

Studi Klasifikasi Tujuh Gerakan Tangan Sinyal *Electromyography* (EMG) Menggunakan Metode *Pattern Recognition*

*Mohamad Irfan¹, Wahyu Caesarendra², Mochammad Ariyanto²

¹Mahasiswa Jurusan Teknik Mesin, Fakultas Teknik, Universitas Diponegoro

²Dosen Jurusan Teknik Mesin, Fakultas Teknik, Universitas Diponegoro

Jl. Prof. Sudharto, SH., Tembalang-Semarang 50275, Telp. +62247460059

*E-mail: irfan.ahmadi.ina@gmail.com

Abstrak

Pada studi ini, sinyal EMG diproses menggunakan 16 *features extraction* domain – waktu untuk mengklasifikasikan gerakan tangan seperti *tripod*, *power*, *precision closed*, *finger point*, *mouse*, *hand open*, dan *hand close*. 16 fitur dari masing – masing sinyal EMG dari gerakan tangan tersebut direduksi menggunakan *principal component analysis* (PCA) untuk mendapatkan satu set fitur baru yang memberikan informasi yang lebih kompek. *Pattern recognition* dari fitur baru tersebut diklasifikasikan menggunakan *support vector machine* (SVM). *Pattern recognition* digunakan pada masing – masing subjek dan menghasilkan persentase *training* dan *testing*. Berdasarkan SVM *training* dan *testing* yang dihasilkan, sinyal EMG dari gerakan tangan sukses diklasifikasikan dan akurasi dari klasifikasi mencapai 80% - 86%.

Kata kunci: *electromyography, features extraction, principal component analysis, support vector machine, pattern recognition.*

Abstract

In this study, the EMG signals are processed using 16 time – domain features extraction to classify the hand movements such as tripod, power, precision closed, finger point, mouse, hand open, and hand close. The 16 features of each EMG signals of hand movements are reduced using principal component analysis (PCA) to obtain the new features set that encode the classification information more compact the pattern recognition of the new features set are classified using support vector machine (SVM). The pattern recognition is used to each of subject and it result percentage of training and testing. Based on the resulted svm training and testing of each subject, the EMG signals of hand movement has been success to classified and the accuracy of classifications is 80% - 86%.

Keywords: *electromyography, features extraction, principal component analysis, support vector machine, pattern recognition.*

1. Pendahuluan

Sinyal *electromyography* (EMG) telah digunakan dan diaplikasikan sebagai sistem kontrol sinyal dalam berbagai macam aplikasi *human machine interface* dan juga dikembangkan dalam banyak aplikasi klinis dan industry [1]. Aplikasi potensial dari penggunaan sistem kontrol sinyal menggunakan sinyal EMG ini diantaranya adalah pada *electrical wheelchair*, *virtual mouse*, dan *robotic hand* [1, 2].

