

# Identifikasi Variabel-Variabel dari Sinyal Elektroensefalogram Pasien Rehabilitasi Stroke Menggunakan Wavelet dan Self-Organizing Map

Deka P. Gustiawan<sup>1</sup>, Esmeralda C. Djamal, Agus K.

Jurusan Informatika - Unjani  
Cimahi - Indonesia  
<sup>1</sup>deka.gustiawan@gmail.com

Daswara Djajasasmita  
Fakultas Kedokteran - Unjani  
Cimahi - Indonesia

**Abstract**—Evaluasi terhadap pasien paska stroke yang terukur sangat dibutuhkan untuk mengetahui perkembangan aktivitas di otak dalam masa rehabilitasi. Salah satunya instrumen yang dapat menangkap aktivitas listrik di otak adalah Elektroensefalogram (EEG). Pengamatan visual yang dilakukan dokter dari rekaman EEG adalah kerapatan, amplitudo, bentuk gelombang, dan perbandingan sinyal pada kanal yang simetrik, namun tidaklah mudah. Penelitian ini melakukan ekstraksi dari sinyal EEG untuk memperoleh variabel-variabel signifikan dari pasien paska stroke. Sinyal EEG diperoleh dari 25 pasien paska stroke dan 25 orang sehat dari 14 kanal. Setiap sinyal selama 180 detik diekstraksi menggunakan Wavelet untuk memperoleh gelombang Alfa, Beta, Teta, Gama, dan Mu. Clustering dilakukan menggunakan Self Organizing Map (SOM) Kohonen dengan fitur masukan kelima gelombang, amplitudo, dan asimetrik dari kanal simetrik. SOM melakukan clustering berdasarkan fitur-fitur pembeda pola, sehingga hasil clustering dibandingkan dengan cluster dari data sebenarnya. Cara ini dilakukan untuk menentukan variabel-variabel sinyal EEG beserta kanal-kanalnya yang memberikan akurasi terbaik. Hasil penelitian menunjukkan penggunaan keenam fitur dari 14 kanal dan fitur sinkronisasi dari 7 pasang kanal memberikan ketepatan klustering sebesar 54-68%. Akurasi fitur tertinggi diperoleh dari variabel perubahan amplitudo. Sistem identifikasi telah diimplementasikan dalam perangkat lunak dan diintegrasikan dengan wireless EEG Emotiv. Waktu komputasi dari sistem identifikasi sekitar empat menit, cukup realistis yang dapat digunakan untuk membantu analisis dokter.

**Keywords**— *rehabilitasi stroke, sinyal EEG, wavelet, SOM, clustering*

## I. PENDAHULUAN

Stroke adalah penyebab kematian terbesar kedua di seluruh dunia dan salah satu yang terdepan penyebab kecacatan. Meski hampir 85% pasien bertahan cedera awal, sekitar 65% penderita Stroke akan mengalami cacat residual yang mengganggu fungsi sehari-hari dan kualitas hidup, bahkan setelah mendapat standar perawatan medis dan rehabilitasi. Di antara kebanyakan cacat fisik, gangguan untuk kinerja neuromuskular seperti kontrol motorik halus atau kasar, otot kekuatan, dan kekuatan adalah ciri stroke yang memiliki dampak terbesar pada kemampuan fungsional [1].

Salah satu upaya meningkatkan kualitas hidup penderita stroke adalah melalui rehabilitasi. Rehabilitasi paska-stroke seperti fisioterapi, psikologi, dan pengobatan merupakan salah

satu upaya untuk mengembalikan atau memulihkan kemampuan pasien secara fisik pada keadaan semula (normal). Oleh sebab itu diperlukan identifikasi variabel-variabel terkait aktivitas listrik di otak yang direkam melalui Elektroensefalogram (EEG) selama masa rehabilitasi untuk monitoring perkembangan pasien paska-stroke [2].

Sinyal EEG adalah sinyal aktivitas listrik pada otak manusia yang memiliki frekuensi antara 0-100 Hz. Sinyal EEG yang mempunyai amplitudo kecil yaitu 1-100 $\mu$ V. Beberapa pemrosesan sinyal EEG dapat dilakukan dengan analisis gelombang dalam domain frekuensi yaitu gelombang Alfa, Beta, Teta, Gama, sinkronisasi pada kanal yang simetrik, perubahan amplitudo setiap waktu, beserta analisis statistiknya. Penelitian mengenai EEG stroke telah dilakukan dari pasien paska-stroke iskemik [3] yaitu terhadap dominasi gelombang Alfa dan Beta, dan pada pasien cedera otak traumatis [4]. Penelitian lain mengidentifikasi *motor imagery* dari selama pasien menjalani rehabilitasi stroke [5].

