

Deteksi Intensi Pergerakan Jari Menggunakan Metode *Power Spectral Density* dengan Stimulus Visual

Reza Darmakusuma¹, Ary S. Prihatmanto², Adi Indrayanto³, Tati L. Mengko⁴

Abstract—This research explores a detection of finger's movement using Burg's Power Spectral Density (PSD) as features vector. EEG signal is recorded using sampling frequency of 1000 Hz. Analysis of the signal is conducted by dividing signal into three segments; 1000 ms, 500 ms and 250 ms. Common Average Reference (CAR) and Support Vector Machine (SVM) are used in features extraction and pattern recognition. The result shows that the system can classify the finger's movement with accuracy of about $\pm 65,37\%$ in 1000 ms of signal length.

Intisari—Pada penelitian ini dilakukan pendeteksian pergerakan jari menggunakan fitur *Power Spectral Density* (PSD) Burg. Sinyal EEG direkam dengan frekuensi *sampling* 1000 Hz. Analisis dilakukan dengan membagi sinyal menjadi tiga segmen; 1000 ms, 500 ms dan 250 ms. *Common Average Reference* (CAR) dan *Support Vector Machine* (SVM) digunakan untuk ekstraksi fitur dan pengenalan pola. Hasil penelitian menunjukkan bahwa sistem dapat melakukan deteksi pergerakan jari dengan akurasi $\pm 65,37\%$ dengan panjang sampel 1000 ms.

Kata Kunci—EEG, PSD, *Common Average Reference*, SVM.


I. PENDAHULUAN

Otak merupakan organ tubuh yang mengatur sistem dalam tubuh manusia [12]. Organ ini melakukan koordinasi terhadap organ lain atau anggota tubuh dengan cara mengirimkan sinyal elektrik melalui jaringan syaraf [12], seperti menggerakkan tangan, kaki dan sebagainya. Namun, tidak semua koordinasi dari otak dapat dihantarkan ke organ lain atau anggota tubuh dengan optimal. Salah satu penyebab terjadinya hambatan ini adalah kerusakan pada jaringan syaraf yang timbul karena penyakit ataupun kecelakaan. Kelumpuhan merupakan salah satu akibat yang timbul karena kerusakan pada jaringan syaraf [13].

Beberapa teknologi dikembangkan untuk membantu penderita kelumpuhan dalam melakukan aktivitas hidupnya, seperti bergerak atau berkomunikasi. Salah satu teknologi tersebut adalah *brain-computer interface* (BCI). Sistem BCI menggunakan gelombang otak yang dihasilkan dari sebuah aktivitas mental sebagai masukan. Gbr. 1 memberikan ilustrasi sistem dasar BCI yang digunakan [1], [6].

¹Mahasiswa doktoral dan peneliti, Sekolah Teknik Elektro dan Informatika, Institut Teknologi Bandung, Jl. Ganesha 10, Bandung. 40132 INDONESIA (tlp: 022-2500960; fax: 022-2534217 e-mail: reza.darmakusuma@gmail.com)

^{2, 3, 4}Dosen, Sekolah Teknik Elektro dan Informatika, Institut Teknologi Bandung, Jl. Ganesha 10, Bandung. 40132 INDONESIA (tlp: 022-2500960; e-mail: asetijadi@lisk. ee.itb.ac.id)



Gbr. 1 Sistem dasar *Brain-Computer Interface* (BCI).

Pada beberapa penelitian telah dikenali beberapa jenis gelombang otak, di antaranya adalah *Alpha rhythm* dan *Beta rhythm*. *Alpha rhythm* merupakan gelombang otak yang memiliki frekuensi antara 8 Hz hingga 13 Hz [3]. Sedangkan *Beta rhythm* adalah gelombang otak yang memiliki frekuensi antara 13 Hz hingga 30 Hz [3]. Selain itu dikenal pula sebuah gelombang dengan nama *mu rhythm*.

