

Peramalan kekuatan gerak tangan menggunakan *Extreme Learning Machine* untuk terapi pasca-stroke

Hand motion strength forecasting using *Extreme Learning Machine* for post-stroke rehabilitation

Khairul Anam^{*)}, Ali Rizal Chaidir, Fahrul Isman

Jurusan Teknik Elektro, Fakultas Teknik, Universitas Jember
Jl. Kalimantan No.37, Kampus Tegalboto, Jember, Indonesia 68121

Cara sitasi: K. Anam, A. R. Chaidir and F. Isman, "Peramalan kekuatan gerak tangan menggunakan Extreme Learning Machine untuk terapi pasca-stroke," *Jurnal Teknologi dan Sistem Komputer*, vol. 9, no. 2, pp. 70-76, 2021. doi: [10.14710/jtsiskom.2021.13844](https://doi.org/10.14710/jtsiskom.2021.13844), [Online].

Abstract – Stroke or Cerebrovascular accident (CVA) can cause weakness in one side of the body, including the upper limbs such as the hand. Rehabilitation is needed to restore the function of the hand. Rehabilitation should also measure the strength of the movements carried out. This article aims to forecast the strength of movement based on Electromyography (EMG) signals using the Extreme Learning Machine (ELM). This study collected EMG signal data and movement strength, carried out data pre-processing and data extraction using various extraction features, applied ELM for forecasting strength based on EMG signals, and applied created models in stroke therapy robots. The forecasting model is evaluated by measuring the Mean Squared Error (MSE). The average value of the best MSE in offline testing is 1.77, while the real-time testing is 0.79. A small MSE value indicates that the model is good enough. The resulted value of strength can be applied to make the stroke therapy robots actuating properly.

Keywords – electromyography; Extreme Learning Machine; forecasting; hand-robot; stroke rehabilitation

Abstrak – Stroke atau Cerebrovascular accident (CVA) dapat menyebabkan kelemahan pada salah satu bagian sisi tubuh termasuk anggota gerak atas, seperti tangan, sehingga diperlukan rehabilitasi untuk mengembalikan fungsi dari tangan. Rehabilitasi yang dilakukan sebaiknya juga dapat mengukur kekuatan dari gerakan yang dilakukan. Artikel ini bertujuan untuk melakukan peramalan kekuatan gerakan berdasarkan sinyal Electromyography (EMG) menggunakan metode Extreme Learning Machine (ELM). Tahapan yang dilakukan meliputi pengumpulan data sinyal EMG dan kekuatan gerakan, pre-processing data dan ekstraksi fitur data menggunakan berbagai fitur ekstraksi, penerapan ELM untuk peramalan kekuatan berdasarkan sinyal

EMG, dan penerapan model yang dibuat pada robot terapi stroke. Evaluasi model peramalan dilakukan dengan mengukur Mean Squared Error (MSE). Nilai rata-rata MSE terbaik pada pengujian offline adalah 1,77, sedangkan pada pengujian real-time sebesar 0,79. Nilai MSE yang kecil menunjukkan bahwa model yang dibuat sudah cukup baik. Pergerakan robot berdasarkan nilai kekuatan yang dilakukan sudah dapat bergerak dengan baik.

Kata kunci – electromyography; Extreme Learning Machine; peramalan; robot tangan; terapi stroke

I. PENDAHULUAN

Stroke atau Cerebrovascular accident (CVA) merupakan sebuah kejadian berkurangnya atau terhentinya aliran darah yang dapat mengakibatkan kematian pada sel-sel otak [1]. Berdasarkan [2], 15 juta orang di seluruh dunia telah menderita stroke setiap tahunnya. Stroke dapat menyebabkan kelemahan pada salah satu bagian atau sisi tubuh (*hemiparesis*). Hal ini menyebabkan seseorang kesulitan untuk menggerakkan dan menggunakan salah satu sisi bagian tubuhnya [3].

Bagi pasien yang telah mengalami stroke, rehabilitasi merupakan cara agar mampu untuk melakukan aktivitas hidup sehari-hari seperti semula [4]. Rehabilitasi mengembalikan kemandirian dari penderita untuk melakukan aktivitas sehari-hari sehingga tidak menjadi suatu beban bagi keluarganya. Salah satu metode rehabilitasi adalah berlatih bergerak. Terapi gerak yang dilakukan sebaiknya juga merupakan gerakan fungsional. Gerak fungsional yang bisa dilakukan misalnya gerakan menggenggam untuk meraih, memegang, dan membawa gelas ke mulut [5].

Dalam terapi gerak tangan, kekuatan genggam menjadi salah satu bagian penting yang perlu diperbaiki. Terapi rehabilitasi berbasis teknologi memberikan latihan terapi yang lebih interaktif, efektif dan independen, dibandingkan dengan terapi rehabilitasi yang konvensional. Salah satunya adalah dengan menggunakan teknologi robot untuk meningkatkan kinerja motorik pasien [6].