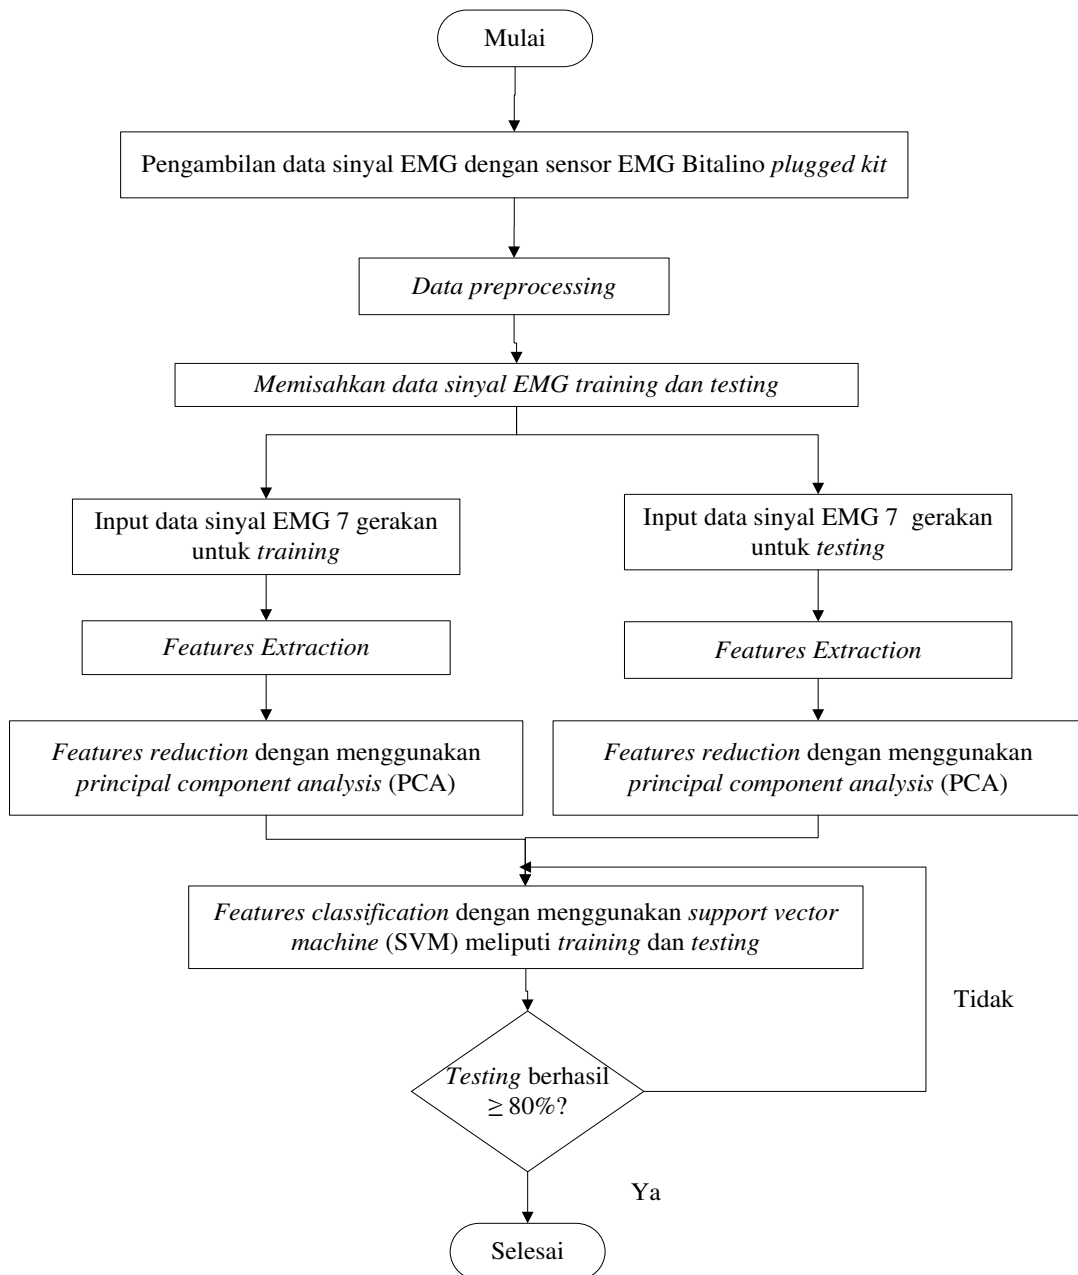
Saat ini jumlah studi mengenai tangan bionik telah berkembang secara signifikan. Pokok utama dari studi ini adalah untuk menginterpretasi gerakan tangan. Sensor yang umum digunakan dalam pengukuran aktivitas otot adalah sensor *electromyography* (EMG) [1, 3]. Sinyal mentah (*raw signal*) dari sensor EMG begitu rumit untuk diinterpretasi olah manusia [3]. Sehingga, implementasi metode *pattern recognition* yang mampu menginterpretasikan aktivitas otot atau gerakan tangan sangat penting [3]. Penelitian ini difokuskan pada *pattern recognition* klasifikasi gerakan tangan menggunakan sinyal EMG mentah.

Pada studi kali ini, SVM akan digunakan untuk mengklasifikasikan tujuh gerakan tangan berbasis pada sinyal EMG. 16 *features* dalam domain waktu (*time domain*) digunakan dalam proses *feature extraction*. PCA digunakan sebagai *features reduction* pada 16 *features* tersebut yang akan dibahas pada bagian 3.2. Hasil klasifikasi akan ditampilkan dalam bagian 3.3.

2. Metode Penelitian

2.1 Diagram Alir Penelitian

Metodologi penelitian terdiri dari *data acquisition*, *data preprocessing*, *features extraction*, *features reduction*, *features classification*. Pada Gambar 1 adalah diagram alir penelitian.

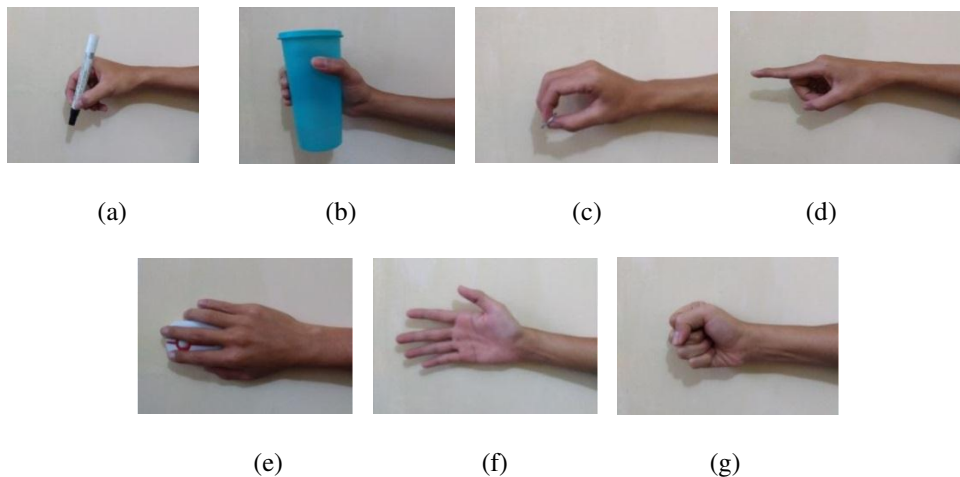


Gambar 1. Diagram alir penelitian.