Mu rhythm didefinisikan sebagai gelombang otak yang memiliki frekuensi 8 Hz hingga 13 Hz (*Alpha rhythm*) yang diukur pada *sensory* atau *motor cortex area*. *Mu rhythm* yang terjadi pada daerah tersebut dapat terlihat pada kondisi aktivitas mental tidak sedang mengakses syaraf motorik (bergerak) atau tidak sedang mengakses syaraf sensorik yang berkaitan dengannya [1], [4].

Setiap aktivitas mental yang dilakukan akan menghasilkan pola sinyal EEG tertentu. Sebagai contoh apabila aktivitas mental tersebut mengakses informasi syaraf motorik, maka gelombang *mu rhythm* dan *beta rhythm* pada *motor cortex area* dan *sensory cortex area* akan mengalami perubahan [1], [4]. Fenomena perubahan ini disebut dengan *event related desynchronization* (ERD) dan *event related synchronization* (ERS).

Ketika seseorang (subjek) melakukan gerakan, pola sinyal EEG akan mengalami perubahan. Amplitude *mu rhythm* dan *beta rhythm* mengalami atenuasi ketika gerakan sedang terjadi. Penurunan amplitude ini disebut dengan ERD. Namun setelah pergerakan selesai dan subjek tidak lagi melakukan aktivitas yang berhubungan dengan syaraf sensorik atau motorik, amplitude *mu rhythm* dan *beta rhythm* kembali menguat. Fenomena peningkatan kembali amplitude *mu rhythm* dan *beta rhythm* ini disebut dengan ERS.

Beberapa penelitian mengenai pergerakan jari menggunakan *non-invasive* EEG telah banyak dilakukan, salah satunya oleh Pires et al. [16]. Namun, penelitian yang dilakukan adalah membedakan pergerakan jari kanan dan kiri dengan percobaan *single trial* menggunakan domain waktu. Oleh sebab itu, pada penelitian ini dilakukan pendeteksian pergerakan jari menggunakan stimulus secara visual dengan jari pada kondisi istirahat menggunakan *non-invasive* EEG. Pendeteksian pergerakan jari ini memanfaatkan gelombang *mu rhythm* dan *beta rhythm*, karena diketahui bahwa gerakan berpengaruh pada gelombang *mu rhythm* dan *beta rhythm* [15].

Selain hal tersebut, posisi elektroda yang akan digunakan hanya akan terbatas pada C3, C4, F3, F4 yang terletak di sekitar *motor cortex area* dan *sensory cortex area*. Tujuan yang hendak dicapai pada penelitian ini adalah menguji penggunaan metoda *power spectral density* (PSD) dalam pendeteksian pergerakan jari pada percobaan *single trial*.

II. METODOLOGI

Untuk melakukan identifikasi terhadap gerakan akan digunakan metode *Go/Nogo task* dengan memberikan rangsangan visual yang teridentifikasi. Metode ini mensimulasikan terjadinya gerakan berdasarkan rangsangan visual yang diberikan, yaitu melakukan identifikasi terhadap gambar binatang. Percobaan dilakukan menggunakan data yang diperoleh dari Swartz Center for Computational Neuroscience [10]. Prosedur percobaan dapat dijelaskan sebagai berikut.

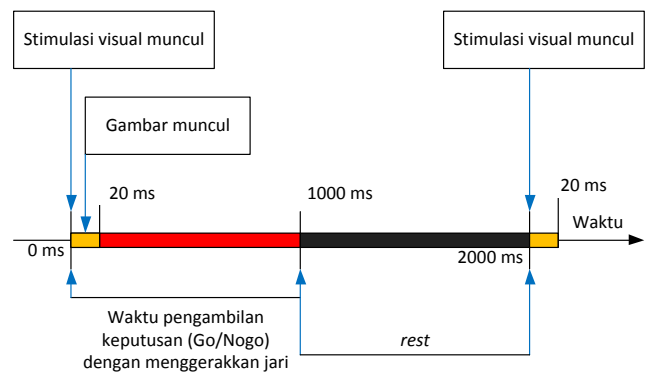
Subjek duduk di ruang dengan cahaya yang redup dan berjarak 110 cm dari layar komputer yang terhubung dengan komputer PC. Tugas yang dilakukan adalah melakukan identifikasi. Dalam percobaan tersebut, gambar yang digunakan sebagai target (*Go*) dan gambar non-target (*Nogo*) memiliki kemungkinan yang sama disajikan.