Penggunaan transformasi Wavelet untuk ekstraksi gelombang Alfa, Beta, Teta, Gama dan Mu. Beberapa penelitian menggunakan Wavelet untuk ekstraksi dan klasifikasi emosi pada pasien paska stroke [6] dan pada seseorang yang sehat [7] yang diperoleh sangat efektif dan mendapatkan nilai akurasi yang baik. Self-Organizing Map (SOM) Kohonen telah digunakan untuk menganalisa kesamaan data EEG [8].

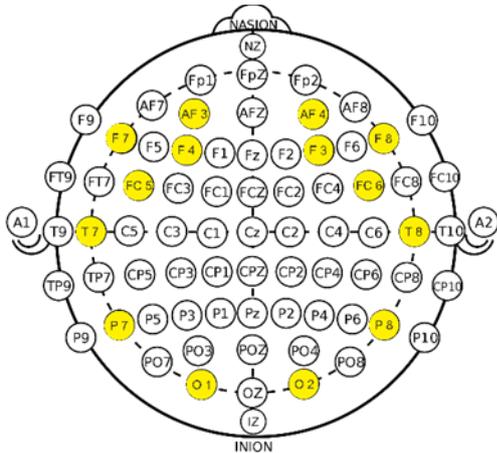
Penelitian ini bertujuan membuat sistem identifikasi variabel-variabel sinyal EEG yang berpengaruh pada pasien selama rehabilitasi stroke, yang nantinya dapat digunakan untuk evaluasi dan monitoring selama rehabilitasi stroke berlangsung. Sistem dibangun dengan pembelajaran *unsupervised* atau *clustering* menggunakan Self Organizing Map Kohonen. Hasil clustering dibandingkan dengan kelas sebenarnya untuk mempertimbangkan variabel-variabel yang berpengaruh dalam monitoring pasien paska stroke. Sinyal EEG ditransformasi dengan Wavelet untuk mengekstraksi tiap gelombang Alfa, Beta, Teta, Gama, dan Mu. Gelombang Mu direlasikan kehadirannya saat membayangkan gerakan atau *motor imagery*. Kelima gelombang, disertai perubahan amplitudo, dan sinkronisasi kanal simetrik merupakan fitur-fitur dari sistem identifikasi. Clustering dilakukan terhadap 25 pasien paska stroke di RS Al Islam, dan 25 orang sehat.

## II. METODE

### A. Akuisisi Data

Pembacaan sinyal EEG yang dilakukan oleh dokter adalah mengamati irama atau kerapatan gelombang, amplitudo, perubahan amplitudo, perbedaan amplitudo antar kanal simetrik, dan kehadiran gelombang-gelombang Alfa, Beta, Gama, dan Teta. Beberapa acuan atau literatur dan diskusi dengan beberapa dokter spesialis syaraf memberikan gambaran variabel-variabel yang biasanya berpengaruh terhadap pasien rehabilitasi Stroke. Namun perlu diterjemahkan agar dapat dibaca oleh komputer. Analisis sinyal EEG pada penderita stroke dapat dilihat berdasarkan komponen-komponen gelombang daerah frekuensinya, yaitu Alfa (8 Hz-13 Hz), Beta (13 Hz-30 Hz), Gamma (30 Hz-49 Hz), Alfa-Gamma (8 Hz-49 Hz), Beta-Gamma (13 Hz-49Hz) [9]. Pada penelitian terdahulu hasil dari klasifikasi menunjukkan bahwa semua gelombang saling berkorelasi [6]. Sinyal EEG juga dapat menghasilkan motor imagery[10][11] dengan membayangkan atau berfikir untuk menggerakkan suatu benda [12] atau biasa disebut dengan gelombang Mu.

Penempatan elektroda pada EEG dilakukan dengan beberapa standar, salah satunya adalah dengan menggunakan standar International Federation of Societies of Electroencephalography, dimana elektroda ditempatkan pada kulit kepala pada posisi/aturan standar yaitu sistem 10-20. Pada penelitian ini penempatan elektroda menggunakan sistem Modified Combinatorial Nomenclature (MCN) yang merupakan pengembangan sistem 10-20 dimana sistem MCN lebih terperinci dengan elektroda yang lebih banyak, seperti terlihat pada Gambar 1.



kemungkinan sinyal berada pada frekuensi 1-64 Hz atau setengahnya untuk mendapatkan gelombang Alfa, Beta, Teta, Gama, dan Mu selanjutnya direduksi untuk dengan klasifikasi yang akan ditinjau.