Berdasarkan Gambar 1, akuisisi data sinyal EMG didapat dari 5 subjek, 3 laki – laki dan 2 perempuan, diminta untuk menjadi sampel penelitian. Semua subjek tidak memiliki masalah atau penyakit otot. Subjek dalam pengambilan data sinyal EMG dilakukan dengan posisi subjek duduk dan lengan di atas meja seperti pada Gambar 2. Pada Gambar 2 ditunjukkan pemosisian *electrode* dalam akuisisi sinyal EMG. Semua subjek sebelum diambil sinyal EMG diinformasikan untuk melakukan 7 gerakan tangan seperti pada Gambar 3. Masing – masing gerakan dilakukan sebanyak 11 kali pengulangan dan diinformasikan untuk konsisten dalam melakukan gerakan.



Gambar 2. Subjek melakukan akuisisi data sinyal EMG.



Gambar 3. Tujuh gerakan tangan untuk pengambilan sinyal EMG (a) *tripod*, (b) *power*, (c) *precision closed*, (d) *finger point*, (e) *mouse*, (f) *hand close*, dan (g) *hand open*.

2.2 Features Extraction

Sinyal EMG mentah diakuisisi dari sejumlah elektroda yang diposisikan pada otot yang mengandung sejumlah besar data namun memiliki sedikit informasi. Jika data mentah EMG ini digunakan sebagai input dalam proses klasifikasi, maka akurasi klasifikasi akan menjadi rendah dan waktu kalkulasi akan meningkat. Sehingga dalam *pattern recognition*, data mentah EMG membutuhkan transformasi fitur – fitur yang representatif. Dalam analisis sinyal EMG, *feature extraction* dapat dibagi menjadi tiga: *time – domain features*, *frequency – domain features*, dan *time – frequency* atau *time – scale domain* [4]. Pada penelitian ini, *feature* yang digunakan hanya *time – domain feature*. *Time – domain (TD) features* adalah fitur yang paling umum digunakan dalam klasifikasi sinyal [4]. Keuntungannya dibandingkan fitur yang lain adalah TD cepat untuk dikalkulasi karena TD tidak membutuhkan transformasi matematis [2, 4].

Fitur – fitur *time domain* EMG digunakan, sebagai berikut:

a. *Integrated EMG (IEMG)*

Integrated EMG (IEMG) biasanya digunakan sebagai indeks deteksi *onset* di EMG *non-pattern recognition* dan aplikasi klinis [2]. Fitur ini berhubungan dengan urutan *firing point* sinyal EMG. Fitur IEMG didefinisikan sebagai penjumlahan nilai absolut amplitudo sinyal EMG(x_i) [4].

$$IEMG = \sum_{i=1}^N |x_i|$$

(1)

b. *Mean Absolute Value (MAV)*

Mean absolute value (MAV) adalah salah satu fitur paling populer digunakan dalam analisis sinyal EMG [2]. Serupa dengan fitur IEMG yakni digunakan sebagai indeks *onset*, khususnya dalam sinyal *surface EMG* untuk kontrol kaki palsu (*prosthetic limb*). Namun, ada banyak sebutan yang diberikan untuk fitur ini, misalnya, *average*

rectified value (ARV), average absolute value (AAV), integral of absolute value (IAV), dan first order of v-order features (V1). Fitur MAV adalah rata-rata nilai absolut dari amplitudo sinyal EMG dalam sebuah segmen [4].

$$MAV = \frac{1}{N} \sum_{i=1}^N |x_i| \quad (2)$$

c. *Root Mean Square (RMS)*

Root mean square (RMS) adalah fitur populer yang lain dalam analisis sinyal EMG [4]. Fitur ini dimodelkan sebagai amplitudo proses modulasi *Gaussian random* yang mana berhubungan dengan gaya konstan dan kontraksi *non-fatiguing* [4].

