

Klasifikasi Gerakan Jari Tangan Berdasarkan Sinyal *Electromyogram* Pada Lengan

Catur Atmaji^{*1}, Yusuf Waraqa Santoso², Roghib Muhammad Hujja³, Andi Dharmawan⁴,
Danang Lelono⁵

^{1,3,4,5}Departemen Ilmu Komputer dan Elektronika, FMIPA UGM, Yogyakarta, Indonesia

²Prodi Elektronika dan Instrumentasi, DIKE, FMIPA UGM, Yogyakarta, Indonesia

e-mail: ^{*1}catur_atmaji@ugm.ac.id, ²raqasantoso@gmail.com, ³roghib.muh@ugm.ac.id,

³andi_dharmawan@ugm.ac.id, ³danang@ugm.ac.id

Abstrak

Sinyal *electromyogram* merupakan rekaman aktivitas gerakan otot. Sinyal tersebut telah dimanfaatkan baik untuk diagnosis medis maupun untuk rekayasa seperti deteksi gerakan jari pada orang sehat maupun pada pasien rehabilitasi. Banyak penelitian yang telah dilakukan untuk memetakan hubungan antara *electromyogram* dengan gerakan jari, salah satunya mengenai hubungan antara jumlah kanal akuisisi data yang digunakan dengan kompleksitas sistem. Jumlah kanal yang digunakan berbanding lurus dengan kompleksitas dari suatu sistem. Semakin kompleks sistem maka semakin berat *processing data* yang dikerjakan sehingga membutuhkan sumber daya lebih besar. Karena itu, penelitian ini berfokus pada pembangunan sistem klasifikasi gerakan jari tangan manusia menggunakan kanal yang sedikit.

Jumlah kanal yang digunakan adalah sebanyak 4 kanal. *Root Mean Square* diterapkan pada *sliding window* sebagai metode ekstraksi ciri sinyal *EMG*. Metode klasifikasi yang digunakan adalah jaringan syaraf tiruan metode pembelajaran *backpropagation* yang efektif digunakan pada data yang memiliki pola. Validasi sistem dilakukan menggunakan *10 fold cross validation*. Hasil pengujian rata-rata nilai akurasi setiap kelas gerakan adalah ibu jari 89%, telunjuk 90%, jari tengah 93%, jari manis 95%, kelingking 93%, genggam 94%, rileks 91% yang dapat dikatakan cukup baik mengingat jumlah kanal yang relatif sedikit dibanding penelitian-penelitian yang sebelumnya.

Kata kunci— jaringan syaraf tiruan, *root mean square*, 4 kanal

Abstract

An *electromyogram* is a recording of muscle activity. These signals have been used both for medical diagnosis and engineering such as finger motion detection in healthy people and rehabilitation patients. Many studies have been conducted to map the relationship between *electromyogram* and finger movements, one of which is the relationship between the number of channels used and the complexity of the system. The number of channels used is directly proportional to the complexity of a system. The more complex the system, the heavier the data processing is so that it requires greater resources. Therefore, this study focuses on the construction of a classification system for human finger movements using fewer channels.

The number of channels used in this study is 4. *Root Mean Square* is applied in a *sliding window* as feature extraction. The classifier used is the artificial neural network. System validation is done with *10-fold cross-validation*. The test results of the average accuracy value for the thumb, index finger, middle finger, ring finger, little finger, grip, and relaxation were 89%, 90%, 93%, 95%, 93%, 94%, and 91% respectively which can be said to be quite good considering the number of channels relatively few compared to previous studies.

Keywords— artificial neural network, *root mean square*, 4-channels *EMG*

1 PENDAHULUAN

Gerakan pada tubuh manusia pada dasarnya dikendalikan oleh jaringan syaraf dan diterjemahkan oleh otot motorik. Gerakan-gerakan otot tersebut pada di antaranya adalah gerakan fleksi, ekstensi, kontraksi, dan relaksasi. Aktivitas syaraf pada manusia diamati melalui sinyal *electroencephalogram* (EEG), sedangkan gerakan otot diamati melalui perekaman sinyal *electromyogram* (EMG). Sinyal EEG maupun EMG banyak dimanfaatkan untuk diagnosis pada dunia medis. Selain pada ranah medis, sinyal EMG juga dimanfaatkan untuk keperluan rekayasa seperti untuk deteksi gerakan jari [1]–[5], untuk pengendalian robot rangka luar jari bagi orang sehat [6], serta untuk pengembangan robot rangka luar untuk rehabilitasi pasien [7]–[9].

Deteksi gerakan jari melalui sinyal EMG memiliki manfaat yang banyak, baik bagi orang sehat maupun pada pasien rehabilitasi paska-stroke. Pola-pola gerakan jari melalui EMG terkait langsung dengan kondisi otot, tidak seperti pengawasan melalui media tak langsung seperti kamera. Pada penelitian sebelumnya mengenai pemanfaatan sinyal EMG untuk analisis gerakan jari, digunakan berbagai macam variasi jumlah kanal akuisisi data. Variasi kanal seperti dari 6 kanal hingga 160 kanal [10], [11]. Penelitian sebelumnya banyak yang menggunakan jenis elektrode bipolar karena sesuai dengan cara kerja otot yaitu kontraksi dan relaksasi. Elektrode diletakkan pada lengan tangan bagian bawah [12].

Jumlah kanal yang digunakan dikatakan berbanding lurus dengan kompleksitas dari suatu sistem, dengan kata lain semakin banyak kanal yang digunakan semakin kompleks sistem tersebut [13]. Kompleksitas muncul karena semakin banyak kanal maka akan semakin banyak data seperti pada penelitian yang 6 buah kanal menghasilkan 66 ciri [12], 11 kanal menghasilkan 121 data ciri yang akan diolah pada proses selanjutnya [13]. Semakin kompleks sistem maka semakin berat *processing* data yang dikerjakan sehingga membutuhkan *resource* yang lebih besar.