Aproksimasi dan detil dapat dilihat pada Persamaan 1 dan Persamaan 2.

$$\text{Sinyal Aproksimasi} = y_{high}[k] = \sum_n x[n] \cdot g[2k - n] \quad (1)$$

$$\text{Sinyal Detil} = y_{low}[k] = \sum_n x[n] \cdot h[2k - n] \quad (2)$$

Dimana,

$x(n)$  = sinyal asli

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

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

Aproksimasi adalah sinyal yang diperoleh dari proses konvolusi sinyal asli terhadap *low-pass filter* untuk mengambil data berindeks ganjil, sedangkan detil adalah sinyal yang diperoleh dari proses konvolusi sinyal asli terhadap *high-pass filter* untuk mengambil data berindeks genap. Pada penelitian ini Wavelet yang digunakan adalah Symlet2 yang memiliki empat koefisien pada masing-masing aproksimasi dan detil, seperti pada Persamaan 3 dan persamaan 4.

Koefisien Fungsi Skala (*low-pass filter*)

$$h_0 = \frac{1-\sqrt{3}}{4\sqrt{2}} = 0.4829, h_1 = \frac{3-\sqrt{3}}{4\sqrt{2}} = 0.8365, h_2 = \frac{3+\sqrt{3}}{4\sqrt{2}} =$$

$$0.2241, h_3 = \frac{1+\sqrt{3}}{4\sqrt{2}} = -0.1294 \quad (3)$$

Koefisien Fungsi Wavelet (*high-pass filter*)

$$g_0 = \frac{1-\sqrt{3}}{4\sqrt{2}} = -0.1294, g_1 = -\frac{3-\sqrt{3}}{4\sqrt{2}} = -0.2241, g_2 = \frac{3+\sqrt{3}}{4\sqrt{2}} =$$

$$0.8365, g_3 = -\frac{1+\sqrt{3}}{4\sqrt{2}} = -0.4829 \quad (4)$$

Pada penelitian terdahulu, ekstraksi sinyal EEG menggunakan Wavelet telah dilakukan untuk monitoring kondisi emosional [13][14][15], identifikasi tingkat kewaspadaan dengan akurasi[16] identifikasi kondisi rileks [17].

Sinyal EEG selama tiga menit disimpan sebagai file (.csv) yang direkam dari 14 kanal. Setiap segmen 180 detik setiap kanalnya diekstraksi menggunakan transformasi Wavelet. Transformasi Wavelet ditujukan untuk ekstraksi gelombang Alfa, Beta, Teta, Gama, dan Mu dari sinyal EEG. Proses dekomposisi sinyal Wavelet dapat dilihat pada Gambar 4.

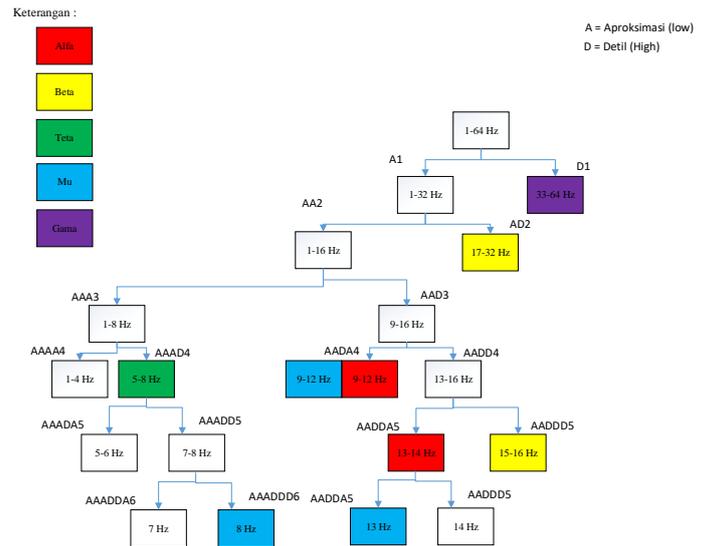
### 1) Ekstraksi Gelombang Gama

Proses ekstraksi gelombang Gama menggunakan koefisien high pass filter. Hasil tersebut melewati proses *downsampling* dengan mengambil indeks genap. Hasil ekstraksi Wavelet pada gelombang Gama dari sinyal EEG selama 180 detik, mereduksi jumlah data dari 23.040 menjadi 1.520 data.