^{*)} Penulis korespondensi (Khairul Anam)
Email: khairul@unej.ac.id

Robotika dapat memberikan strategi terapi baru yang berfokus pada pengurangan gangguan dan peningkatan kinerja motorik. Salah satunya jenis robot yang bisa dipakai dalam rehabilitasi adalah robot *exoskeleton* [7], [8]. Robot *exoskeleton* dapat menunjukkan interaksi kognitif dan fisik yang dekat dengan pengguna manusia. Robot ini biasanya beroperasi bersama anggota tubuh manusia [9]. Contoh robot *exoskeleton* adalah robot terapi untuk ekstremitas atas [10], [11]. Ekstremitas atas atau anggota gerak atas merupakan hal yang fundamental dalam melakukan aktivitas sehari-hari [12]. Robot ekstremitas atas dapat dikendalikan dengan sinyal *Electromyography* atau EMG [13], [14].

EMG merupakan sebuah teknik merekam aktivitas listrik untuk mengevaluasi fungsi saraf dan otot [10], [15]. Beberapa robot sudah dapat digerakan berdasarkan sinyal EMG [16]. Untuk mendapatkan kekuatan berdasarkan sinyal EMG, robot dapat menggunakan metode peramalan. Peramalan ini digunakan untuk memperkirakan nilai-nilai data *time series* di masa depan [17]. Metode *Extreme Learning Machine* (ELM) merupakan salah satu metode yang dapat digunakan untuk peramalan. ELM dapat menghasilkan akurasi yang relatif baik dan pembelajaran yang memakan sedikit waktu dibandingkan metode lain [18], [19].

ELM sebenarnya ada di sebuah jaringan syaraf tiruan yang hanya memiliki satu layar tersembunyi [20]. Keunggulan dari ELM adalah pada proses pembelajarannya yang cepat karena tidak perlu proses iterasi sebagaimana pembelajaran menggunakan *backpropagasi*. Hal tersebut dapat terjadi karena bobot pada lampiran tersembunyi ditentukan secara acak dan tidak diubah selama pelatihan. Yang diubah adalah hanya bobot pada lapisan keluaran yang ditentukan secara analitik menggunakan metode *least square*.

Penelitian ini bertujuan untuk mengembangkan peramalan kekuatan genggam tangan menggunakan metode ELM yang dapat diterapkan pada robot tangan untuk terapi pasca stroke. Peramalan ini menggunakan sinyal EMG untuk mendapatkan besaran kekuatan dari gerakan yang dilakukan. Pengembangan ini diharapkan dapat mengetahui kekuatan gerakan jari tangan dari pengguna robot terapi yang belum dilakukan sebelumnya. Sejauh pengetahuan penulis, prediksi kekuatan genggam tangan juga diteliti oleh [18], namun penelitian mereka hanya sebatas prediksi, belum sampai ke penerapan pada robot. Artikel ini, tidak hanya menampilkan hasil prediksi, tetapi juga telah diterapkan langsung pada robot.

II. METODE PENELITIAN

Tahapan yang dilakukan pada penelitian ini adalah pengumpulan data, proses ekstraksi sinyal EMG, penerapan ELM, dan penerapan model pada robot.

A. Pengumpulan data

EMG digunakan untuk merekam aktivitas elektrik dari otot untuk menentukan apakah otot sedang melakukan kontraksi atau tidak [15]. Pengumpulan data



Gambar 1. Posisi Myo Armband dan Handgrip Dinamometer saat pengambilan data

Tabel 1. Data diri subjek penelitian

Subjek	Jenis Ke- lamin	Umur (tahun)	Tinggi Badan (cm)	Berat Badan (kg)	Kondisi
S1	Pria	25	165	65	Normal
S2	Pria	21	170	70	Normal
S3	Pria	23	165	63	Normal
S4	Pria	21	168	69	Normal
S5	Pria	22	172	65	Normal

sinyal EMG dilakukan menggunakan sensor Myo Armband. Data kekuatan diperoleh menggunakan Handgrip Dinamometer.

Proses pengumpulan data dilakukan menggunakan Handgrip Dinamometer dan Myo Armband yang dipasangkan di bawah siku tangan pada tangan kanan [21]. Jari tangan menggenggam Handgrip Dinamometer untuk mendapatkan data kekuatan bersamaan dengan data sinyal EMG. Proses pengambilan data dilakukan dengan subjek menggenggam Handgrip Dinamometer dengan kekuatan 0 sampai 7 N. Nilai ini akan menjadi target kekuatan yang akan diprediksi oleh sistem. Myo Armband dipasang melingkar pada lengan bawah dekat dengan siku subjek seperti pada Gambar 1. Subjek pada penelitian ini sebanyak 5 orang dengan kondisi normal atau tidak mengalami stroke dengan posisi yang sama untuk semua subyek. Data subjek penelitian dinyatakan pada Tabel 1.

Pengambilan data dilakukan selama 30 detik untuk setiap kekuatan genggam tangan. Myo Armband yang digunakan memiliki frekuensi sebesar 50 Hz sehingga dalam 30 detik didapatkan 1500 data berupa nilai *Analog To Digital Converter* (ADC) dari EMG untuk setiap kekuatan gerakan. Jumlah kanal dari Myo Armband yang digunakan adalah semua kanal, yaitu sebanyak 8.

