATU DATA LATIH

Detik ke	Kanal	Panjang Data	Komponen
1 – 30	14	$x1 - x15.120$	Beta
		$x15.121 - x18.480$	Delta
		$x18.481 - x21.840$	Teta
61 – 90	2	$x21.841 - x23.280$	Mu
91 – 120	14	$x28.281 - x28.320$	Alfa
		$x28.321 - x31.680$	Teta
	14	$x 31.680 - x45.120$	Amplitudo
		Jumlah :	45.120 titik data

Backpropagation menggunakan arsitektur Multilayer Perceptron untuk mengubah bobot yang terhubung dengan neuron-neuron yang terdapat pada *hidden layer* dan fungsi *sigmoid biner* pada *output layer*. Dalam menentukan banyaknya neuron pada *hidden layer* dapat menggunakan Persamaan 4 dan untuk fungsi *sigmoid biner* dapat dilihat pada Persamaan 5.

$$p = \sqrt{(m \times n)} \quad \square \square \square$$

dimana :

$m$  == jumlah neuron *input*

$n$  == jumlah neuron *output*

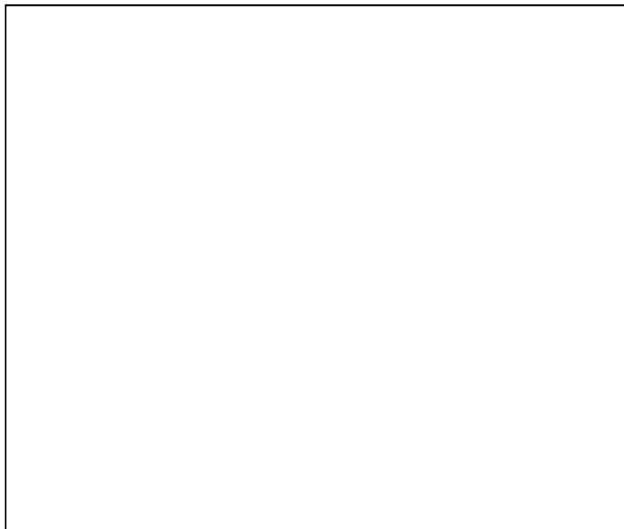
$$f'(x) = f(x)(1 - f(x)) \quad \square \square \square$$

dimana :

$e$  == nilai eksponen

$x$  == *input* data yang diaktivasi

Arsitektur Multilayer Perceptron yang digunakan pada penelitian ini diperlihatkan pada Gambar 4 yang terdiri dari *input layer*, *hidden layer* dan *output layer*. Proses pembelajaran dimulai dari setiap neuron *input* sebanyak 46.224 neuron terhadap setiap neuron pada *hidden layer* sebanyak 368 neuron, yang diteruskan hingga setiap neuron dalam *output layer*



Seminar Nasional Aplikasi Teknologi Informasi (SNATi) 2019  
Yogyakarta, 03 Agustus 2019

sebanyak 3 neuron. Bobot awal diperoleh dari hasil optimalisasi menggunakan Algoritma Genetika  $\alpha = 0,001$ .

Gambar 3. Arsitektur Multilayer Perceptron

Pada proses pelatihan menggunakan Backpropagation terdapat tiga fase yang akan dilakukan untuk proses identifikasi yaitu *feed forward*, *backpropagation* dan modifikasi bobot [17]. Berikut penjelasan dari ketiga fase pada Backpropagation.

### 1) Feed Forward

*Feed Forward* atau fase maju merupakan tahap dimana setiap neuron *input*  $x_i$  akan mengirimkan sinyal masukkan pada *hidden layer*. Masing-masing neuron pada *hidden layer* dikalikan dengan bobot dan dijumlahkan dengan bias. Perhitungannya dilakukan menggunakan Persamaan 6.

$$z_{net\ j} = v_{j0} + \sum_n x_i v_{kj} \quad \square \square \square$$

dimana :

$i$  == indeks neuron *input*

$j$  == indeks neuron *hidden*

$v_{j0}$  == bobot *bias* dari *input layer* ke *hidden layer*

$n$  == jumlah neuron pada *input layer*

$x_i$   $X_i$  == data nilai masukkan yang ke- $i$

$v_{kj}$  == bobot dari *input layer* ke *hidden layer*

Selanjutnya melakukan perhitungan pada masing-masing neuron *output* yang dikalikan dengan bobot dan dijumlahkan dengan bias menggunakan Persamaan 7.