### 2) Ekstraksi Gelombang Beta

Dekomposisi gelombang Beta prosesnya sama seperti dekomposisi pada gelombang Gama, namun untuk mendapatkan gelombang Beta pada konvolusi kesatu menggunakan filter *low-pass*. Konvolusi kedua menggunakan filter *high-pass* dan *low-pass*. Pada konvolusi ketiga menggunakan filter *high-pass* lalu keempat dan kelima

menggunakan filter *high-pass*. Dari 23.040 didapatkan gelombang Beta 6.480 data sinyal EEG selama 180 detik.



Gambar 4 Ekstraksi wavelet

### 3) Ekstraksi Gelombang Teta

Dekomposisi gelombang Teta prosesnya sama seperti dekomposisi pada gelombang Beta, namun untuk mendapatkan gelombang Teta pada konvolusi kesatu sampai ketiga menggunakan filter *low-pass*. Selanjutnya konvolusi keempat menggunakan filter *high-pass*. Dari 23.040 didapatkan gelombang beta 1.440 data.

### 4) Ekstraksi Gelombang Alfa

Dekomposisi gelombang Alfa prosesnya melalui *low-pass* pada konvolusi kesatu sampai kedua. Pada konvolusi ketiga menggunakan *high-pass*, pada konvolusi keempat menggunakan filter *low-pass* dan *high-pass*. Selanjutnya pada konvolusi kelima menggunakan *low-pass filter*. Sehingga gelombang Alfa yang diperoleh 120 data dari 23.040. Hasil dekomposisi gelombang Alfa setiap 180 detik menghasilkan 2.160 data.

### 5) Ekstraksi Gelombang Mu

Dekomposisi gelombang Mu prosesnya melalui *low-pass* pada konvolusi kesatu sampai kedua. Pada konvolusi ketiga menggunakan *high-pass*, pada konvolusi keempat menggunakan filter *low-pass* dan *high-pass*. Selanjutnya pada konvolusi kelima menggunakan *low-pass filter*. Sehingga gelombang Mu yang diperoleh 2.160 data dari 23.040. Hasil dekomposisi gelombang Mu setiap 180 detik menghasilkan 2.160 data.

### 6) Perubahan Amplitudo

Perubahan amplitudo didapatkan dari sinyal asli yang disegmentasi setiap 16 data dan diambil nilai absolut rata-ratanya. Sehingga dari data asli 23.040 menjadi 1440 titik data.

## C. Self-Organizing Map

Salah satu teknik untuk melakukan pembelajaran *unsupervised* adalah *Self-Organizing Map* (SOM). Seperti pada

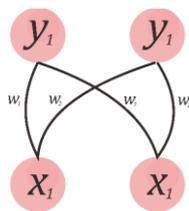
penelitian terdahulu mengenai klasifikasi dan *clustering* EEG, membandingkan antara *Supervised Learning* menggunakan *Feedforward* dan *Unsupervised Learning* menggunakan *Self-Organizing Map*[18][8] dengan masing-masing unit sebanyak empat dan sepuluh *cluster*, identifikasi dan *labeling* juga telah dilakukan pada sinyal EEG pasien Epilepsi [19] [20].

SOM merupakan teknik *clustering* yang sebelumnya harus menentukan banyak *cluster* yang akan dibuat. Pada penelitian ini *cluster* akan dibagi menjadi dua berdasarkan pasien paska stroke dan orang sehat. Jumlah *neuron* masukan SOM pada penelitian ini memiliki panjang data yang berbeda tergantung dari variabel atau fitur apa yang akan dilakukan *clustering*. Panjang data EEG masing-masing variabel dapat dilihat pada Tabel I.