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (3)$$

d. *Difference Absolute Standard Deviation Value (DASDV)*

Difference absolute standard deviation value (DASDV) tampak seperti fitur RMS, dalam sebutan lain, fitur ini adalah nilai standar deviasi dari panjang gelombang [4].

$$DASDV = \sqrt{\frac{1}{N-1} \sum_{i=1}^{N-1} (x_{i+1} + x_i)^2} \quad (4)$$

e. *Simple Square Integral (SSI)*

Simple square integral (SSI) atau *integral square* menggunakan energi dari sinyal EMG sebagai fitur [4]. Fitur ini adalah jumlah dari nilai pangkat dua dari amplitudo sinyal EMG. Umumnya, parameter ini didefinisikan sebagai sebuah indeks energi [4].

$$SSI = \sum_{i=1}^N x_i^2 \quad (5)$$

f. *Variance of EMG (VAR)*

Variance of EMG (VAR) adalah indeks daya yang lain. Umumnya, *variance* didefinisikan sebagai rata-rata dari nilai pangkat dua variabel deviasi [4]. Namun, nilai mean dari sinyal EMG mendekati angka nol ($\sim 10^{-10}$).

$$VAR = \frac{1}{N-1} \sum_{i=1}^N x_i^2 \quad (6)$$

g. *Modified Mean Absolute Value Type 1 (MAV1)*

Modified mean absolute value type 1 (MAV1) adalah perluasan atau ekstensi dari fitur MAV [4]. Fungsi *weighted window* w_i yang dimasukkan ke dalam persamaan untuk meningkatkan *robustness* dari fitur MAV [4].

$$MAV1 = \frac{1}{N} \sum_{i=1}^N w_i |x_i|$$

$$w_i = \begin{cases} 1, & \text{jika } 0.25N \leq i \leq 0.75N \\ 0.5, & \text{jika tidak} \end{cases} \quad (7)$$

h. *Modified Mean Absolute Value Type 2 (MAV2)*

Modified mean absolute value type 2 (MAV2) adalah ekstensi dari fitur MAV yang serupa dengan MAV1 [4]. Namun, fungsi *weighted window* w_i dimasukkan ke dalam persamaan sebagai suatu fungsi kontinu (*continuous function*). Fitur ini meningkatkan kelembutan (*smoothness*) dari fungsi *weighted window* [4].

$$MAV2 = \frac{1}{N} \sum_{i=1}^N w_i |x_i|$$

$$w_i = \begin{cases} 1, & \text{if } 0.25N \leq i \leq 0.75N \\ 4i/N, & \text{else if } i < 0.25N \\ 4(i-N)/N, & \text{otherwise} \end{cases} \quad (8)$$

i. *Waveform Length (WL)*

Waveform length (WL) adalah ukuran kompleksitas sinyal EMG [4]. Parameter ini didefinisikan sebagai panjang kumulatif dari gelombang sinyal EMG sepanjang segmen waktu.

$$WL = \sum_{i=1}^{N-1} |x_{i+1} - x_i| \quad (9)$$

j. *Hjorth Activity (Hjorth 1)*

Parameter aktivitas yang merepresentasikan daya sinyal, variasi dari fungsi waktu. Sehingga dapat mengindikasikan permukaan dari spektrum daya dalam domain frekuensi [3, 5].

$$Hjorth_1 = \sigma_x^2 = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2 \quad (10)$$

k. *Hjorth Mobility (Hjorth 2)*

Parameter mobilitas yang merepresentasikan mean frekuensi atau proporsi standar deviasi spektrum daya [3, 5].

$$Hjorth_2 = \frac{\sigma_{x'}}{\sigma_x} \quad (11)$$

l. *Hjorth Complexity (Hjorth 3)*

Parameter kompleksitas yang merepresentasikan perubahan frekuensi [3, 5]. Parameter ini membandingkan similaritas sinyal dengan sinus gelombang murni, dimana nilainya berpusat pada angka 1 jika sinyal banyak yang mirip.

$$Hjorth_3 = \frac{\sigma_{x''}/\sigma_{x'}}{\sigma_{x''}/\sigma_x} \quad (12)$$

m. *Koefisien Autoregressive (AR)*

Koefisien Autoregressive adalah Suatu pendekatan umum untuk pemodelan univariat time series dalam bentuk persamaan [2, 3]:

$$y_t = a_1 y_{t-1} + a_2 y_{t-2} + \dots + a_n y_{t-n} + \varepsilon_t = \sum_{i=1}^n a_i y_{t-i} + \varepsilon_t \quad (13)$$

Dimana a_1 hingga a_n adalah koefisien autoregressive, y_t adalah *time series*, n adalah orde model AR ($n=4$) dan ε adalah residual yang selalu diasumsikan Gaussian *white noise*.