B. Fitur ekstraksi sinyal EMG

Sinyal EMG yang diperoleh perlu diolah terlebih dahulu agar dapat digunakan. Salah satu cara yang dilakukan adalah ekstraksi fitur menggunakan fitur domain waktu [22]. Metode ekstraksi yang digunakan di antaranya adalah *Mean Absolute Value* (MAV), *Variance* (VAR), dan *Root Mean Square* (RMS) [23]. MAV digunakan untuk menghitung pergeseran *window* (Persamaan 1). Metode ini digunakan untuk menghitung

nilai rata-rata dari setiap sinyal EMG pada setiap *window*, sehingga pada setiap pergeseran dapat diketahui durasinya. Metode *Variance* (VAR) pada penelitian ini menggunakan variabilitas dari sinyal EMG (Persamaan 2). VAR dapat menjadi indikator dari kekuatan sinyal pada sinyal EMG dan dapat membantu mengidentifikasi kontraksi perpindahan. Metode RMS bekerja dengan menghitung pergeseran *window* (Persamaan 3). Pergeseran *window* ini dihitung dengan mencari akar rata-rata dari kuadrat nilai sinyal EMG.

$$MAV = \frac{1}{N} \sum_{n=1}^N |x_n| \quad (1)$$

$$VAR = \frac{1}{N-1} \sum_{n=1}^N |x_n|^2 \quad (2)$$

$$RMS = \sqrt{\frac{1}{N} \sum_{n=1}^N |x_n|^2} \quad (3)$$

C. Penerapan metode *Extreme Learning Machine*

ELM merupakan suatu metode pembelajaran dari Jaringan Syaraf Tiruan (JST) yang menggunakan arsitektur *Single Hidden Layer Feedforward Neural Network*. Metode ELM ini dibuat untuk dapat mengatasi masalah pada metode JST, yakni dalam hal kecepatan pembelajaran [24]. Semua parameter ELM, seperti bobot masukan dan bias tersembunyi, dipilih secara acak sehingga pada saat pelatihan dapat dilakukan dengan cepat [25].

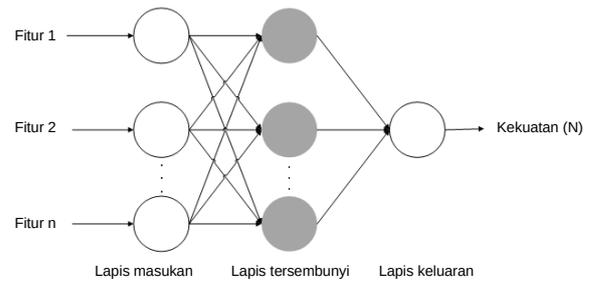
Struktur ELM dibuat menggunakan jaringan syaraf tiruan dengan sebuah lapis tersembunyi (Gambar 2). Masukan dari sistem yang dibuat adalah sinyal EMG yang sudah ekstraksi dengan fitur ekstraksi sebelumnya. Jumlah *node* dari masukan sebanyak fitur yang masuk, yaitu sebanyak 8 buah. Pada lapis tersembunyi, digunakan fungsi aktivasi *Radial Basis Function* (RBF). Keluaran dari sistem peramalan yang dibuat berupa kekuatan gerakan.

Secara umum, fungsi yang digunakan untuk *Single Hidden Layer Feedforward Neural Networks* dinyatakan pada Persamaan 4. Parameter j menyatakan indeks bilangan 1, 2, ..., N, w_i menyatakan *weight*, β_i bobot, b_i nilai ambang dari i node tersembunyi dan $w_i x_j$ adalah perkalian dari w_i dan x_j .

$$\sum_{i=1}^N \beta_i g_1(x_j) = \sum_{i=1}^N \beta_i g_1(x_j) (w_i x_j + b_i) = o_j \quad (4)$$

Langkah-langkah yang digunakan untuk menghitung dengan metode ELM adalah sebagai berikut :

- Menentukan bobot masukan dan nilai bias secara acak,
- Menghitung nilai keluaran pada lapis tersembunyi (Persamaan 5),
- Menghitung bobot akhir dari lapis tersembunyi (Persamaan 6), dan
- Menghitung semua keluaran di unit keluaran (Persamaan 7).



Gambar 2. Struktur jaringan *Extreme Learning Machine*

$$G(a_1, x_1, b_1) = \sum_{i=1}^N (a_i x_j + b_i) \quad (5)$$

$$\beta = H^* T \quad (6)$$

$$g(x) = \frac{1}{1 + e^{-x}} \quad (7)$$

Proses pembelajaran pada jaringan syaraf tiruan terbagi menjadi pengujian secara *offline* dan *real-time*. Pada pembelajaran secara *offline*, perbaikan bobot jaringan menggunakan error dari seluruh sampel data. Proses pembaruan dari bobot pada pembelajaran *offline* dilakukan berdasarkan galat yang diperoleh dari semua set masukan tanpa tambahan data baru. Sedangkan pembelajaran secara *real-time* merupakan pembelajaran dengan proses perbaikan bobot nya dilakukan pada setiap sampel data yang dilatih pada setiap iterasi. Pembelajaran ini menggunakan proses pembaruan secara *real-time* dengan tambahan data-data baru [26].

Agar model yang dibuat dapat bekerja, maka proses pelatihan dan pengujian diperlukan dengan menggunakan data yang telah diperoleh. Proses ini menggunakan teknik validasi silang *k-fold*, yaitu 5 *fold*. Data yang sudah dikumpulkan dibagi menjadi 5 bagian dengan masing-masing 20 % dari keseluruhan data. Pada perulangan 1, 20 % data pada *fold* 1 digunakan sebagai data uji dan 80 % data pada *fold* 2 - 5 sebagai data latih. Pada perulangan 2, data uji yang digunakan adalah data pada *fold* 2, sedangkan data pada *fold* lain sebagai data latih. Proses ini berlangsung sebanyak 5 perulangan atau *split* (Gambar 3).