TABEL I PANJANG DATA EEG

| No    | Gelombang | Panjang Data | Panjang Data (14 kanal) |
|-------|-----------|--------------|-------------------------|
| 1.    | Alfa      | 2160         | 30240                   |
| 2.    | Beta      | 6480         | 90720                   |
| 3.    | Teta      | 1440         | 20160                   |
| 4.    | Gama      | 11520        | 161280                  |
| 5.    | Mu        | 2160         | 30240                   |
| 6.    | Amplitudo | 1440         | 20160                   |
| Total |           | 33200        | 464800                  |

Parameter masukan lain untuk proses *clustering* SOM adalah *learning rate* ( $\alpha$ ) sebesar 0.05 dengan pengurangan setiap kali iterasi 0.1 dikali *learning rate*. Untuk nilai minimum *learning rate* (Eps) sebesar 0.0001 dan maksimum 1000 *epoch*. Arsitektur jaringan SOM untuk *clustering* data EEG dapat dilihat pada Gambar 4.



Gambar 5 Arsitektur som

Pengelompokan data menggunakan algoritma SOM yang terdiri dari empat tahapan yaitu :

1. Kompetisi : Setiap simpul *output*  $j$ , dihitung nilai  $D(x, w_j)$  yang merupakan fungsi jarak Euclidean antara  $x$  dan  $w$ . Fungsi ini didefinisikan pada Persamaan 5.

$$D(x, w_m) = \sqrt{\sum_{i=1}^m (x_i - w_{mi})^2} \quad (5)$$

2. Update bobot: setelah mendapat nilai jarak dari tiap-tiap vektor *input* kevektor bobot, pilih nilai jarak yang minimum sebagai *neuron* pemenang. Setiap *neuron* pemenang beserta tetangganya dilakukan proses adaptasi yaitu memperbaharui nilai. Apabila kelas pemenang sama dengan kelas sebenarnya maka menggunakan Persamaan 6 dan apabila kelas pemenang berbeda dengan kelas sebenarnya maka menggunakan Persamaan 7.

$$W_j(\text{baru}) = W_j(\text{lama}) + \alpha (x - W_j(\text{Lama})) \quad (6)$$

$$W_j(\text{baru}) = W_j(\text{lama}) - \alpha (x - W_j(\text{Lama})) \quad (7)$$

3. Perbaharui  $\alpha$ , dilakukan perubahan nilai dengan Persamaan 8.

$$\alpha = \alpha - 0.1 * \alpha \quad (8)$$

4. Hentikan perlakuan : perlakuan dihentikan ketika kriteria pemberhentian tercapai yaitu berdasarkan banyaknya iterasi, nilai minimum *error*, nilai  $\alpha$  dan lebar tetangga.

### III. HASIL DAN DISKUSI

Data latih yang digunakan dalam penelitian ini sebanyak 50 set yang didapatkan dari 25 pasien paska stroke dan 25 orang sehat. *Clustering* dilakukan untuk pengelompokan variabel berdasarkan kemiripan untuk pasien paska stroke dan orang sehat. Dari variabel yang didapatkan akan menunjukkan adanya variabel-variabel yang saling berhubungan sehingga proses *clustering* dianggap cocok untuk menghilangkan variabel yang tidak mewakili sinyal EEG dari pasien rehabilitasi Stroke.

Uji parameter *clustering* dilakukan untuk mengetahui pengaruh *learning rate* terhadap kualitas pembelajaran data latih dengan menggunakan 1000 *epoch*, *learning rate* 0.05 dan minimum *learning rate* sebesar 0.1 seperti terlihat pada Tabel II.

TABEL II PENGARUH LEARNING RATE MELALUI EKSTRAKSI GELOMBANG DENGAN SOM

| No | Variabel | Learning rate | Waktu Clustering (detik) | Tingkat Akurasi Clustering (%) |              |
|----|----------|---------------|--------------------------|--------------------------------|--------------|
|    |          |               |                          | Sesuai                         | Tidak Sesuai |
| 1  | Alfa     | 0.1           | 40                       | 56                             | 44           |
| 2  | Alfa     | 0.05          | 40                       | 58                             | 42           |
| 3  | Alfa     | 0.02          | 76                       | 58                             | 42           |
| 4  | Alfa     | 0.01          | 78                       | 54                             | 46           |

Berdasarkan Tabel II perbandingan pengaruh *learning rate* dan konstanta pengurangan *learning rate* yang meliputi tingkat akurasi *clustering*. Dari hasil perbandingan nilai *learning rate* didapatkan hasil 58% akurasi data sesuai dengan clusternya menggunakan *learning rate* 0.05 dan 0.02.

Setelah didapatkan parameter yang optimal untuk *clustering*, pengujian terhadap masing-masing variabel yang diduga berpengaruh dengan *clustering* menggunakan SOM dilakukan dengan hasil dari *clustering* tersebut dapat dilihat pada Tabel III.