Salah satu metode ekstraksi ciri adalah dengan menggunakan nilai RMS pada sinyal biomedis seperti EMG dan EEG [14]. Nilai RMS merupakan nilai yang menunjukkan besar *power* sinyal. Nilai RMS dipilih juga karena memiliki nilai *error* terendah terhadap nilai kontraksi maksimum otot sebesar 4,21%-8,10% sehingga baik digunakan sebagai metode ekstraksi ciri [15]. Metode *sliding window* juga digunakan untuk mengamati pola dari sinyal EMG. Lebar *window* disesuaikan dengan gerakan yang dilakukan. Gerakan refleks menggunakan 20 ms dan gerakan lambat dan dalam kondisi statis menggunakan 500 ms. Pergerakan jari tangan termasuk ke dalam pergerakan lambat.

2 METODE PENELITIAN

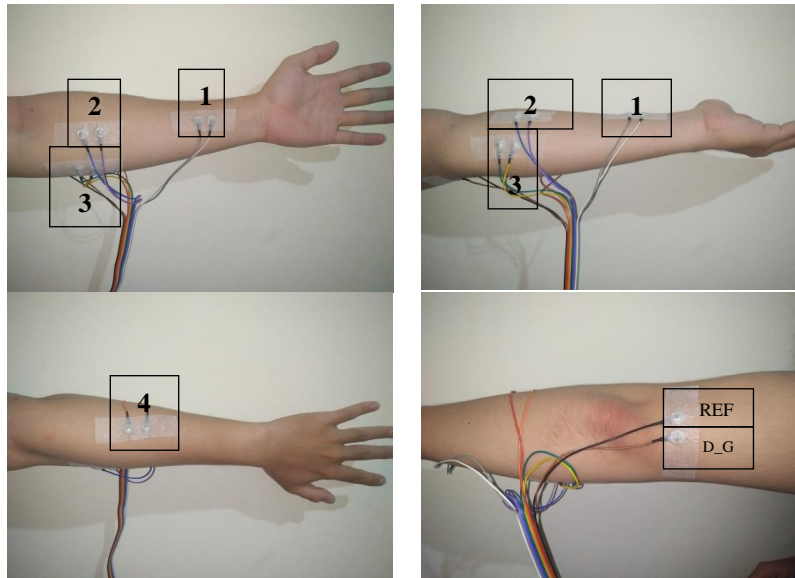
2.1 Deskripsi Sistem

Tabel 1 Nomer kanal dan nama otot

Nomer Kanal	Nama Otot
1	<i>Flexor Digitorum Superficial</i>
2	<i>Palmari Longus</i>
3	<i>Pronator Teres</i>
4	<i>Extensor Digitorum communis</i>
REF dan D_G	Siku tangan


Sistem klasifikasi gerak jari tangan manusia yang dikembangkan ini bertujuan untuk dapat mengklasifikasi gerakan yang dilakukan oleh jari manusia. Gerakan tersebut yaitu ibu jari, telunjuk, jari tengah, jari manis, kelingking yang kelimanya menekuk ke arah telapak tangan, gerakan tangan menggenggam, dan gerakan tangan rileks sehingga total ada tujuh macam gerakan yang akan diklasifikasi. Berdasar pada anatomi tangan manusia, otot yang mengontrol gerakan jari berada di lengan sehingga pada sistem ini sinyal EMG yang digunakan sebagai tempat pembacaan yaitu pada lengan tangan. Lengan yang digunakan adalah lengan kiri. Posisi

elektroda dapat dilihat pada Tabel 1. Posisi elektroda dapat dilihat pada Gambar 1. Penelitian ini menggunakan *Ganglion Board OpenBCI* sebagai perangkat akuisisi data dengan frekuensi pencuplikan sebesar 200 Hz. Kanal yang digunakan berjumlah 4 kanal bipolar dengan dilengkapi 2 kanal referensi yaitu kanal *REF* dan *D_G*.



Gambar 1 Posisi elektroda

Sistem yang dirancang pada penelitian ini bertujuan untuk mengklasifikasi gerakan jari tangan manusia berbasis sinyal EMG. Secara keseluruhan diagram blok sistem ini ditunjukkan pada Gambar 2.




Gambar 2 Diagram blok sistem secara keseluruhan

2.2 Preprocessing

Sinyal EMG memiliki rentang frekuensi dari 10 – 250Hz. Untuk keperluan deteksi gerakan ini, tidak diperlukan komponen frekuensi sangat tinggi karena yang dilihat adalah pola secara umum, dalam artian pada frekuensi yang relatif rendah. Oleh karenanya, digunakan penapisan pada rentang frekuensi 15 – 49Hz bersama dengan tapis notch pada frekuensi 50Hz untuk menghilangkan gangguan kelistrikan yang dihasilkan dari piranti yang digunakan.

Penapisan dilakukan dengan menggunakan tapis Butterworth orde-4 pada setiap segmen sinyal EMG sepanjang 1,5 detik. Rentang waktu 1,5 detik tersebut merupakan rentang waktu *event* sinyal sEMG yang di dalamnya terdapat informasi kelas gerakan untuk diproses pada proses selanjutnya. Jumlah total segmen hasil segmentasi adalah 7 segmen yang mewakili gerakan ibu jari, telunjuk, jari tengah, jari manis, kelingking, genggam, dan rileks. Segmen-segmen ini akan menjadi input untuk proses selanjutnya. Diagram blok *preprocessing* dapat dilihat pada Gambar 3.