2.3 Principal Component Analysis (PCA)

Teknik transformasi linear dan non – linear digunakan untuk menghasilkan satu set fitur dari satu set pengukuran atau dari satu set fitur awal (*original feature*) [6]. Teknik ini bertujuan untuk memperoleh fitur baru yang menyediakan informasi klasifikasi yang lebih padat dibandingkan fitur awal (*original feature*). Hal ini berarti pengurangan (*reduction*) jumlah fitur dibutuhkan untuk sebagai acuan klasifikasi fitur (*feature classification*). Teknik ini juga sering disebut sebagai *dimensionality reduction* atau *feature reduction* karena jumlah fitur baru berkurang dari jumlah sebelumnya [6, 7, 8]. Hal ini tentu saja bertujuan untuk optimalisasi fitur – fitur yang memang akan digunakan untuk klasifikasi dengan mengurangi fitur – fitur yang tidak optimal [6]. Metode *feature reduction* yang umum digunakan dalam pemrosesan sinyal adalah *principle component analysis* (PCA).

PCA adalah teknik statistik yang dapat digunakan untuk mereduksi sejumlah variable asal menjadi beberapa variable baru yang bersifat orthogonal dan tetap mempertahankan total keragaman dari variable asalnya [6]. PCA bertujuan untuk mengubah dari sebagian besar variable asli yang digunakan yang saling berkorelasi satu dengan yang lainnya, menjadi satu set variable baru yang lebih kecil dan bebas (*tidak berkorelasi*), dan merupakan kombinasi linier dari variable asal [7, 8]. Selanjutnya variable baru ini dinamakan *principal component*. Dimana satu set l sampel (*feature*) original membentuk elemen dari sebuah vector $x \in R^l$. PCA adalah aplikasi transformasi linear untuk memperoleh satu set sampel (*feature*) baru, dalam bentuk matriks adalah sebagai berikut [7, 8]

$$y = A^T x \quad (14)$$

sehingga komponen y tidak berkorelasi. Untuk kemudian, dipilih komponen (*feature*) yang paling signifikan dari komponen ini [7]. Langkah-langkah PCA terangkum sebagai berikut:

- Mengestimasi kovarian matriks S . biasanya nilai mean diasumsikan nol, $E[x] = 0$. Dalam kasus ini, matriks kovarian dan matriks autokorelasi serupa, $R \equiv E[xx^T] = S$. Jika nilai mean tidak diasumsikan nol, mean disubstraksi. Sehingga, diberikan vector fitur N , $x_i \in R^l, i = 1, 2, 3, \dots, N$, estimasi matriks autokorelasi dirumuskan sebagai:

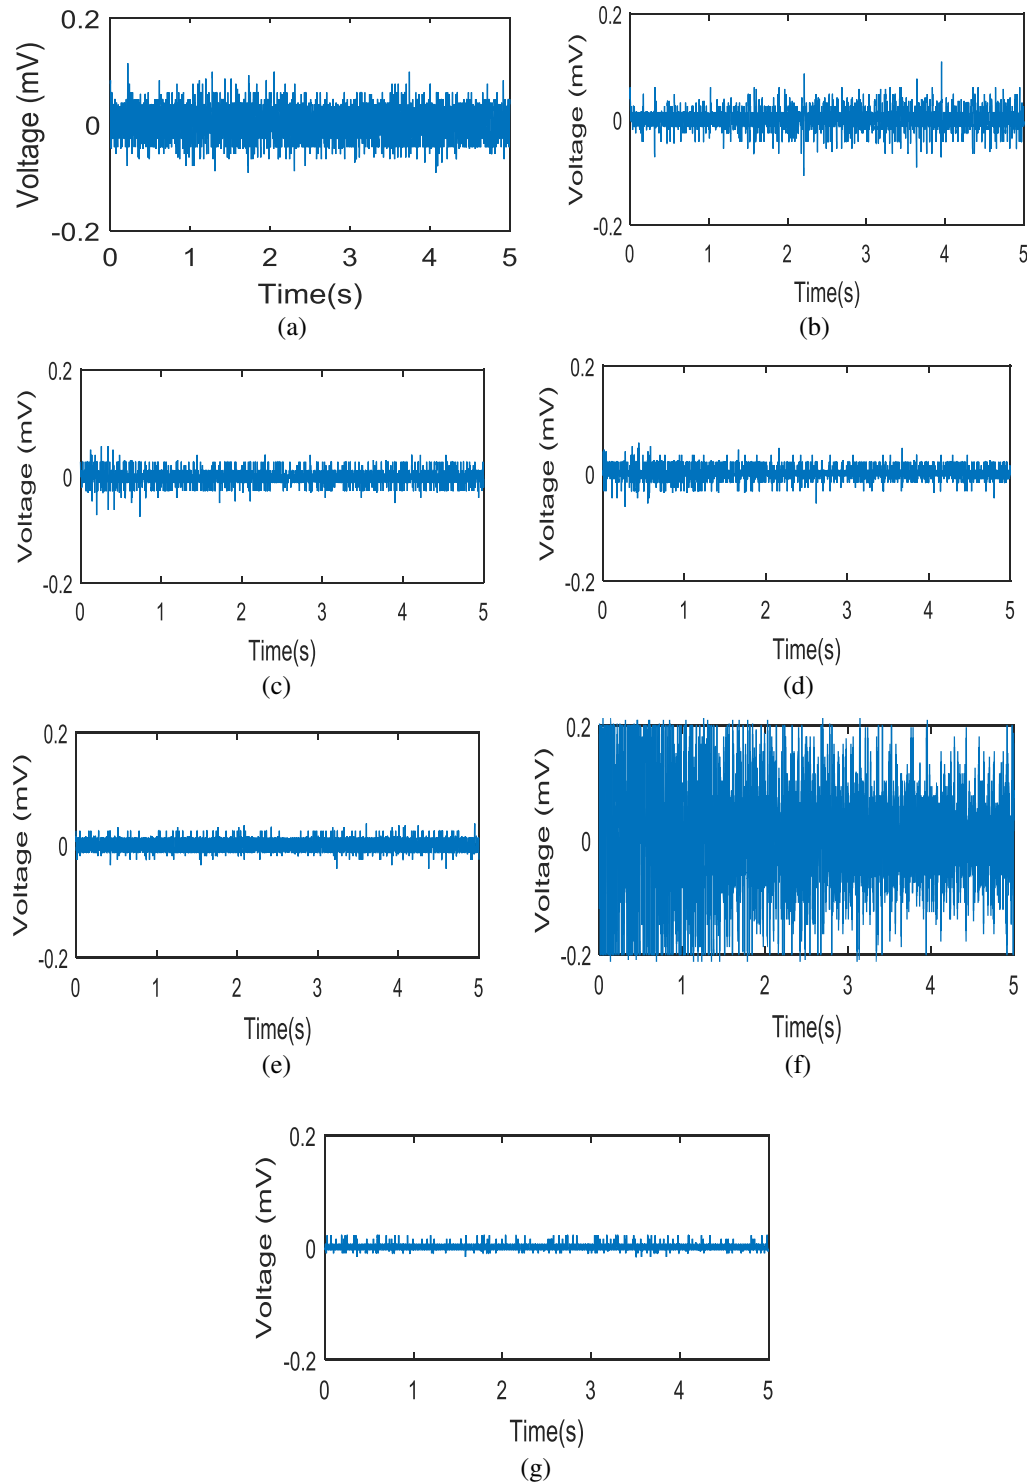
$$R \approx \frac{1}{N} \sum_{i=1}^N x_i x_i^T \quad (15)$$