Untuk memulai seri percobaan, subjek harus menekan tombol sentuh yang sensitif. Sebuah titik fiksasi kecil (lebih kecil dari $0,1^\circ$ dari sudut visual) ditarik di tengah layar hitam. Warna foto yang digunakan memiliki resolusi 8-bit (256 piksel lebar dan 384 piksel tinggi yang secara kasar sesuai dengan $4,5^\circ$ dari sudut visual lebar dan $6,5^\circ$ di ketinggian) yang melintas selama 20 ms (dua frame layar SVGA 100 Hz) sebanyak 15 kali menggunakan *graphic board* (VSG 2.1, Cambridge Research Systems).

Presentasi gambar dengan waktu yang singkat akan menghindarkan subjek menggunakan gerakan mata untuk melakukan eksplorasi dalam merespons. Subjek memberikan respons pada metode *Go/Nogo*. Untuk setiap target, mereka harus mengangkat jari mereka dari tombol secepat dan seakurat mungkin (*latency* peralatan ini adalah di bawah 1 ms). Subjek diberi waktu 1000 ms untuk merespons. Apabila tidak ada respons dalam waktu lebih dari 1000 ms, sistem menganggapnya sebagai respons *Nogo*. *Stimulus onset asynchrony* (SOA) adalah 2000 ms ditambah penundaan acak sebesar kurang lebih 200 ms. Untuk setiap gambar bukan target, subjek harus terus menekan tombol selama setidaknya 1000 ms (respons *Nogo*).

Stimulus yang digunakan adalah gambar alam yang di dalamnya terdapat gambar binatang. Gelombang otak direkam menggunakan 32 elektroda yang dipasang pada topi elastis (Oxford Instrumen) dengan posisi FP1, FP2, F3, F4, C3, C4, P3, P4, O1, O2, F7, F8, T7, T8, P7, P8, Fz, Pz, TP7, TP8, PO7, PO8, PO3, PO4, POz, Oz, Iz, O9, O10, PO9, PO10, dan AFz menurut sistem internasional 10-20. Elektroda Cz digunakan sebagai referensi dan elektroda mastoid digunakan sebagai dasar. Pengambilan data dilakukan pada 1000 Hz (sesuai dengan bin sampel dari 1 ms) menggunakan sistem pencatatan SynAmps ditambah dengan komputer PC. Impedansi kulit dijaga dibawah 5 KOhm. Gbr. 2

mengilustrasikan pengambilan data yang dipergunakan dalam penelitian ini.



Gbr. 2 Sistem pengambilan data metode *Go/Nogo Task*

III. PENGOLAHAN SINYAL DAN PENGENALAN POLA

Pada percobaan, sinyal EEG diasumsikan sebagai sinyal stokastik yang linear dan stasioner. Pengolahan sinyal dilakukan dengan membagi sinyal ke dalam tiga segmen, yaitu 250 ms, 500 ms dan 1000 ms setelah rangsangan visual terjadi. Terhadap setiap segmen akan dilakukan pemrosesan sinyal dan dikenali polanya menggunakan *support vector machine* (SVM). Gbr. 3 memperlihatkan diagram blok metode sistem pengenalan pola pergerakan jari yang digunakan.



Gbr. 3 Diagram blok sistem pengenalan pola pergerakan jari

Pengolahan sinyal EEG diawali dengan melakukan pemisahan sinyal untuk tiap *trial*. Setiap *trial* terdiri atas sinyal dengan kisaran 2000 ms, yang terdiri atas 500 ms sebelum stimulus visual muncul dan 1000 ms setelah stimulus visual muncul. Maka, dengan frekuensi sampling 1000 Hz, setiap *trial* memiliki 2000 sampel data. Sinyal kemudian dinormalisasi. Sebagai sinyal referensi, digunakan sinyal rata-rata masing-masing kanal dengan kisaran 500 ms sebelum stimulus muncul sampai dengan stimulus muncul. Jika didefinisikan $x(c, k)$ dan $x(c, i)$ adalah sinyal EEG hasil pengukuran dengan c adalah jumlah kanal atau elektroda, k dan i adalah sampel sinyal dengan $1 \leq k \leq 2000$ dan $1 \leq i \leq 500$, maka $\hat{x}_{normalisasi}(c, k)$ dapat dihitung dengan (1).