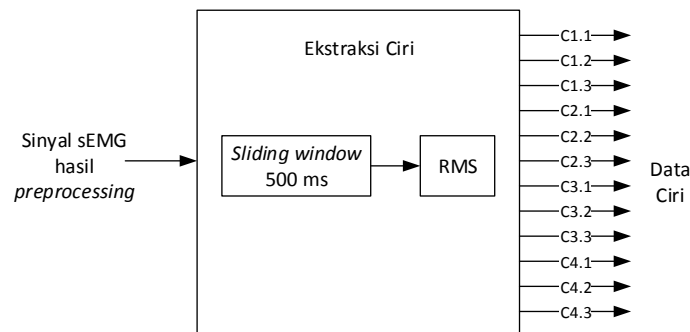


Gambar 3 Diagram blok preprocessing

2.3 Ekstraksi Ciri

Setelah melalui proses *preprocessing* sinyal EMG siap untuk masuk ke proses selanjutnya yaitu ekstraksi ciri. Ekstraksi ciri adalah suatu proses untuk mengambil informasi (ciri) yang diperlukan dan dapat digunakan untuk membangun sistem klasifikasi gerakan jari manusia. Penelitian ini menggunakan metode *root mean square* (RMS) dilengkapi dengan *sliding window* sebagai metode untuk ekstraksi ciri dari sinyal EMG dengan lebar jendela sebesar 500 ms, karena gerakan yang dilakukan termasuk dalam kategori gerak lambat dan posisi lengan statis ketika proses akuisisi data. Metode RMS dengan *sliding window* digunakan untuk mengambil ciri *power* dari sinyal EMG yang menjadi nilai *input* untuk proses klasifikasi. Lebar sinyal EMG hasil *preprocessing* adalah sebesar 1,5 detik. Penggunaan metode *sliding window* sebesar 500 ms akan menghasilkan 3 buah jendela/*window* untuk satu sinyal EMG. Dari 4 buah kanal, dihasilkan total ciri RMS sebanyak 12 ciri. Diagram blok ekstraksi ciri dapat dilihat pada Gambar 4. Persamaan RMS dapat dilihat pada persamaan (1).

$$RMS = \sqrt{\frac{1}{N} \sum_{i=0}^{N-1} (x_i)^2} \quad (1)$$



Gambar 4 Diagram blok ekstraksi ciri


2.4 Klasifikasi

Tabel 2 Kelas gerakan dan kombinasi biner

Kelas Gerakan	Kombinasi Biner
Ibu jari	1000000
Telunjuk	0100000
Jari tengah	0010000
Jari manis	0001000
Kelingking	0000100
Genggam	0000010
Rileks	0000001

Hasil ekstraksi ciri kemudian digunakan sebagai *input* proses klasifikasi menggunakan jaringan syaraf tiruan (JST). JST dipilih karena *input* untuk sistem klasifikasi berupa pola sinyal

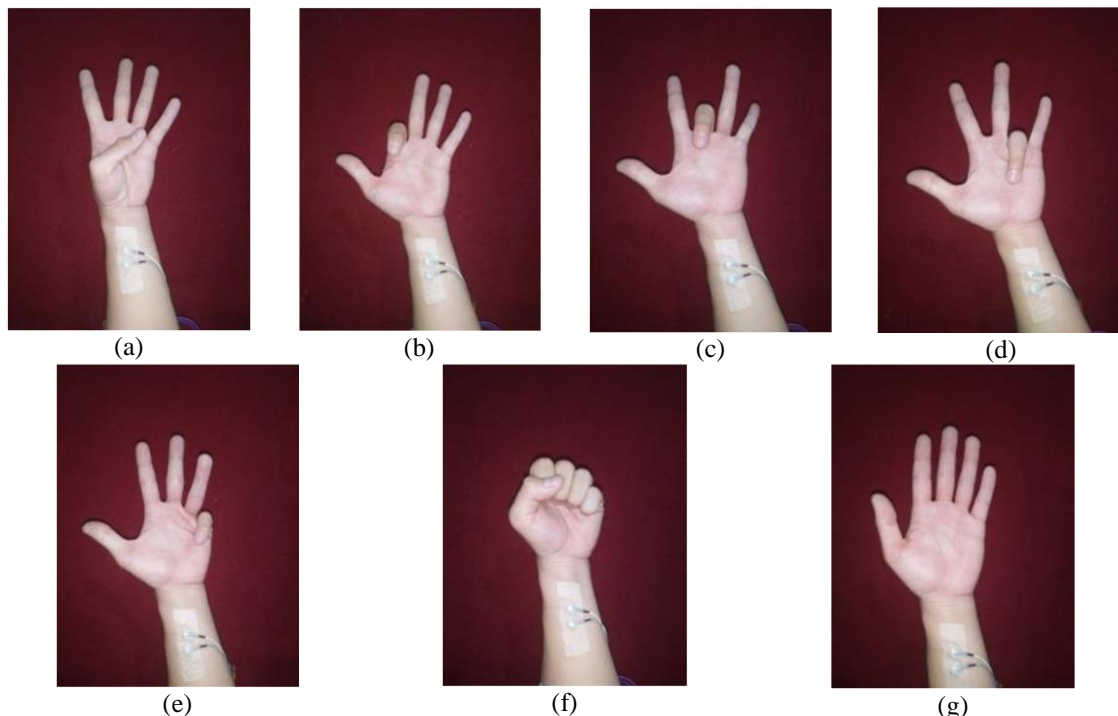
EMG. Dari beberapa referensi serta penelitian sebelumnya, JST merupakan metode yang paling cocok digunakan. Pada proses klasifikasi ini akan mengklasifikasikan sinyal EMG ke dalam 7 kelas gerakan berdasar pada 12 ciri RMS hasil ekstraksi ciri. Setiap kelas gerakan akan ditampilkan dalam bentuk kombinasi angka biner. Kelas gerakan dan kombinasi binernya dapat dilihat pada Tabel 2. Jaringan yang digunakan terdiri dari dua lapisan tersembunyi yang masing-masing memiliki 64 dan 86 *node* seperti ditunjukkan pada Gambar 5