$$y_{net\ k} = w_{k0} + \sum_p z_j y_{kj} \quad \square \square \square$$

dimana:

$j$  == indeks neuron *hidden layer*

$pp$  == jumlah neuron pada *hidden layer*

$k$  == indeks neuron *output*

$w_{k0}$  == bobot *bias* dari *hidden layer* ke *output layer*

$z_j$   $Z_j$  == nilai hasil aktivasi dari *hidden layer*

$y_{kj}$  == bobot dari *hidden layer* ke *output layer*

### 3) Backpropagation

*Backpropagation* atau fase mundur merupakan tahap masing-masing neuron *output* menerima pola target yang telah dicapai sesuai pola masukkan saat pelatihan. Lakukan perhitungan untuk perubahan bias menggunakan Persamaan 8.

$$\Delta w_{kj} = \alpha x \delta_k \quad \square \square \square$$

dimana:

$\alpha$  = nilai *learning rate*

$\delta_k$  = komponen kesalahan pada *output layer*

### 4) Modifikasi Bobot

Semua bobot dimodifikasi secara bersamaan. Tahap ini berfungsi untuk menurunkan kesalahan yang terjadi. Melakukan perhitungan kesalahan pada setiap *hidden layer*, pembaharuan bias dan bobot dari masing-masing neuron *output* sehingga menghasilkan bobot dan bias baru. Perhitungan tersebut dilakukan menggunakan Persamaan 9. Perhitungan

ISSN: 1907 – 5022

pada setiap neuron *hidden* dimulai dari neuron ke-1 sampai neuron ke-*p* menggunakan Persamaan 9.

$$w_{kj} = w_{kj(lama)} + \Delta w_{kj}$$

$$v_{ji} = v_{ji(lama)} + \Delta v_{ji} \quad \square \square \square$$

dimana:

$w_{kj(lama)}$   $W_{kj(lama)}$  = bobot neuron *hidden* ke *output* yang lama

$\Delta w_{kj}$   $\Delta W_{kj}$  = koreksi bobot *W*

$v_{ji(lama)}$   $V_{ji(lama)}$  = bobot neuron *input* ke *hidden* yang lama

$\Delta v_{ji}$   $\Delta V_{ji}$  = koreksi bobot *V*

### III. HASIL DAN DISKUSI

Data latih yang digunakan pada penelitian ini sebanyak 60 dataset yang diperoleh dari perekaman sinyal EEG pasien pasca-stroke, pasien yang sudah sembuh dari stroke dan orang normal. Data yang digunakan sudah dilabeli terlebih dulu oleh dokter syaraf. Dari proses ekstraksi Wavelet didapatkan gelombang yang dapat membedakan antara ketiga kelas dalam proses identifikasi sinyal EEG yaitu no stroke, minor stroke dan moderate stroke.

Pelatihan data latih dan data baru menggunakan Backpropagation dengan bobot secara random dan bobot menggunakan Algoritma Genetika. Pelatihan dilakukan dengan parameter pelatihan yang sama yaitu 100 *epoch* dan *learning rate* 0.5. Hasil pelatihan dapat dilihat pada Tabel 3.

TABEL III. HASIL PENGUJIAN BOBOT AWAL BACKPROPAGATION

No	Jumlah Data Latih/Data Baru	Bobot Awal Backpropagation	Akurasi (%)	
			Data Latih	Data Baru
1	75	Random	70	52
2	75	Optimalisasi Algoritma Genetika	73	55

Hasil analisis pada Tabel 3 menunjukkan bahwa akurasi tertinggi diperoleh pelatihan Backpropagation menggunakan bobot awal hasil optimalisasi Algoritma Genetika. Pelatihan menggunakan bobot hasil optimalisasi Algoritma Genetika mampu meningkatkan akurasi dari 70% menjadi 73% untuk data latih dan 52% menjadi 55% untuk data uji. Hal tersebut karena bobot yang diperoleh tidak hanya diproses secara acak atau random tetapi adanya proses pemilihan bobot yang optimal dengan menggunakan Algoritma Genetika. Bobot awal hasil optimalisasi melalui beberapa tahapan sehingga didapatkan bobot yang optimal. Dimulai dari proses seleksi kromosom untuk mendapatkan individu terbaik, selanjutnya masuk proses persilangan hingga proses mutasi.