Evaluasi dari model yang dibuat menggunakan persamaan *Mean Squared Error* (MSE) atau rata-rata kuadrat kesalahan peramalan (Persamaan 8). Semakin kecil nilai MSE, maka hasil peramalan semakin mendekati nilai aktual. Pengujian dilakukan sejumlah N, yaitu 17 kali. Parameter x_i menyatakan nilai aktual, sedangkan \hat{x}_i nilai peramalan.

$$MSE = \frac{1}{N} \sum_{i=1}^N (x_i - \hat{x}_i)^2 \quad (8)$$

D. Penerapan pada robot tangan

Robot tangan yang digunakan untuk terapi stroke menggunakan aktuator berupa motor linier yang dipasang pada jari-jari robot (Gambar 4). Penerapan model ELM

yang dibuat pada robot menggunakan *hardware* Raspberry pi untuk melakukan proses peramalan. Pengujian yang dilakukan adalah untuk mengetahui akurasi peramalan dan pergerakan robot setelah mendapat masukan kekuatan. Pengambilan data dan pengujian robot pada penelitian ini telah melalui uji etik di Komisi Etik Penelitian Kesehatan (KEPK) Fakultas Kedokteran Gigi Universitas Jember dengan nomor 407/UN25.8/KEPK/DL/2019 dan tidak ada masalah etik.

III. HASIL DAN PEMBAHASAN

Hasil yang diperoleh di antaranya adalah grafik sinyal EMG, sinyal EMG setelah mengalami proses ekstraksi, hasil peramalan menggunakan ELM, dan hasil peramalan kekuatan saat diterapkan pada robot.

A. Sinyal EMG

Sinyal EMG dalam penelitian ini dideteksi menggunakan sensor Myo Armband. Sinyal EMG diperoleh dengan gerakan menggenggam. Pada Myo Armband terdapat 8 buah kanal sehingga didapatkan 8 buah sinyal amplitude yang masih sulit untuk dapat langsung digunakan (Gambar 5). Data yang diperoleh merupakan data positif. Rentang nilai ADC yang didapat dari Myo Armband dari 0 – 1023. Nilai ADC ini diubah menjadi tegangan.

Setelah itu, sinyal EMG diolah menggunakan fitur ekstraksi dengan tujuan mempermudah pada proses pengolahan data. Hasil ekstraksi menunjukkan sinyal yang lebih halus dan mudah untuk dianalisis dibandingkan sebelum diekstraksi (Gambar 6). Energi potensial dari satuan unit gerak kurang dari 2 mV sesuai [27]. Penguatan dilakukan sampai maksimal 1000x agar sinyal dapat dianalisis lebih lanjut. Gambar 6 merupakan data amplitude yang sudah mengalami penguatan dari modul Myo Armband sehingga mudah untuk menentukan kondisi kontraksi otot sesuai [15], [21].

B. Hasil validasi data

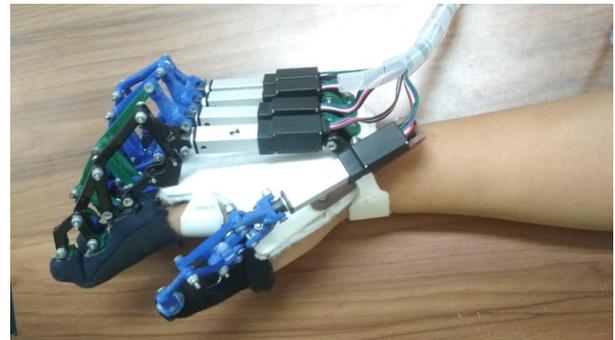
Data pada penelitian ini dibagi menjadi dua, yaitu untuk data latih dan data uji. Data hasil peramalan dibandingkan dengan nilai aktual untuk mengetahui akurasi (Tabel 2). Nilai aktual merupakan nilai kekuatan yang diinginkan atau target kekuatan sedangkan nilai peramalan merupakan nilai yang didapatkan dari keluaran model yang dibuat. Keseluruhan data peramalan mempunyai pola yang sama, yaitu nilai peramalan selalu di bawah dari nilai aktual. Pada sebagian besar data, selisih dari nilai aktual dan peramalan tidak terlalu besar sehingga MSE seharusnya juga tidak terlalu besar. Akan tetapi, terdapat selisih yang cukup besar pada kekuatan 0 N yang mengakibatkan MSE menjadi lebih besar.

Validasi data latih dan uji dilakukan menggunakan metode k-fold dan dilakukan 5 validasi silang untuk menghindari kesalahan data peramalan. Validasi silang dilakukan sebanyak 5 kali *split* dan dihasilkan 5 data hasil peramalan. Data ini dirata-ratakan untuk mendapatkan hasil akurasi peramalan seperti pada Tabel 3.