Gambar 5 Arsitektur Jaringan Syaraf Tiruan dengan 2 lapisan tersembunyi

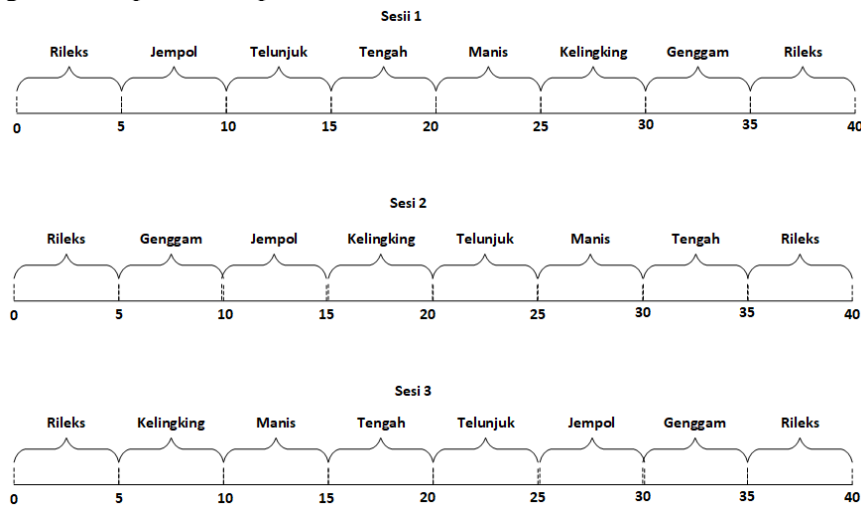
2.5 Perekaman Gerakan Jari

Gerakan jari yang dilakukan oleh subjek untuk dideteksi terdiri dari 7 macam gerakan, yaitu gerakan masing-masing untuk 5 jari, gerakan menggenggam, dan gerakan rileks. Bentuk gerakan jari yang harus dilakukan oleh setiap subjek ditunjukkan pada Gambar 6.



Gambar 6 Klasifikasi gerakan jari. (a) ibu jari, (b) telunjuk, (c) jari tengah, (d) jari manis, (e) kelingking, (f) genggam, (h) rileks

Sesi perekaman dilakukan selama 40 detik, namun hanya 35 detik yang dipakai, dengan 5 detik awal diabaikan karena penyesuaian data rekaman dari piranti yang digunakan. Setiap subjek akan melakukan 3 kombinasi gerakan dan setiap kombinasi dilakukan 3 perekaman. Kombinasi gerakan dapat dilihat pada Gambar 7.



Gambar 7 Sesi perekaman gerakan

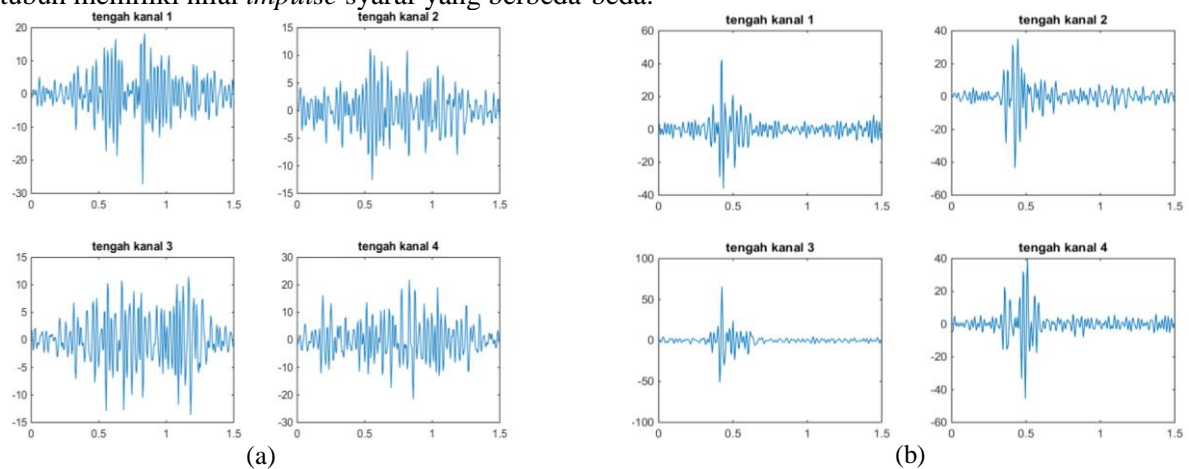
2.6 10-fold Cross Validation

Untuk memvalidasi hasil model jaringan yang dirancang dan dilatihkan, digunakan *10-fold cross validation*. Pembagian data uji dan data latih menggunakan metode *cross validation* artinya akan mengambil data latih sebesar 90% dari total data dan 10% sisanya adalah data uji. Jumlah set data keseluruhan sebesar 350 data sehingga didapatkan 315 set data latih dan 35 set data uji. Pembagian set data dilakukan berimbang di setiap kelas gerakan yaitu 45 set data per kelas gerakan pada set data latih dan 5 set data per kelas gerakan pada set data uji.

3 HASIL DAN PEMBAHASAN

3.1 Sinyal Electromyography Jari Tangan

Sinyal EMG yang dapat dimanfaatkan dan diolah adalah sinyal yang memiliki perubahan bentuk yang jelas antara keadaan rileks dan kontraksi. Saat kontraksi otot terjadi lonjakan nilai tegangan pada sinyal EMG. Lonjakan nilai tersebut menandakan adanya pengiriman *impulse* syaraf saat adanya bagian tubuh yang bergerak. Setiap pergerakan anggota tubuh memiliki nilai *impulse* syaraf yang berbeda-beda.