- Melakukan dekomposisi eigen S dan menghitung *eigenvalue / eigenvector*, $\lambda_i, a_i \in R^l, i = 0, 2, \dots, l - 1$.
- Menyusun *eigenvalue* berurutan, $\lambda_0 \geq \lambda_1 \geq \dots \geq \lambda_{l-1}$.
- Memilih *eigenvalue* m terbesar. Biasanya m dipilih sehingga rentang antara λ_{m-1} dan λ_m besar. *Eigenvalue* $\lambda_0, \lambda_1, \dots, \lambda_{m-1}$ diketahui sebagai m *principle component*.
- Menggunakan kolom *eigenvector* $a_i, i = 0, 1, 2, \dots, m - 1$ berturut – turut untuk membentuk transformasi matriks

$$A = [a_0 \ a_1 \ a_2 \ \dots \ a_{m-1}] \quad (16)$$
- Mentransformasikan masing – masing l -dimensional vector x dalam bentuk awan menjadi sebuah m -dimensional vector y melalui transformasi $y = A^T x$. Dengan kata lain, elemen $y(i)$ ke- i dari y merupakan proyeksi x pada a_i ($y(i) = a_i^T x$).

2.4 Support Vector Machine (SVM)

SVM adalah salah satu teknik klasifikasi paling *powerful* berbasis teori statistik dan *machine learning* yang bekerja atas prinsip *structural risk minimization* (SRM) dengan tujuan menemukan *hyperplane* terbaik yang memisahkan dua atau lebih kelas [6, 9]. Seperti ditunjukkan pada Gambar 4 yang mengilustrasikan margin SVM untuk memisahkan dua kelas.