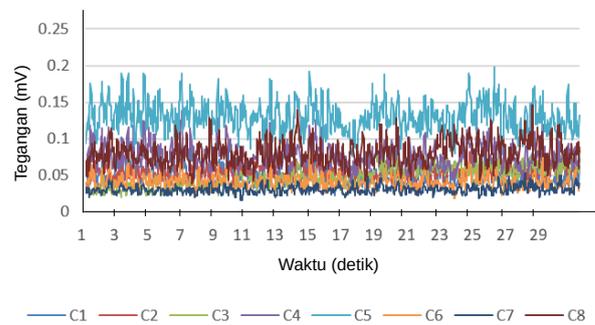
	fold 1	fold 2	fold 3	fold 4	fold 5
split 1	1	2	3	4	5
split 2	1	2	3	4	5
split 3	1	2	3	4	5
split 4	1	2	3	4	5
split 5	1	2	3	4	5

Data uji
 Data latih

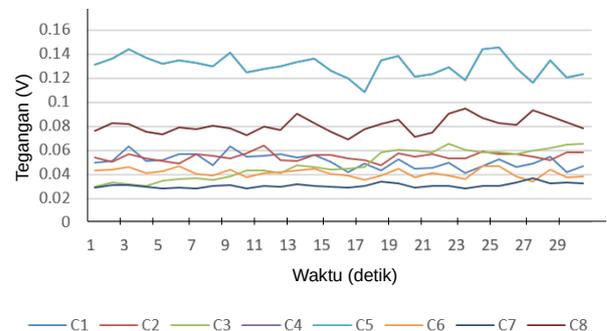
Gambar 3. Pembagian data uji dan data latih dengan validasi silang 5-fold



Gambar 4. Robot tangan untuk terapi pasca-stroke



Gambar 5. Grafik sinyal EMG dari Myo Armband saat menggenggam dengan kekuatan 7 N



Gambar 6. Sinyal EMG dengan fitur ekstraksi MAV saat menggenggam dengan kekuatan 7 N

C. Akurasi peramalan berdasarkan fitur ekstraksi

Pengujian fitur ekstraksi bertujuan untuk mengetahui fitur yang baik untuk digunakan pada sinyal EMG yang didapat dari Myo Armband. Parameter yang diuji adalah berbagai fitur ekstraksi dengan menggunakan fungsi

Tabel 2. Perbandingan nilai aktual dan peramalan

No	Aktual (N)	Peramalan (N)	Kesalahan (N)
1	0	-1,51	1,51
2	0	-1,99	1,99
3	0	0,55	0,55
4	1	0,91	0,09
5	1	0,99	0,01
6	2	2,0	0,00
7	2	1,99	0,01
8	3	2,96	0,04
9	3	2,95	0,05
10	4	3,90	0,10
11	4	3,94	0,06
12	5	4,97	0,03
13	5	4,99	0,01
14	6	5,98	0,02
15	6	5,98	0,02
16	7	6,97	0,03
17	7	6,99	0,01

aktivasi RBF pada ELM. Hasil peramalan ditunjukkan dengan nilai MSE dan standar deviasi (STD). Dari pengujian yang dilakukan, fitur MAV memiliki nilai MSE terkecil (Tabel 4).

Terdapat perbedaan MSE dari masing-masing fitur ekstraksi yang diuji. Fitur ekstraksi MAV memiliki MSE terkecil dengan fungsi aktivasi RBF, yaitu sebesar 1,77. Pada pengujian dengan gabungan dari 3 fitur ekstraksi, didapatkan hasil MSE 2,94 (Tabel 5). Pengujian fitur gabungan masih memiliki MSE yang lebih besar dibandingkan MAV. Gambar 7 menunjukkan perbedaan dari berbagai fitur ekstraksi yang digunakan [18], [19].

D. Pengujian peramalan secara *real-time*

Pengujian secara *real-time* merupakan pengujian model ELM yang dibuat kepada subjek secara langsung. Data EMG yang didapat menggunakan Myo Armband diproses secara langsung untuk menghasilkan data kekuatan. Parameter yang digunakan pada pengujian ini adalah fitur MAV dengan fungsi aktivasi RBF dan jumlah neuron pada lapis tersembunyi ELM sejumlah 500 neuron. Dari pengujian *real-time*, dimungkinkan terdapat beberapa data peramalan kekuatan yang tidak sesuai dengan data kekuatan aktualnya. Pengujian dilakukan selama 80 detik dengan total 80 peramalan dan dilakukan sebanyak 10 kali untuk setiap kekuatan.

Pengujian *real-time* memiliki MSE 0,24 seperti pada Gambar 8. Hal ini menunjukkan bahwa peramalan menggunakan model ELM yang dirancang saat diuji secara *real-time* sudah cukup baik seperti [18], terutama pada pengujian dengan subjek 2 dengan MSE yang kecil. Perbedaan hasil MSE ini dapat terjadi karena perbedaan diameter dan massa otot dari subjek [15]. Subjek S2 memiliki diameter lengan yang lebih besar sehingga Myo Armband terpasang dengan sangat erat pada lengannya dan memberikan pembacaan data EMG yang lebih baik. Hal ini berkebalikan dengan subjek S3 yang memiliki lingkaran lengan yang lebih kecil.