Gambar 8 Sinyal EMG hasil akuisisi data, (a) tidak dapat digunakan, (b) dapat digunakan

Setelah *preprocessing*, dilakukan pemilahan sinyal sEMG yang dapat diolah dan yang tidak dapat diolah. Gambar 8 (a) merupakan contoh bentuk sinyal sEMG kelas jari tengah (Gambar 6 (c)) yang tidak dapat digunakan karena tidak terlihat jelas perubahan bentuk ketika kontraksi. Gambar 8 (b) merupakan contoh bentuk sinyal sEMG kelas jari tengah yang dapat digunakan karena terlihat jelas perubahan bentuk ketika kontraksi. Perbedaan utama pada kedua contoh tersebut adalah pada amplitudonya, dimana pada Gambar 8 (a), amplitudo relatif lemah dan tidak berubah. Hal tersebut dapat diakibatkan oleh penempelan elektroda yang tidak pas.

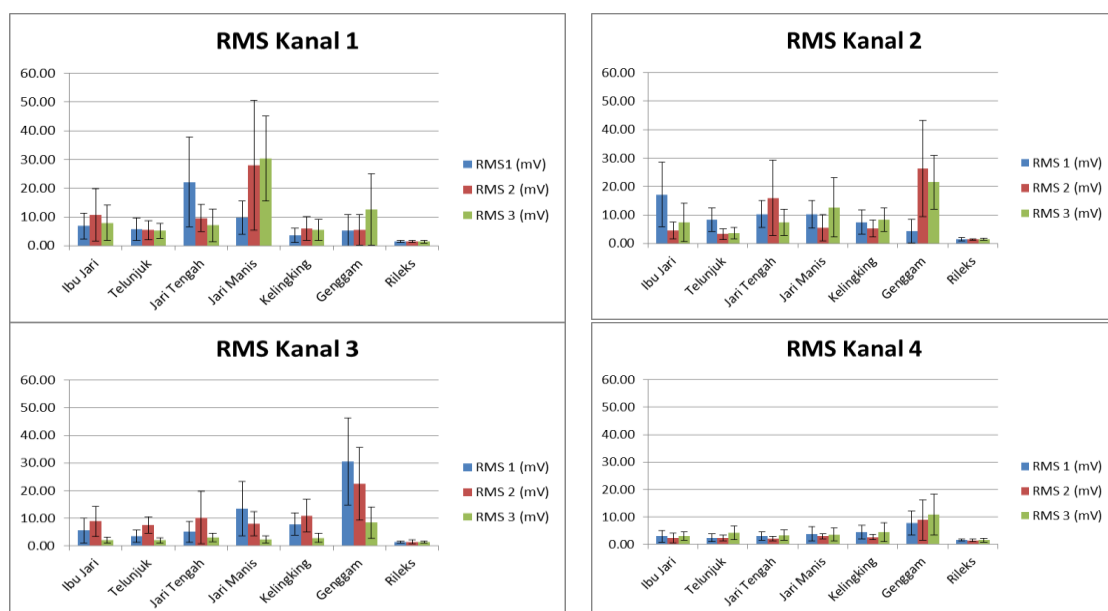
3.2 Ciri RMS untuk setiap kelas gerakan

Penelitian ini menggunakan *Root Mean Square (RMS)* sebagai metode ekstraksi ciri. RMS digunakan untuk mendapatkan nilai *power* sinyal setiap gerakan. Ekstraksi ciri pada penelitian ini ditambah dengan metode *sliding window*. *Sliding window* digunakan untuk mendapatkan bentuk dari sinyal sehingga ciri dapat mewakili bentuk visual sinyal sEMG.

Metode *sliding window* yang digunakan adalah jendela yang tidak berhimpit dengan lebar jendela 500 ms. Lebar jendela 500 ms karena gerakan yang dilakukan pada penelitian ini termasuk ke dalam gerakan lambat dan tangan dalam kondisi statis. Karena satu buah sinyal berlangsung selama 1,5 detik maka dengan lebar jendela tersebut akan membagi sinyal menjadi 3 bagian.

Satu buah sinyal terdapat 300 data yang berarti bila digunakan 3 buah jendela maka satu jendela berisi 100 data yang kemudian akan dicari nilai RMS untuk dijadikan ciri dari sinyal sEMG. Penambahan metode *sliding window* menyebabkan setiap satu kanal memiliki 3 nilai RMS. Karena menggunakan 4 kanal maka total ciri yaitu 12 ciri.

Setiap orang memiliki nilai RMS yang berbeda-beda walaupun pada kelas gerakan yang sama. Persebaran data antar kelas gerakan saling beririsan, hal tersebut yang menyebabkan sulitnya klasifikasi kelas gerakan dengan hanya berdasar pada rentang nilai tertentu. Untuk mengatasi masalah tersebut maka digunakan pendekatan berdasar pada pola *power* sinyal sEMG di setiap kelas dan kanal. Setelah dilihat ternyata pada setiap kanal dan setiap kelas gerakan memiliki pola *power* sinyal sEMG yang berbeda seperti pada Gambar 9. Perbedaan pola tersebut yang kemudian dimanfaatkan sebagai *input* untuk proses klasifikasi.



Gambar 9 Pola rata-rata nilai RMS setiap kelas gerakan pada setiap kanal

3.3 Klasifikasi

Berdasar hasil ekstraksi ciri yaitu nilai RMS memiliki pola pada setiap kelas gerakan di setiap kanal. JST merupakan metode yang cocok untuk klasifikasi, karena JST mampu melakukan klasifikasi berdasar pada pola *input*. Penelitian yang sebelumnya juga menggunakan JST sebagai klasifikator dengan alasan yang serupa dan JST juga termasuk ke dalam metode yang cepat dan ringan. Pada proses klasifikasi menggunakan JST ini terdapat dua subproses yaitu subproses klasifikasi pada pelatihan bobot data latih JST dan subproses pengujian sistem dengan menggunakan bobot JST yang sudah dilatih sebelumnya untuk mengklasifikasi data uji.