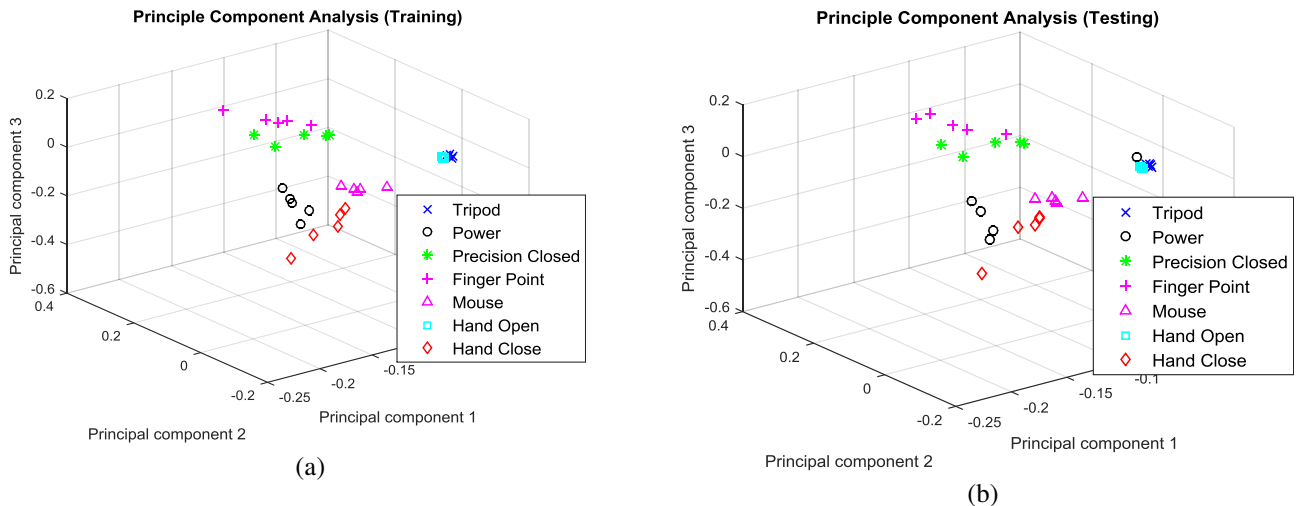


Gambar 5. Sinyal EMG mentah (a) *tripod*, (b) *power*, (c) *precision closed*, (d) *finger point*, (e) *mouse*, (f) *hand close*, dan (g) *hand open*.

3.2 Hasil *Principal Component Analysis* (PCA) Sinyal EMG

Pada proses selanjutnya 16 set feature untuk masing – masing gerakan direduksi menggunakan PCA. Pada Gambar 6 menunjukkan hasil *plotting 3 principal component* (PC) yang merepresentasikan pemetaan sinyal – sinyal EMG. Pada Gambar 6 tersebut menunjukkan PCA untuk training dan PCA untuk testing. Pada Gambar 6 (a) merupakan hasil PCA untuk sinyal EMG *training* terlihat bahwa masing – masing gerakan tangan sinyal EMG berkelompok pada suatu daerah tertentu dan terlihat terpisah antar satu gerakan dengan gerakan lain. Tetapi terdapat dua gerakan yang saling berdekatan yaitu *tripod* dan *hand open*. Sedangkan, Pada Gambar 6 (b) hasil PCA untuk sinyal EMG *testing*

terlihat bahwa masing – masing gerakan tangan sinyal EMG berkelompok pada suatu daerah tertentu dan terlihat terpisah antar satu gerakan dengan gerakan lain. Tetapi terdapat dua gerakan yaitu *tripod* dan *hand open* dan satu data *power* yang saling berdekatan. Hal ini dikarenakan nilai 3 PC dari masing - masing gerakan tersebut dalam bentuk plot 3 dimensi berdekatan.

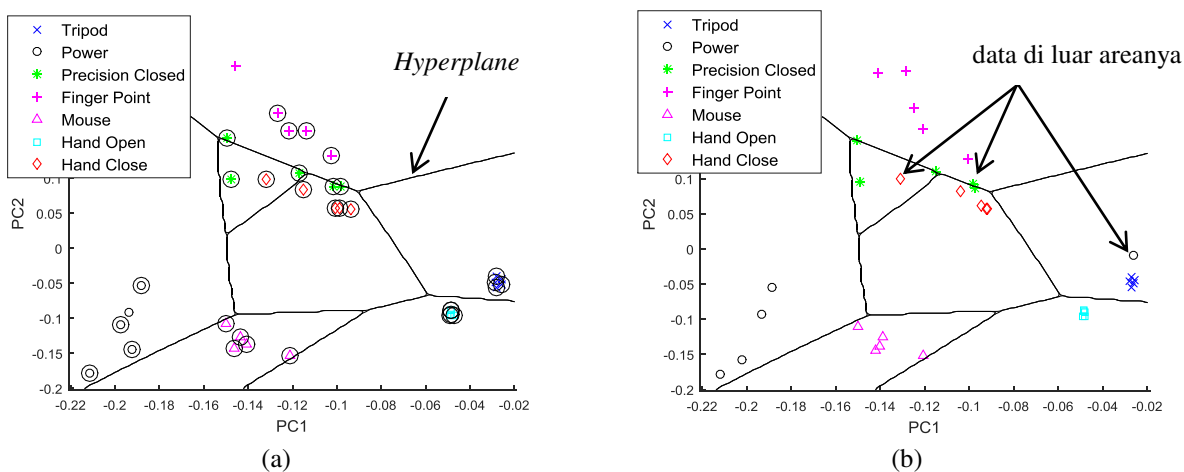


Gambar 6. (a) PCA Training dan (b) PCA testing untuk subjek 1.