Analisis pengujian untuk setiap pasien juga dilakukan untuk melihat akurasi yang didapatkan. Pengujian melibatkan 15 pasien yang terdiri dari 10 data latih dan 5 data baru. Hasil akurasi untuk setiap pasien dapat dilihat pada Tabel 4.

*Seminar Nasional Aplikasi Teknologi Informasi (SNATi) 2019 Yogyakarta, 03 Agustus 2019*

TABEL IV. HASIL PENGUJIAN MASING-MASING PASIEN

Data	Pasien	Kelas	Akurasi (%)
Data latih	Pasien 1	No Stroke	87
	Pasien 2	Minor Stroke	68
	Pasien 3	Moderate Stroke	80
	Pasien 4	No Stroke	87
	Pasien 5	Minor Stroke	68
	Pasien 6	Moderate Stroke	80
	Pasien 7	No Stroke	87
	Pasien 8	Minor Stroke	68
	Pasien 9	Moderate Stroke	80
	Pasien 10	No Stroke	87
Data baru	Pasien 11	Minor Stroke	50
	Pasien 12	Moderate Stroke	54
	Pasien 13	No Stroke	60
	Pasien 14	Minor Stroke	50
	Pasien 15	Moderate Stroke	54

Hasil analisis pada Tabel 4 menunjukkan bahwa pengujian data latih dan data baru diperoleh akurasi dengan rata-rata 79% dan 54%.

Proses ekstraksi Wavelet untuk mendapatkan gelombang memerlukan waktu sekitar 445 detik atau 7-8 menit untuk data baru. Berbeda dengan penelitian sebelumnya [4] yang membutuhkan waktu sekitar 227 detik atau 4-5 menit untuk waktu perekaman 180 detik pada setiap data yang direkam. Hal tersebut dikarenakan perbedaan jumlah data yang sangat banyak. Waktu komputasi untuk proses ekstraksi data baru dapat dilihat pada Tabel 5.

TABEL V. WAKTU EKSTRAKSI DATA

No	Pasien	Waktu Perekaman (detik)	Waktu Ekstraksi (detik)
1	Pasien 1	150	444
2	Pasien 2	150	444
3	Pasien 3	150	444
4	Pasien 4	150	445
5	Pasien 5	150	445

### IV. KESIMPULAN

Pada penelitian ini telah diimplementasikan model komputasi yang dapat mengidentifikasi sinyal EEG pasien pasca-stroke untuk mengetahui tingkatan stroke yang diderita. Sistem juga dapat melakukan proses ekstraksi sinyal EEG sehingga dapat menampilkan grafik ekstraksi sesuai dengan fitur yang dipilih, sehingga dapat membantu dokter sebagai evaluasi tambahan pada saat pasien melakukan rehabilitasi.

Pelatihan Backpropagation menggunakan bobot awal hasil optimalisasi Algoritma Genetika. Hal tersebut terbukti dapat meningkatkan akurasi pelatihan data latih dan data baru.

Hasil pengujian untuk tingkat moderate stroke mendapat akurasi 80% dan untuk tingkat no stroke sebesar 87%. Hal

ISSN: 1907 – 5022

tersebut dipengaruhi oleh perbedaan jumlah data latih yang lebih banyak naracoba untuk pasien dengan tingkat moderate stroke dan no stroke. Sehingga akurasi data latih untuk tingkat minor stroke hanya 68%.

Proses ekstraksi data latih membutuhkan waktu yang cukup lama dibandingkan dengan ekstraksi untuk data baru. Proses ekstraksi data baru memerlukan waktu 7-8 menit dalam proses identifikasi untuk mengetahui tingkat stroke yang diderita pasien.

#### UCAPAN TERIMA KASIH

Terima kasih kepada Rumah Sakit Al-Islam Bandung atas ketersediaannya memberikan izin untuk pengambilan data.