Arsitektur JST *backpropagation* pada penelitian ini menggunakan 2 buah *hidden layer* dengan jumlah *node* 12 – 64 – 86 – 7. Fungsi aktivasi yang digunakan adalah *sigmoid bipolar (tansig)* dan identitas (*purelin*). *Node* 12 merupakan *node* yang berisi 12 ciri hasil ekstraksi ciri. *Node* 64 dan 86 merupakan *node* pada kedua lapisan tersembunyi. Penentuan jumlah *hidden layer* dan jumlah *node* di dalamnya menggunakan metode *trial and error* karena hingga saat ini tidak ada metode yang dapat digunakan untuk menentukan jumlah *node hidden layer*.

3.4 Hasil Pengujian

Tabel 3 Rata-rata hasil pengujian dengan metode confusion matrix

Kelas Gerakan	Data Latih			Data Uji		
	Akurasi (%)	Sensitifitas (%)	False Discovery Rate (FDR) (%)	Akurasi (%)	Sensitifitas (%)	False Discovery Rate (FDR) (%)
Ibu jari	82	70	30	89	75	20
Telunjuk	78	64	36	90	77	19
Jari Tengah	93	88	12	93	85	10
Jari Manis	92	86	14	95	89	6
Kelingking	82	70	30	93	83	12
Genggam	97	97	3	94	87	8
Rileks	88	75	25	91	77	18
Rata-rata	87	79	22	92	82	13

Tabel 3 adalah tabel yang menampilkan hasil perhitungan *confusion matrix* terhadap set data latih dan set data uji. Secara umum performa klasifikasi hasil pengujian lebih baik dibanding pelatihan karena jumlah set data pelatihan jauh lebih banyak dibanding set data uji. Penelitian ini menggunakan 10 *fold cross validation* sehingga jumlah data uji hanya sebesar 10% dari total data latih.

Pada Gambar 9 nilai ciri RMS dari kelas gerakan yang akan diklasifikasi memiliki nilai yang saling beririsan sehingga bila semakin banyak set data yang digunakan maka akan semakin banyak terjadi persebaran data yang berakibat pada performa yang menurun. Namun penggunaan set data pelatihan yang banyak jumlahnya diperlukan untuk membangun sistem yang reliabel atau handal karena cakupan penggunaannya semakin luas. Untuk sistem ini diperlukan banyak set data latih karena kekuatan dan kondisi otot setiap orang berbeda sehingga dengan semakin banyak set data latih semakin banyak kondisi otot yang dikenali.

Berdasar Gambar 9 tersebut dapat dilihat juga standar deviasi yang mewakili persebaran set data. Ketika suatu set data pada suatu kelas dalam posisi terendah atau tertinggi dapat beririsan dengan nilai RMS dari kelas gerakan lain. Persebaran data yang lebar itu juga dapat mempengaruhi bentuk dari pola ciri RMS. Sehingga dimungkinkan terjadi kekeliruan dalam klasifikasi karena miripnya pola satu kelas dengan pola kelas yang lain.

3.4.1 Akurasi

Akurasi adalah suatu nilai yang menunjukkan seberapa sering klasifikator mendeteksi data benar. Berdasar pada Tabel 3 rata-rata akurasi hasil pengujian sistem adalah 92% dengan nilai tertinggi 95% pada kelas gerakan jari manis dan terendah 89% pada kelas gerakan ibu jari. Akurasi kelas gerakan jari manis tertinggi disebabkan pola nilai RMS yang terlihat dengan jelas perbedaannya dibanding kelas lain yang dapat dilihat pada Gambar 9. Pola yang berbeda tersebut juga menyebabkan nilai FDR menjadi rendah.

Akurasi terendah dimiliki oleh kelas gerakan ibu jari. Hal tersebut terjadi karena pola nilai RMS kelas gerakan ibu jari yang memiliki kesamaan dengan kelas gerakan lain pada beberapa kanal yang dapat dilihat pada Gambar 9. Pola yang hampir mirip tersebut juga menyebabkan nilai FDR menjadi tinggi. Berdasar Tabel 3 dapat dilihat bahwa bila nilai FDR dan sensitivitas berpengaruh pada nilai akurasi. Bila nilai FDR tinggi dan sensitivitas rendah akan menyebabkan nilai akurasi menurun. Hal tersebut terbukti pada kelas gerakan ibu jari. Kelas tersebut memiliki nilai FDR tertinggi dan nilai sensitivitas terendah sehingga memiliki akurasi terendah dibanding kelas gerakan lain. Bila nilai FDR semakin rendah dan sensitivitas tinggi maka nilai akurasi ikut meningkat seperti pada kelas gerakan jari manis.

Kelas gerakan yang mengalami peningkatan nilai akurasi pengujian dibanding pelatihan adalah kelas gerakan ibu jari, telunjuk, dan kelingking. Peningkatan tersebut terjadi karena nilai FDR yang menurun dan nilai sensitivitas yang meningkat sehingga nilai akurasi ikut meningkat. Sehingga bisa diambil kesimpulan bahwa nilai akurasi dipengaruhi oleh nilai sensitivitas dan FDR karena nilai akurasi memperhitungkan nilai *true positif* (TP) dan *true negatif* (TN) yang berarti lebih mengutamakan kebenaran dari data yang menjadi data input dibanding dengan hasil *output* sistem. Nilai rata-rata akurasi sistem 92% berarti sistem dapat mengetahui dan memilah data *input* sesuai dengan kelasnya secara benar pada semua kelas dengan tingkat kebenaran rata-rata mencapai 92%.