3.3 Hasil Klasifikasi Tujuh Gerakan Tangan Sinyal EMG Menggunakan SVM

Hasil dari pemrosesan sinyal menggunakan PCA dipilih 2 PC terbaik diantara PC yang lain. 2 PC terbaik diklasifikasikan menggunakan SVM untuk didapatkan *boundary* yang akan memetakan area untuk masing masing gerakan tangan. Hasil *boundary* tersebut didapatkan dari proses klasifikasi dari *training* data. Pada Gambar 7 (a) menunjukkan salah satu contoh klasifikasi untuk subjek 1 dengan hasil klasifikasi data *training* untuk tujuh gerakan tangan sinyal EMG. *Hyperplane* memvisualisasikan batasan antar kelas. *Hyperplane* membuat suatu area untuk masing – masing kelas atau gerakan. SVM mampu mengklasifikasikan sinyal EMG untuk tujuh kelas dengan membentuk area sebanyak tujuh area seperti pada Gambar 7 (a). Area untuk masing – masing gerakan diperoleh untuk kemudian area tersebut digunakan sebagai referensi dengan diuji menggunakan data *testing* sinyal EMG, seperti ditunjukkan pada Gambar 7 (a). Hasil klasifikasi data *training* sinyal EMG ditunjukkan pada Gambar 8.

Hyperplane yang terbentuk pada proses klasifikasi SVM *training* membentuk suatu pola area yang terpisah dengan masing – masing area adalah milik satu kelas. Area tersebut diuji dengan sinyal EMG *testing*. Pada Gambar 7 (b) menunjukkan salah satu contoh hasil *testing* untuk subjek 1 dengan hasil klasifikasi data *testing* untuk tujuh gerakan tangan sinyal EMG. Tampak ada data *testing* yakni data untuk gerakan *power*, *precision closed*, dan *hand close* yang berada di luar area kelasnya. Hasil klasifikasi data *testing* sinyal EMG ditunjukkan pada Gambar 8.



Gambar 7. Klasifikasi menggunakan teknik SVM membuat *boundary* untuk mengklasifikasikan sinyal EMG (a) data *training* dan (b) data *testing*.



Gambar 8. Persentase *training* dan *testing* untuk masing – masing subjek dengan klasifikasi SVM.

4. Kesimpulan

Pengolahan sinyal EMG dengan metode *pattern recognition* meliputi (1) *features extraction* (2) *features reduction* (3) *features classification*. Dengan metode *pattern recognition* sinyal EMG dari 5 dataset *training* berhasil diklasifikasikan dengan hasil akurasi *training* sebesar 85 – 89%. Kemudian hasil klasifikasi diuji dengan sinyal EMG dari 5 dataset *testing* menghasilkan akurasi *testing* sebesar 80 – 86%.

5. Daftar Pustaka

- [1] R. Merletti, P. Parker. 2004. *Electromyography: Physiology, Engineering, and Noninvasive Applications*. Hoboken, NJ: John Wiley & Sons.
- [2] Phinyomark, P. Phukpattaranont, C. Limsakal. 2011. *A Review of Control Methods for Electric Power Wheelchair Based on Electromyography Signals with Special Emphasis on Pattern Recognition*. IETE Tech. Rev. 28(4): 316 - 326.
- [3] M. Arijanto, W. Caesarendra, K. A. Mustaqim, M. Irfan, J. A. Pakpahan, J. D. Setiawan. 2015. *Finger Movement Pattern Recognition Method Using Artificial Neural Network Based on Electromyography (EMG) Sensor*. International Conf. on Automat., Cognit. Science, Optics, Micro Electro-Mechanical Syst., and Information Tech. (ICACOMIT) 29-30 Oct. 2015.
- [4] A. Phinyomark, P. Phukpattaranont, C. Limsakul. 2012. *Feature Reduction and Selection for EMG Signal Classification*. Expert Syst. App. 39 (3) 7420–7431.
- [5] R. N. Khushaba, S. Kodagoda, M. Takturi, G. Dissanayake. 2012. *Toward Improved Control of Prosthetic Finger Using Surface Electromyogram (EMG) Signals*. Elsevier. Exp. Syst. with Appl. 39 :10731 – 10738.
- [6] B.S. Yong, A. Widodo. 2011. *Introduction of Intelligent Machine Fault Diagnosis and Prognosis*. Nova Science Publish.: US.
- [7] S. Theodoridis, K. Koutrombus. 2009. *Pattern Recognition, 4th Ed*. Academic Press: US.
- [8] S. Theodoridis, K. Koutrombas. 2010. *An Introduction to Pattern Recognition: A Matlab Approach*. Academic Press: US.
- [9] M. A. Oskoei, H. Hu. 2008. *Support Vector Machine Based Classification Scheme for Myoelectric Control Applied to Upper Limb*. IEEE Transact. on Biomed. Eng. 55(8), 1956–1965.