$$\hat{x}_{normalisasi}(c, k) = x(c, k) - \frac{1}{N} \sum_{i=1}^N x(c, i) \quad (1)$$

dengan $N = 500$. N menunjukkan lebar *window* sinyal normalisasi yang digunakan. Sinyal kemudian ditapis menggunakan *band pass filter* Butterworth orde 2. Tapis ini digunakan untuk mengambil sinyal *mu rhythm* pada EEG yang terletak pada rentang frekuensi 8 Hz hingga 13 Hz dan *beta rhythm* yang memiliki rentang frekuensi 13 Hz sampai 30 Hz. Oleh sebab itu, frekuensi *cutoff* yang digunakan pada *band pass filter* Butterworth dalam penelitian ini adalah 8 Hz

dan 35 Hz. Tahap berikutnya adalah penapisan secara spasial sinyal EEG menggunakan metode *common average reference* (CAR) [9]. Sinyal multi-kanal EEG dapat dideskripsikan sebagai sinyal dengan gangguan, Y , yang terbentuk dari sinyal EEG yang tidak diketahui, X , dan sinyal gangguan yang tidak diketahui, N . Sinyal EEG ini dapat diformulasikan dengan persamaan,

$$Y = AX + N \quad (2)$$

dengan Y adalah vektor $nx1$ yang diperoleh dari pengukuran n kanal, X adalah vektor $kx1$ yang merupakan sinyal EEG yang sebenarnya (k merepresentasikan jumlah sumber sinyal dari syaraf), A adalah matrik nxk dengan $n > k$ yang memetakan X ke Y , dan N adalah vektor $nx1$ yang merupakan random noise yang terdistribusi normal dengan $E[X] = 0$ dan *covariance* K . Untuk mendekati nilai X dari pengukuran parameter nilai Y , digunakan estimasi nilai \hat{X} dengan \hat{X} merupakan fungsi yang linier dengan Y , sehingga

$$\hat{X} = BY \quad (3)$$

Gauss-Markov menyatakan bahwa pada model linear dengan kesalahan yang memiliki $E[\hat{X}] = 0$ dan *variance* yang sama, koefisien estimasi linear tanpa bias terbaik didapatkan dari *least square estimator*, sehingga dengan persamaan tersebut, matriks B dapat ditentukan, dengan matriks B adalah *spatial filter* yang memberikan estimasi linear tanpa bias dari nilai X berdasarkan nilai Y . Filter B_i dapat dihitung dengan persamaan

$$B_i = (A_i^T K^{-1} A_i)^{-1} A_i^T K^{-1} \quad (4)$$

Apabila diasumsikan,

1. jarak titik cukup besar untuk menentukan bahwa neuron-neuron dapat diwakili hanya pada satu titik, maka A_i untuk masing-masing kanal adalah $[1,0,0,\dots,0]$, dan
2. model sinyal *noise* setiap kanal adalah identik, sehingga menghasilkan *covariance* K dengan nilai 1 untuk komponen matriks diagonal dan nilai c untuk komponen matrik yang bukan diagonal,

maka filter B_i untuk masing-masing kanal adalah

$$B_i = [1, \alpha, \alpha, \dots, \alpha] \quad (5)$$

dengan $\alpha = -\frac{c}{1+(n-2)c}$. Apabila nilai c semakin besar (mendekati 1), maka nilai α mendekati $-\frac{1}{(n-1)}$, sehingga persamaan *spatial filter* untuk masing-masing kanal menjadi

$$B_i = \left[1, -\frac{1}{(n-1)}, -\frac{1}{(n-1)}, \dots, -\frac{1}{(n-1)}\right] \quad (6)$$

sehingga dengan memasukkan (6) ke dalam (3), estimasi sinyal EEG \hat{X} dapat ditentukan.