TABEL III PENGARUH SETIAP FITUR

| No | Variabel Diduga Berpengaruh | Akurasi (%)                |                                  |
|----|-----------------------------|----------------------------|----------------------------------|
|    |                             | Sesuai dengan Kelas Target | Tidak Sesuai dengan Kelas Target |
| 1  | Alfa                        | 58                         | 42                               |
| 2  | Beta                        | 54                         | 46                               |
| 3  | Teta                        | 52                         | 48                               |
| 4  | Gama                        | 56                         | 44                               |
| 5  | Mu                          | 52                         | 48                               |
| 6  | Amplitudo                   | 68                         | 32                               |

Pada Tabel III terlihat setiap variabel memiliki akurasi yang berbeda. Berdasarkan hasil *clustering*, didapatkan variabel amplitudo memiliki presentasi kecocokan terhadap label sebenarnya yaitu 68%. Tabel IV menunjukkan seluruh data orang sehat masuk kedalam *cluster* yang seharusnya, namun pada data pasien paska stroke hanya 9 dari 25 data pasien paska stroke

yang masuk ke dalam label seharusnya 16 data pasien paska stroke memiliki kedekatan dengan label orang sehat.

TABEL IV HASIL CLUSTERING DATA EEG PASIEN PASKA STROKE

| No | EEG Pasien | Target | Cluster |
|----|------------|--------|---------|
| 1  | P1         | 1      | 2       |
| 2  | P2         | 1      | 2       |
| 3  | P3         | 1      | 2       |
| 4  | P4         | 1      | 2       |
| 5  | P5         | 1      | 1       |
| 6  | P6         | 1      | 2       |
| 7  | P7         | 1      | 1       |
| 8  | P8         | 1      | 1       |
| 9  | P9         | 1      | 2       |
| 10 | P10        | 1      | 1       |
| 11 | P11        | 1      | 1       |
| 12 | P12        | 1      | 2       |
| 13 | P13        | 1      | 1       |
| 14 | P14        | 1      | 2       |
| 15 | P15        | 1      | 1       |
| 16 | P16        | 1      | 2       |
| 17 | P17        | 1      | 2       |
| 18 | P18        | 1      | 1       |
| 19 | P19        | 1      | 2       |
| 20 | P20        | 1      | 2       |
| 21 | P21        | 1      | 2       |
| 22 | P22        | 1      | 2       |
| 23 | P23        | 1      | 2       |
| 24 | P24        | 1      | 2       |
| 25 | P25        | 1      | 1       |

Pengujian juga dilakukan untuk setiap variabel terhadap setiap kanal yang simetris untuk mendapatkan akurasi yang terbaik. Seperti terlihat pada Tabel V.

TABEL V HASIL PENGARUH KANAL SIMETRIS

| No | Kanal Simetris | Akurasi Fitur Amplitudo (%) |                                  |
|----|----------------|-----------------------------|----------------------------------|
|    |                | Sesuai dengan Kelas Target  | Tidak Sesuai dengan Kelas Target |
| 1  | AF3-AF4        | 64                          | 36                               |
| 2  | F7-F8          | 64                          | 36                               |
| 3  | F3-F4          | 62                          | 38                               |
| 4  | FC5-FC6        | 62                          | 38                               |
| 5  | T7-T8          | 64                          | 36                               |
| 6  | P7-P8          | 64                          | 36                               |
| 7  | O1-O2          | 62                          | 38                               |
| 8  | Semua Kanal    | 68                          | 32                               |

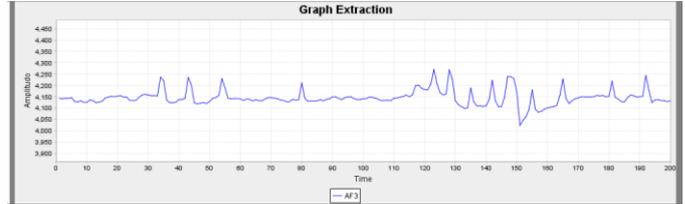
Pada Tabel V terlihat setiap pasangan kanal simetris menunjukkan presentase tertinggi adalah 64% yaitu AF3-AF4, F7-F8, T7-T8, dan P7-P8. Ketika semua kanal disatukan akan menghasilkan presentase clustering terbaik yaitu 68%. Hasil penelitian menunjukkan bahwa waktu komputasi yang dibutuhkan terhadap data EEG pasien baru adalah 277 detik atau 4.61 menit seperti terlihat pada Tabel VI.