Tabel 3. Hasil MSE validasi silang 5-fold untuk rata-rata kekuatan genggam 0 N sampai 7 N

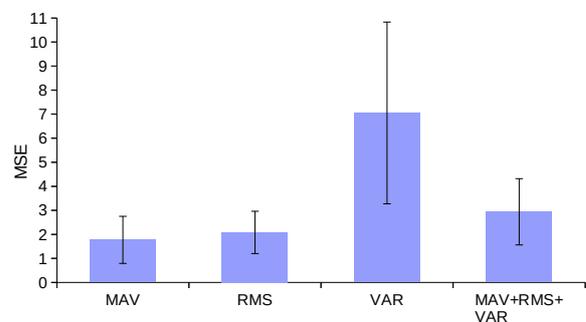
Subjek	Split					Rata-rata
	1	2	3	4	5	
S1	2,46	2,75	1,73	2,78	2,21	2,39
S2	0,60	1,16	1,66	0,85	1,21	1,10
S3	1,73	1,98	2,81	2,51	2,41	2,29
S4	1,69	1,64	2,21	1,67	1,32	1,71
S5	1,37	0,90	0,97	1,18	1,05	1,09

Tabel 4. Hasil akurasi fitur EMG menggunakan fungsi aktivasi ELM dengan berbagai fitur untuk rata-rata kekuatan genggam 0 N sampai 7 N

Subjek	Fitur EMG					
	MAV		RMS		VAR	
	MSE	STD	MSE	STD	MSE	STD
S1	2,96	±2,4	2,72	±2,05	9,56	±7,38
S2	0,97	±0,49	0,95	±0,51	11,71	±6,49
S3	1,97	±1,03	1,95	±0,86	4,51	±1,23
S4	1,73	±0,66	1,77	±0,66	4,43	±1,11
S5	1,25	±0,32	1,26	±0,33	5,19	±2,7
Rata-rata	1,77	±0,98	2,08	±0,88	7,08	±3,78

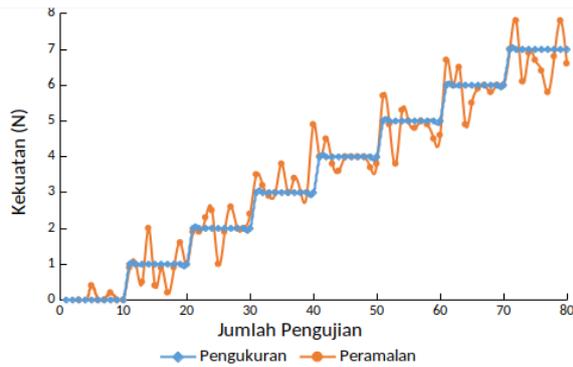
Tabel 5. Hasil akurasi fitur EMG dengan gabungan 3 fitur untuk rata-rata kekuatan genggam 0 N sampai 7 N

Subjek	Fitur MAV+RMS+VAR	
	MSE	STD
S1	2,95	±1,30
S2	0,64	±0,41
S3	5,92	±3,53
S4	2,27	±0,42
S5	2,93	±2,38
Rata-rata	2,94	±1,38

**Gambar 7.** Perbandingan MSE fitur ekstraksi dengan validasi silang 5-fold

E. Penerapan pada robot tangan

Pengujian robot ini juga dilakukan untuk mengetahui kinerja dari model ELM yang dibuat saat diterapkan pada robot. Penerapan pada robot dilakukan dengan berbagai tahap, yaitu pengambilan data sinyal



Gambar 8. Pengujian peramalan secara *real-time*

EMG, pengolahan sinyal, peramalan kekuatan menggunakan ELM sampai dengan keluaran *Pulse Width Modulation* (PWM) untuk menggerakkan aktuator pada robot. Nilai PWM untuk aktuator ditentukan berdasarkan peramalan kekuatan gerak adalah kekuatan 0–7 N. Aktuator robot menggunakan motor linier L12 yang bergerak berdasarkan nilai PWM seperti pada Tabel 6.

Saat motor linier menerima *duty cycle* sebesar 0 %, maka tegangan yang terukur pada motor sebesar 0,2 V dan panjang motor 1 cm, sedangkan dengan *duty cycle* 100 %, nilai tegangan yang terukur menjadi 3,5 V dengan panjang motor 3,90 cm. Motor linier yang bergerak akan mendorong jari-jari sehingga jari yang semula terbuka menjadi menggenggam. Panjang motor linier mempengaruhi gerakan menggenggam robot. Dengan panjang 1 cm atau kekuatan 0 N, robot dalam posisi membuka atau tidak menggenggam, sedangkan dengan panjang 3,90 cm atau kekuatan genggam 7 N maka robot menggenggam secara maksimal.

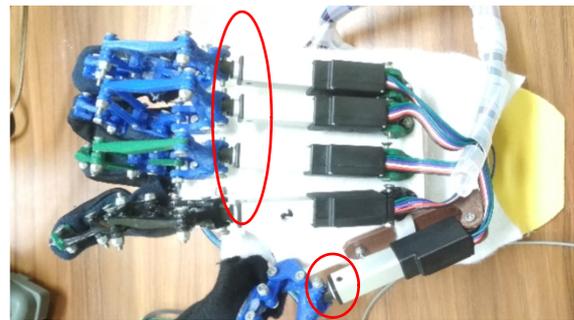
PWM yang diberikan mempengaruhi panjang dari aktuator robot. Semakin besar PWM, maka semakin panjang aktuator robot dan semakin menggenggam pula jari-jari subjek. Dengan semakin kuatnya kekuatan genggam yang diperoleh dari proses peramalan, maka semakin menggenggam pula jari-jari tangan. Perbedaan panjang aktuator robot seperti pada Gambar 9 dan Gambar 10. Bagian yang dilingkari merah merupakan bagian aktuator yang akan berubah panjangnya. Perubahan paling panjang terjadi pada Gambar 10, yaitu dengan panjang 3,9 cm sesuai dengan panjang peramalan kekuatan. Percobaan tersebut menunjukkan kinerja dari peramalan untuk robot sudah cukup baik seperti halnya [13]-[16]. Perbaikan dan pengujian dengan parameter yang lebih banyak perlu dilakukan untuk mendapatkan hasil yang lebih baik.