3.4.2 Sensitivitas

Sensitivitas merupakan ukuran yang menyatakan jika pada kenyataannya data itu “ya” dan seberapa sering sistem menyatakan data itu “ya”. Dengan kata lain sistem mampu mengklasifikasikan data dengan benar dari data *input* yang telah dianggap benar sebelumnya. Berdasar Tabel 3 rata-rata sensitivitas sistem setelah dilakukan pengujian yaitu 82%. Nilai tersebut berarti sistem mampu mengklasifikasikan dengan benar data *input* benar dengan tingkat kebenaran 82%.

Berdasar pada Tabel 3 nilai sensitivitas tertinggi dimiliki oleh kelas gerakan jari manis. Hal tersebut berbanding lurus dengan nilai akurasi dan FDR. Semakin tinggi nilai akurasi dan semakin rendah nilai FDR akan meningkatkan nilai sensitivitas. Terbukti juga dengan nilai sensitivitas terendah dimiliki oleh ibu jari yang memiliki nilai akurasi terendah dan nilai FDR tertinggi. Nilai sensitivitas 89% pada kelas gerakan jari manis dapat diartikan bahwa sistem akan menghasilkan *output* benar sebanyak 89% dari data *input* yang sudah dikenali dengan benar.

Nilai rata-rata sensitivitas set data uji lebih tinggi dibanding nilai rata-rata set data latih. Hal ini bisa disebabkan karena rata-rata nilai akurasi set data uji juga lebih tinggi dibanding set data latih. Meningkatnya nilai akurasi akan berimplikasi meningkatnya pengenalan data *input* benar menjadi lebih akurat. Semakin banyak set data *input* yang sudah benar secara langsung akan meningkatkan nilai sensitivitas karena sensitivitas lebih mengutamakan perhitungan atas data input yang benar. Semakin menurunnya nilai FDR juga akan meningkatkan nilai sensitivitas dan akurasi karena FDR mengenali data input yang salah/tidak sesuai. Sehingga bila nilai FDR semakin menurun maka semakin sedikit set data input yang salah dikenali oleh sistem.

Suatu kesimpulan dapat ditarik mengenai nilai sensitivitas yaitu nilai sensitivitas lebih spesifik ke dalam penentuan kebenaran dari suatu nilai *output* sistem. Hal tersebut karena

sensitivitas lebih mengutamakan perhitungan *true positif* (TP) yaitu sistem menyatakan data itu benar terhadap data *input* yang sebelumnya sudah dikatakan benar.

3.4.3 False Discovery Rate

FDR merupakan ukuran yang menyatakan jika pada kenyataannya data itu “tidak” dan seberapa sering sistem menyatakan data itu “ya”. Dengan kata lain FDR merupakan sebuah ukuran yang menyatakan tingkat kekeliruan sistem dalam mengenali dan mengklasifikasikan suatu data *input*. Berdasar Tabel 3 rata-rata nilai FDR hasil pengujian adalah 13%. Angka tersebut berarti sistem ini memiliki kemungkinan keliru dalam mengenali suatu data *input* dengan benar sebesar 13%.

Nilai FDR tertinggi pada kelas gerakan ibu jari dengan nilai 20%. Angka tersebut berarti ada 20% set data kelas gerakan lain yang dikenali sebagai kelas gerakan jari tengah. Hal ini terjadi karena berdasar pada Gambar 9 nilai ciri RMS pada setiap kelas gerakan saling beririsan satu dengan yang lain. Nilai yang beririsan dapat dilihat dari nilai standar deviasi pada setiap ciri yang besar. Sehingga sangat dimungkinkan klasifikator keliru dalam mengklasifikasikan suatu set data *input*. Bentuk pola nilai yang sama antar kelas gerakan yang satu dengan yang lain juga dapat menimbulkan kekeliruan dalam sistem. Bentuk pola yang sama seperti terjadi pada kelas gerakan jari tengah yang polanya mirip dengan kelas gerakan telunjuk, jari tengah, dan kelingking pada kanal 3. Ketiga kelas gerakan tersebut juga memiliki nilai FDR yang tinggi.

Nilai FDR terendah pada kelas gerakan jari manis dengan nilai 6%. Angka tersebut berarti hanya sekitar 6% set data kelas lain yang dikenali sebagai kelas gerakan jari manis. Hal tersebut dapat terjadi karena pola gerakan jari manis berbeda dengan kelas gerakan lain yang dapat dilihat pada Gambar 9. Dua dari empat kanal memiliki pola ciri yang jelas berbeda dengan kelas gerakan lain. Nilai ciri RMS dari kelas gerakan jari manis memiliki nilai tertinggi kedua setelah kelas gerakan genggam. Hal tersebut mengurangi peluang untuk kelas gerakan lain dikenali sebagai kelas gerakan jari manis yang menyebabkan nilai FDR rendah.

Nilai FDR lebih memperhitungkan nilai *false positif* (FP) yang berarti sistem mengklasifikasikan set data *input* yang salah ke dalam suatu kelas dan menyatakan bahwa itu benar. Nilai FDR akan mempengaruhi nilai akurasi sistem. Semakin tinggi nilai FDR semakin rendah nilai akurasi begitu sebaliknya. Hal itu karena perhitungan nilai akurasi dan FDR saling berkebalikan. Akurasi lebih mengutamakan set data *input* yang benar sedangkan FDR memperhitungkan set data yang tidak benar.