TABEL VI HASIL WAKTU KOMPUTASI

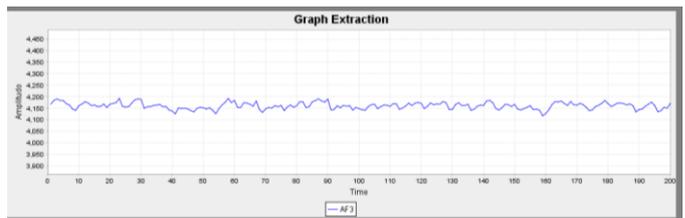
| No | Pasien | Waktu Perekaman (detik) | Waktu Ekstraksi Variabel (detik) |
|----|--------|-------------------------|----------------------------------|
| 1  | P1     | 180                     | 279                              |
| 2  | P2     | 180                     | 277                              |
| 3  | P3     | 180                     | 277                              |
| 4  | P4     | 180                     | 277                              |

Beberapa kekurangan dari akurasi clustering adalah karakteristik beberapa pasien kemungkinan sudah mendekati normal atau memiliki Stroke ringan. Sehingga kemudian perlu lebih banyak cluster.

Dalam grafik hasil ekstraksi secara langsung dapat dilihat perbedaan dan telah divalidasi oleh dokter. Seperti terlihat pada Gambar 6 Amplitudo pasien paska stroke dan Gambar 7 amplitudo orang sehat.



Gambar 6 Amplitudo pasien paska stroke



Gambar 7 Amplitudo orang sehat

Perbandingan yang dapat dilihat dari grafik gelombang EEG yang dihasilkan yaitu terdapatnya perlambatan gelombang pasien paska stroke seperti pada Gambar 6, yang berbeda dengan orang sehat pada gambar 7.

#### IV. KESIMPULAN

Pada penelitian ini sistem identifikasi variabel-variabel EEG pasien paska stroke telah dibangun dan dapat melakukan fungsi utama untuk melakukan ekstraksi dan pengelompokan data EEG. Data EEG dilakukan ekstraksi menggunakan Wavelet Symlet2 untuk mendapatkan variabel atau fitur ekstraksi yang berpengaruh. Fitur tersebut dilakukan pengujian dan validasi satu-persatu menggunakan SOM untuk mengetahui seberapa pengaruhnya terhadap data supervised yang seharusnya.

Hasil clustering menunjukkan bahwa orang sehat memiliki akurasi 100%. Semenetera hanya 36% pasien paska stroke masuk ke dalam cluster sebenarnya. Kemungkinan terdapat kesembuhan ditinjau dari aktivitas listrik di otak. Akurasi dengan konfigurasi semua kanal digabungkan diperoleh akurasi sebesar 68%. Konfigurasi variable dan kanal ini digunakan untuk membangun model analisis sinyal EEG terhadap pasien paska stroke. Walaupun demikian model yang dibangun dalam perangkat lunak memungkinkan dokter untuk melakukan koreksi.

Analisis sinyal semua variabel untuk tim medik dapat dilihat langsung menggunakan grafik yang disediakan pada menu ekstraksi dan identifikasi pada sistem identifikasi variabel EEG pasien paska stroke. Waktu yang dibutuhkan untuk proses ekstraksi data pasien paska stroke baru adalah 4-5 menit.

## UCAPAN TERIMA KASIH

Terima kasih kepada Rumah Sakit Al-Islam atas ketesediannya memberikan izin pengambilan data. Terimakasih juga kepada Direktorat Jenderal Pembelajaran dan Kemahasiswaan Kementerian Riset, Teknologi dan Pendidikan Tinggi atas pemberian dana Program Kreativitas Mahasiswa Bidang Penelitian Eksakta tahun 2018.