IV. KESIMPULAN

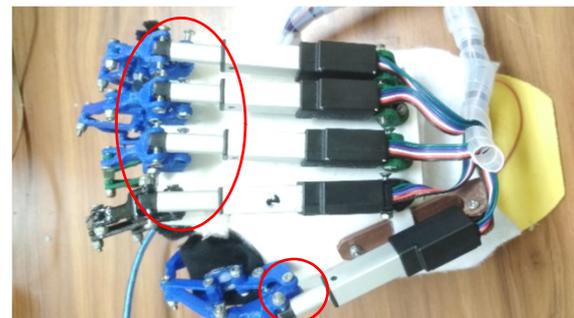
Peramalan yang dilakukan menggunakan metode ELM sudah menghasilkan akurasi yang cukup baik dilihat dari nilai MSE. Percobaan dengan akurasi terbaik adalah menggunakan fitur MAV dengan MSE terkecil pada pengujian *offline*, yaitu dengan rata-rata 1,77 dengan standar deviasi $\pm 0,98$. Pengujian *real-time*

Tabel 6. Panjang aktuator robot

Hasil Peramalan Kekuatan Gerakan (N)	Duty Cycle (%)	PWM	Panjang Aktuator (cm)
0	0	0	1
1	25	60	1,70
2	40	100	1,90
3	55	140	2,60
4	70	180	3,00
5	80	200	3,40
6	95	240	3,60
7	100	255	3,90



Gambar 9. Robot dengan panjang aktuator 1 cm



Gambar 10. Robot dengan panjang aktuator 3,9 cm

menghasilkan MSE yang kecil dengan MSE 0,24. Saat diterapkan pada robot, robot dapat bergerak membuka dan menggenggam dengan baik.

UCAPAN TERIMA KASIH

Terima kasih ditujukan kepada Laboratorium *Intelligent System and Robotic* (ISR) CDAST Universitas Jember yang telah mengizinkan dan menjadi tempat pengambilan data serta pengujian pada penelitian ini.

DAFTAR PUSTAKA

- [1] Y. Yuyun, *Pencitraan pada stroke*. Malang, 2016.
- [2] Graeme J. Hankey, *Stroke: your questions answered*. Edinburg: Churchill Livingstone, 2015.
- [3] F. B. Batticaca, *Asuhan keperawatan pada klien dengan gangguan sistem persarafan*. Jakarta: Salemba Medika, 2008.