#### REFERENSI

- [1] N. Wang *et al.*, "Characterization of Electroencephalography of strokes based on Time-frequency analysis," *Computer Aided Chemical Engineering*, vol. 44, pp. 2161–2166, 2018.
- [2] P. Sultan, S. Abdul, and A. Shah, "An Analysis of EEG Signal Generated from Ischemic Stroke Patient," in *Innovation & Commercialization of Medical Electronic Technology Conference (ICMET)*, 2015, no. November, pp. 74–77.
- [3] W. R. W. Omar *et al.*, "Acute ischemic stroke brainwave classification using relative power ratio cluster analysis," *Procedia - Social and Behavioral Sciences*, vol. 97, pp. 546–552, 2013.
- [4] D. P. Gustiawan, E. C. Djamal, and K. Agus, "Identifikasi Variabel-Variabel dari Sinyal Elektroensefalogram Pasien Rehabilitasi Stroke Menggunakan Wavelet dan Self-Organizing Map," in *Seminar Nasional Aplikasi Teknologi Informasi (SNATi)*, 2018, pp. 15–20.
- [5] Y. Tao and Y. Chen, "Distributed PV power forecasting using genetic algorithm based neural network approach," *International Conference on Advanced Mechatronic Systems, ICAMechS*, pp. 557–560, 2014.
- [6] D. Nienhold, K. Schwab, T. Hanne, and R. Dornberger, "Effects of Weight Initialization in a Feedforward Neural Network for Classification Using a Modified Genetic Algorithm," *Proceedings - 2015 3rd International Symposium on Computational and Business Intelligence, ISCBI 2015*, pp. 6–12, 2016.
- [7] M. A. Esfandani and H. Nematzadeh, "Predicting air pollution in Tehran : Genetic algorithm and back propagation neural network," *Journal of AI and Data Mining*, vol. 4, no. 1, pp. 49–54, 2016.
- [8] A. G. Karegowda, A. S. Manjunath, and M. A. Jayaram, "Application of Genetic Algorithm Optimized Neural Network Connection Weights for Medical," *International Journal on Soft Computing (IJSC)*, vol. 2, no. 2, pp. 15–23, 2011.
- [9] F. Ahmadizar, K. Soltanian, F. Akhlaghiantab, and I. Tsoulos, "Artificial neural network development by means of a novel combination of grammatical evolution and genetic algorithm," *Engineering Applications of Artificial Intelligence*, vol. 39, pp. 1–13, 2015.
- [10] J. Yang, H. Singh, and E. Hines, "Channel selection and classification of electroencephalogram signals: An artificial neural network and genetic algorithm-based approach," *Artificial intelligence in Medicine*, vol. 55, no. 2, pp. 117–126, 2012.
- [11] Z. Leng, J. Gao, B. Zhang, X. Liu, and Z. Ma, "Short-term traffic flow forecasting model of optimized BP neural network based on genetic algorithm," *Control Conference (CCC), 2013 32nd Chinese*, pp. 8125–8129, 2013.
- [12] Z. Gao, C. S. Chin, W. L. Woo, U. Kingdom, C. Energy, and T. Polytechnic, "Genetic Algorithm Based Back-Propagation Neural Network Approach for Fault Diagnosis in Lithium-ion Battery System," in *International Conference on Power Electronics Systems and Applications: Electric Transportation - Automotive, Vessel and Aircraft, PESA 2015*, no. 4, pp. 1–6.
- [13] K. Y. Huang, L. C. Shen, K. J. Chen, and M. C. Huang, "Multilayer perceptron with genetic algorithm for well log data inversion," *International Geoscience and Remote Sensing Symposium (IGARSS)*, vol. 13, pp. 1544–1547, 2013.
- [14] A. Ramadhani, M. Iwan Iwut Tritoasmoro, IR., and M. Inung Wijayanto, ST., "Analisis Penggunaan Algoritma Genetika untuk Meningkatkan Performansi dari Klasifikasi Genre Musik Berbasis Jaringan Syaraf Tiruan Back-propagation," in *e-Proceeding of Engineering*, 2016, vol. 3, no. 2, pp. 1527–1535.
- [15] L. Ma, S. Hu, M. Qiu, Q. Li, and Z. Ji, "Energy Consumption Optimization of High Sulfur Natural Gas Purification Plant Based on Back Propagation Neural Network and Genetic Algorithms," in *The 8th International Conference on Applied Energy - ICAE2016 Energy*, 2017, vol. 105, pp. 5166–5171.
- [16] I. Nadya Oktavia Rahardiani, Wayan Firdaus Mahmudy, "Optimasi Bobot Multi-Layer Perceptron Menggunakan Algoritma Genetika Untuk Klasifikasi Tingkat Resiko Penyakit Stroke.pdf," *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 2, no. 8, pp. 2352–2360, 2018.
- [17] A. M. Zamani and B. Amaliah, "Implementasi Algoritma Genetika pada Struktur Backpropagation Neural Network untuk Klasifikasi Kanker Payudara," *Jurnal Teknik ITS*, vol. 1, 2012.