## REFERENSI

- [1] W. Teo, "Is Motor-Imagery Brain-Computer Interface Feasible in Stroke Rehabilitation?," vol. 6, no. August, pp. 723–728, 2014.
- [2] R. Li, W. Huang, D. Lou, G. Zhu, T. Zhang, and Y. Zhang, "The Feasibility of Utilizing EEG - fNIRS to Characterize the Cortical Activation Difference between Healthy Subjects and Post - Stroke Patients," *IEEE*, pp. 10–13, 2015.
- [3] W. R. W. Omar, Z. Mohamad, R. Jailani, and M. . Taib, "An Analysis of EEG Signal Generated from Ischemic Stroke Patient," *ICMET*, no. November, pp. 74–77, 2015.
- [4] A. Napoli, M. Barbe, K. Darvish, and I. Obeid, "Assessing Traumatic Brain Injuries Using EEG Power Spectral Analysis and Instantaneous Phase," *IEEE EMBS*, pp. 4692–4695, 2012.
- [5] K. K. Ang *et al.*, "Clinical study of neurorehabilitation in stroke using EEG-based motor imagery brain-computer interface with ....," in *32nd Annual International Conference of the IEEE EMBS*, 2010, no. September 2010.
- [6] S. Z. Bong, K. Wan, M. Murugappan, N. M. Ibrahim, Y. Rajamanickam, and K. Mohamad, "Implementation of wavelet packet transform and non linear analysis for emotion classification in stroke patient using brain signals," *Biomed. Signal Process. Control*, vol. 36, pp. 102–112, 2017.
- [7] V. Bajaj and R. B. Pachori, "Human Emotion Classification from EEG Signals using Multiwavelet Transform.pdf," *IEEE*, pp. 125–130, 2014.
- [8] I. S. Jahan, M. Prilepok, V. Snasel, and M. Penhaker, "Similarity Analysis of EEG Data Based on Self Organizing Map Neural Network," pp. 547–556, 2014.
- [9] N. Gurudath and H. B. Riley, "Drowsy Driving Detection by EEG Analysis Using Wavelet Transform and K-Means Clustering," *Procedia - Procedia Comput. Sci.*, vol. 34, pp. 400–409, 2014.
- [10] E. Monge-Pereira, J. Ibañez-Pereda, I. M. Alguacil-Diego, J. I. Serrano, M. P. Spottorno-Rubio, and F. Molina-Rueda, "Use of Electroencephalography Brain-Computer Interface Systems as a Rehabilitative Approach for Upper Limb Function After a Stroke: A Systematic Review," *Pm&R*, vol. 9, pp. 918–932, 2017.
- [11] E. Yulianto, A. Susanto, T. S. Widodo, and S. Wibowo, "Spektrum Frekuensi Sinyal EEG Terhadap Pergerakan Motorik dan Imajinasi Pergerakan Motorik," *Forum Tek.*, vol. 35, pp. 21–32, 2013.
- [12] B. Kim, L. Kim, Y. H. Kim, and S. K. Yoo, "Cross-association analysis of EEG and EMG signals according to movement intention state," *Cogn. Syst. Res.*, vol. 44, pp. 1–9, 2017.
- [13] E. C. Djamal, P. Lodaya, and H. Lestari, "EEG Based Emotion Monitoring Using Wavelet and Learning Vector Quantization," 2017.
- [14] V. Naibaho, S. Prodi, T. Informatika, F. Teknik, and U. Telkom, "Klasifikasi Emosi Melalui Sinyal EEG yang Dihasilkan Otak dengan Menggunakan Discrete Wavelet Transform dan Backpropagation Artificial Neural Network," 2015.
- [15] M. Murugappan, N. Ramachandran, and Y. Sazali, "Classification of human emotion from EEG using discrete wavelet transform," vol. 2010, no. April, pp. 390–396, 2010.
- [16] E. C. Djamal, Suprijanto, and A. Arif, "Identification of Alertness State Based on EEG Signal Using Wavelet Extraction and Neural Networks Identification of Alertness State Based on EEG Signal Using Wavelet Extraction and Neural Networks," 2016.
- [17] E. Rifky, E. C. Djamal, and A. Komarudin, "IDENTIFIKASI KONDISI RILEKS DARI SINYAL EEG MENGGUNAKAN WAVELET DAN LEARNING VECTOR QUANTIZATION," *Pros. SNST*, pp. 150–155, 2015.
- [18] O. al-Ketbi and M. Conrad, "Supervised ANN vs. Unsupervised SOM to Classify EEG Data for BCI: Why can GMDH do better?," *Int. J. Comput. Appl.*, vol. 74, no. 4, pp. 37–44, 2013.
- [19] M. Y. Abdullah, E. C. Djamal, and F. Renaldi, "Aksi Game Arcade Berdasarkan Pikiran Menggunakan Filter Fast Fourier Transform dan Learning Vector Quantization," pp. 17–22, 2016.
- [20] E. C. Djamal and Suprijanto, "Recognition of Electroencephalogram Signal Pattern against Sound Stimulation using Spectral of Wavelet," pp. 374–378, 2011.