- [4] J. R. Suwantara, "Depresi pasca-stroke: epidemiologi, rehabilitasi dan psikoterapi," *Jurnal Kedokteran Trisakti*, vol. 23, no. 4, pp. 150–156, 2004.
- [5] P. Langhorne, J. Bernhardt, and G. Kwakkel, "Stroke rehabilitation," *The Lancet*, vol. 377, no. 9778, pp. 1693–1702, 2011. doi: [10.1016/S0140-6736\(11\)60325-5](https://doi.org/10.1016/S0140-6736(11)60325-5)
- [6] J. R. O. Hariandja, "Teknologi terjangkau untuk penderita stroke di Indonesia," *Research Report – Engineering Science*, vol. 6, no. 3, pp. 1–31, 2013.
- [7] K. Gui, H. Liu, and D. Zhang, "A practical and adaptive method to achieve EMG-based torque estimation for a robotic exoskeleton," *IEEE/ASME Transactions on Mechatronics*, vol. 24, no. 2, pp. 483–494, 2019. doi: [10.1109/TMECH.2019.2893055](https://doi.org/10.1109/TMECH.2019.2893055)
- [8] K. Anam, *Sistem kontrol robot untuk rehabilitasi*. Jember: UTP Percetakan dan Penerbitan Universitas Jember, 2019.
- [9] J. L. Pons, "Rehabilitation exoskeletal robotics," *IEEE Engineering in Medicine and Biology Magazine*, vol. 29, no. 3, pp. 57–63, 2010. doi: [10.1109/MEMB.2010.936548](https://doi.org/10.1109/MEMB.2010.936548)
- [10] P. V. Komi, P. Tesch, V. Komi, and P. Tesch, "EMG Frequency Spectrum, Muscle Structure, and Fatigue," *European Journal of Applied Physiology and Occupational Physiology*, vol. 42, pp. 41–50, 1979. doi: [10.1007/BF00421103](https://doi.org/10.1007/BF00421103)
- [11] D. Leonardis *et al.*, "An EMG-controlled robotic hand exoskeleton for bilateral rehabilitation," *IEEE Transactions on Haptics*, vol. 8, no. 2, 2015. doi: [10.1109/TOH.2015.2417570](https://doi.org/10.1109/TOH.2015.2417570)
- [12] J. A. Opara and K. Jaracz, "Quality of life of post-stroke patients and their caregivers," *Journal of Medicine and Life*, vol. 3, no. 3, pp. 216–220, 2010.
- [13] N. S. K. Ho *et al.*, "An EMG-driven exoskeleton hand robotic training device on chronic stroke subjects: Task training system for stroke rehabilitation," in *IEEE International Conference on Rehabilitation Robotics*, Zurich, Switzerland, Jul. 2011, pp. 1–5. doi: [10.1109/ICORR.2011.5975340](https://doi.org/10.1109/ICORR.2011.5975340)
- [14] M. Chen, L. Cheng, F. Huang, Y. Yan, and Z. G. Hou, "Towards robot-assisted post-stroke hand rehabilitation: Fugl-meyer gesture recognition using sEMG," in *Annual International Conference on CYBER Technology in Automation, Control, and Intelligent Systems*, Honolulu, USA, Aug. 2018. pp. 1472–1477. doi: [10.1109/CYBER.2017.8446436](https://doi.org/10.1109/CYBER.2017.8446436)
- [15] K. Anam, A. A. Rosyadi, B. Sujanarko, and A. Al-Jumaily, "Myoelectric control systems for hand rehabilitation device: A review," in *International Conference on Electrical Engineering, Computer Science and Informatics*, Yogyakarta, Indonesia, Sept. 2017, pp. 1–6. doi: [10.1109/EECSI.2017.8239091](https://doi.org/10.1109/EECSI.2017.8239091)
- [16] L. Bi, A. Feleke, and C. Guan, "A review on EMG-based motor intention prediction of continuous human upper limb motion for human-robot collaboration," *Biomedical Signal Processing and Control*, vol. 51, pp. 113–127, 2019. doi: [10.1016/j.bspc.2019.02.011](https://doi.org/10.1016/j.bspc.2019.02.011)
- [17] S. Suyanto, *Machine learning tingkat dasar dan lanjut*. Bandung: Informatika Bandung, 2018.
- [18] H. Cao, S. Sun, and K. Zhang, "Modified EMG-based handgrip force prediction using extreme learning machine," *Soft Computing*, vol. 21, no. 2, pp. 491–500, 2017. doi: [10.1007/s00500-015-1800-8](https://doi.org/10.1007/s00500-015-1800-8)
- [19] K. Anam and A. Al-Jumaily, "Evaluation of extreme learning machine for classification of individual and combined finger movements using electromyography on amputees and non-amputees," *Neural Networks*, vol. 85, pp. 51–68, 2017. doi: [10.1016/j.neunet.2016.09.004](https://doi.org/10.1016/j.neunet.2016.09.004)
- [20] G.-B. Huang, Q.-Y. Zhu, and C.-K. Siew, "Extreme learning machine: Theory and applications," *Neurocomputing*, vol. 70, no. 1–3, pp. 489–501, 2006. doi: [10.1016/j.neunet.2016.09.004](https://doi.org/10.1016/j.neunet.2016.09.004)
- [21] D. R. Freer, J. Liu, and G. Z. Yang, "Optimization of EMG movement recognition for use in an upper limb wearable robot," in *14th International Conference on Wearable and Implantable Body Sensor Networks*, Endhoven, Netherlands, May 2017, pp. 202–205. doi: [10.1109/BSN.2017.7936041](https://doi.org/10.1109/BSN.2017.7936041)
- [22] Z. Arief, I. A. Sulistijono, and R. A. Ardiansyah, "Comparison of five time series EMG features extractions using Myo Armband," in *International Electronics Symposium*, Surabaya, Indonesia, Sept. 2015, pp. 11–14. doi: [10.1109/ELECSYM.2015.7380805](https://doi.org/10.1109/ELECSYM.2015.7380805)
- [23] A. Rahagiyanto, "Identifikasi ekstraksi fitur untuk gerakan tangan dalam bahasa isyarat (SIBI) menggunakan sensor MYO Armband," *MATRIK Jurnal Manajemen, Teknik Informatika dan Rekayasa Komputer*, vol. 19, no. 1, pp. 127–137, 2019. doi: [10.30812/matrik.v19i1.510](https://doi.org/10.30812/matrik.v19i1.510)
- [24] D. A. R. Wati, *Sistem kendali cerdas*. Yogyakarta, 2011.
- [25] G. Bin Huang, Q. Y. Zhu, and C. K. Siew, "Extreme learning machine: A new learning scheme of feedforward neural networks," in *IEEE International Joint Conference on Neural Networks*, Budapest, Hungary, Jul. 2004, pp. 985–990. doi: [10.1109/IJCNN.2004.1380068](https://doi.org/10.1109/IJCNN.2004.1380068)
- [26] M. A. R. Nst, M. Zarlis, and Z. Situmorang, "Analisis perbandingan online dan offline training pengenalan huruf abjad," *Jurnal Nasional Informatika dan Teknologi Jaringan*, vol. 2, no. 1, pp. 49–59, 2017. doi: [10.30743/infotekjar.v2i1.169](https://doi.org/10.30743/infotekjar.v2i1.169)
- [27] K. R. Mills, "The basics of electromyography," *Journal of Neurology, Neurosurgery & Psychiatry*, vol. 76, no. 2, pp. 32–35, 2005. doi: [10.1136/jnnp.2005.069211](https://doi.org/10.1136/jnnp.2005.069211)



©2021. This article is an open access article distributed under the terms and conditions of the [Creative Commons Attribution-ShareAlike 4.0 International License](https://creativecommons.org/licenses/by-sa/4.0/).