4 KESIMPULAN

Sistem klasifikasi gerakan jari tangan manusia memanfaatkan sinyal sEMG berkompleksitas rendah menggunakan *Ganglion Board* telah berhasil dibuat. Sistem tersebut dapat mengklasifikasikan 7 kelas gerakan yaitu kelas gerakan ibu jari, telunjuk, jari tengah, jari manis, kelingking, genggam, dan rileks. Hasil akurasi sistem untuk kelas gerakan ibu jari 89%, telunjuk 90%, jari tengah 93%, jari manis 95%, kelingking 93%, genggam 94%, rileks 91%. Sehingga rata-rata akurasi sistem yaitu 92%. Sistem yang dirancang pada penelitian ini memiliki kompleksitas yang lebih sederhana karena jumlah kanal yang digunakan lebih sedikit yaitu sejumlah 4 kanal, klasifikasi kelas yang lebih banyak dibanding dengan sistem pada penelitian sebelumnya namun tetap memiliki performa yang baik.

5 SARAN

Mencoba untuk membuat sistem yang bekerja secara *on-line* sehingga dapat melakukan klasifikasi gerakan jari tangan manusia secara nyata dan mengintegrasikan sistem klasifikasi gerakan jari manusia secara *real-time*.

DAFTAR PUSTAKA

- [1] A. Junlasat, T. Kamolklang, P. Uthansakul, and M. Uthansakul, "Finger Movement Detection Based on Multiple EMG Positions," *2019 11th International Conference on Information Technology and Electrical Engineering, ICITEE 2019*, vol. 7, pp. 7–10, 2019, doi: 10.1109/ICITEED.2019.8929980.
- [2] M. Barsotti, S. Dupan, I. Vujaklija, S. Došen, A. Frisoli, and D. Farina, "Online Finger Control Using High-Density EMG and Minimal Training Data for Robotic Applications," *IEEE Robotics and Automation Letters*, vol. 4, no. 2, pp. 217–223, 2019, doi: 10.1109/LRA.2018.2885753.
- [3] I. Yeo and H. C. Shin, "Novel Korean finger language recognition using EMG and motion sensors," *International Conference on Information Networking*, vol. 2018-Janua, pp. 837–839, 2018, doi: 10.1109/ICOIN.2018.8343238.
- [4] K. Rhee and H. C. Shin, "Finger motion recognition robust to diverse arm postures using EMG and accelerometer," *International Conference on Information Networking*, vol. 2018-Janua, pp. 834–836, 2018, doi: 10.1109/ICOIN.2018.8343237.
- [5] T. Hiyama, S. Sakurazawa, M. Toda, J. Akita, K. Kondo, and Y. Nakamura, "Motion estimation of five fingers using small concentric ring electrodes for measuring surface electromyography," *2014 IEEE 3rd Global Conference on Consumer Electronics, GCCE 2014*, no. 2001, pp. 376–380, 2015, doi: 10.1109/GCCE.2014.7031268.
- [6] F. Zhang, L. Lin, L. Yang, and Y. Fu, "Design of an active and passive control system of hand exoskeleton for rehabilitation," *Applied Sciences (Switzerland)*, vol. 9, no. 11, 2019, doi: 10.3390/app9112291.
- [7] N. Naseer, F. Ali, S. Ahmed, S. Iftikhar, R. A. Khan, and H. Nazeer, "EMG Based Control of Individual Fingers of Robotic Hand," *3rd International Conference on Sustainable Information Engineering and Technology, SIET 2018 - Proceedings*, pp. 6–9, 2018, doi: 10.1109/SIET.2018.8693177.
- [8] N. Nazmi, M. A. A. Rahman, S. I. Yamamoto, S. A. Ahmad, H. Zamzuri, and S. A. Mazlan, "A review of classification techniques of EMG signals during isotonic and isometric contractions," *Sensors (Switzerland)*, vol. 16, no. 8, pp. 1–28, 2016, doi: 10.3390/s16081304.
- [9] M. Li *et al.*, "An attention-controlled hand exoskeleton for the rehabilitation of finger extension and flexion using a rigid-soft combined mechanism," *Frontiers in Neurobotics*, vol. 13, no. May, pp. 1–13, 2019, doi: 10.3389/fnbot.2019.00034.
- [10] C. Dai and X. Hu, "Finger Joint Angle Estimation Based on Motoneuron Discharge Activities," *IEEE Journal of Biomedical and Health Informatics*, vol. 24, no. 3, pp. 760–767, 2020, doi: 10.1109/JBHI.2019.2926307.
- [11] S. Stapornchaisit, Y. Kim, A. Takagi, N. Yoshimura, and Y. Koike, "Finger angle estimation from array EMG system using linear regression model with independent component analysis," *Frontiers in Neurobotics*, vol. 13, no. September, pp. 1–12, 2019, doi: 10.3389/fnbot.2019.00075.
- [12] X. Li, J. Fu, L. Xiong, Y. Shi, R. Davoodi, and Y. Li, "Identification of finger force and motion from forearm surface electromyography," *IEEE International Conference on Multisensor Fusion and Integration for Intelligent Systems*, vol. 2015-October, pp. 316–321, 2015, doi: 10.1109/MFI.2015.7295827.

- [13] A. H. Al-timemy, S. Member, G. Bugmann, J. Escudero, and N. Outram, "Classification of Finger Movements for the Dexterous Hand Prosthesis Control With Surface Electromyography," *IEEE Journal of Biomedical and Health Informatics*, vol. 17, no. 3, pp. 608–618, 2013, doi: 10.1109/JBHI.2013.2249590.
- [14] C. Atmaji and Z. Y. Perwira, "Pengaruh Latar Belakang Warna pada Objek Gambar terhadap Hasil Ekstraksi Sinyal EEG," *Indonesian Journal of Electronics and Instrumentation System*, vol. 7, no. 2, pp. 161–172, 2017.
- [15] P. Liu, D. R. Brown, E. A. Clancy, F. Martel, and D. Rancourt, "EMG-force estimation for multiple fingers," *2013 IEEE Signal Processing in Medicine and Biology Symposium, SPMB 2013*, 2013, doi: 10.1109/SPMB.2013.6736772.