Menilik asumsi yang dipergunakan bahwa sinyal EEG adalah sinyal stokastik yang linear dan stasioner [3], maka perhitungan PSD menggunakan metode Burg [3] dapat dilakukan. PSD dengan menggunakan metode Burg merupakan perhitungan PSD dengan pendekatan *parametric* dengan persamaan sebagai berikut:

$$\hat{P}(f) = \frac{1}{F_s} \frac{p}{\left|1 + \sum_{i=1}^6 a_i e^{-j2\pi f \frac{i}{F_s}}\right|^2} \quad (7)$$

dengan p adalah *power spectral white noise* dan F_s adalah frekuensi sampling, sedangkan a_i adalah koefisien-koefisien yang didapat dari estimasi *autoregression* menggunakan metode Burg.

Pemilihan kanal dan frekuensi PSD sinyal EEG yang digunakan sebagai fitur dalam pengenalan pola dilakukan dengan memilih nilai *coefficient of determination* (r^2) yang terbesar. *Coefficient of determination* pada dasarnya adalah nilai kuadrat koefisien korelasi untuk sebuah distribusi *bivariate* yang dibangun dari dua buah *dataset* yang *univariate* sebagai berikut [4]:

1. Apabila terdapat sebuah *dataset* dengan $x_i^{(1)}$ berjumlah $n^{(1)}$ trial dan sebuah *dataset* $x_i^{(2)}$ berjumlah $n^{(2)}$ trial, dan
2. dari kedua *dataset* tersebut, di setiap *dataset* terbentuk 2D data yang memiliki nilai (x,y) dengan x adalah nilai yang terukur dan y adalah nilai yang terbentuk pada kondisi tertentu; sebagai contoh adalah y bernilai +1 untuk nilai x yang diukur pada kondisi A dan y bernilai -1 pada nilai x yang diukur pada kondisi B,

maka untuk 2D *dataset* dari point (x,y) , *coefficient of determination* dihitung dengan persamaan:

$$r^2 = \frac{cov(x,y)}{var(x)var(y)} \quad (8)$$

Apabila didefinisikan $s_k := \sum_i x_i^{(k)}$ dan $q_k := \sum_i x_i^{(k)2}$, dengan nilai $k = 1$ untuk kondisi A dan $k = 2$ untuk kondisi B, maka:

$$cov(x,y) = \frac{s_1 - s_2}{n_1 + n_2} - \frac{(s_1 + s_2)(n_1 - n_2)}{(n_1 + n_2)^2} \quad (9)$$

$$var(x) = \frac{q_1 + q_2}{n_1 + n_2} - \frac{(s_1 + s_2)^2}{(n_1 + n_2)^2} \quad (10)$$

$$var(y) = 1 - \frac{(n_1 - n_2)^2}{(n_1 + n_2)^2} \quad (11)$$

Vektor fitur yang dihasilkan oleh metode-metode diatas digunakan oleh SVM untuk dikenali polanya. Kernel yang dipergunakan oleh SVM adalah *radial basis function* (RBF) [3].


IV. HASIL PERCOBAAN DAN DISKUSI

Analisis data dilakukan secara *offline* menggunakan software MATLAB [18]. Langkah pertama yang perlu dilakukan untuk validasi adalah memastikan sinyal yang digunakan memiliki properti fisis yang telah disebutkan sebelumnya. Properti fisis ini adalah:


1. sinyal yang digunakan berasal dari *motor cortex area* dan *sensory cortex area*,
2. terjadi fenomena ERD dan ERS pada sinyal tersebut.

Gbr. 4 dan Gbr. 5 menunjukkan fenomena ERD/ERS yang terjadi pada sinyal EEG yang didapat dari kanal C3 dan C4. PSD pada Gbr. 4 dan Gbr. 5 diperoleh dari perhitungan PSD menggunakan metode Burg. Dapat dilihat bahwa sinyal EEG,

mu rhythm dan *beta rhythm* pada kanal C3 dan C4 ketika terjadi pergerakan jari (biru) memiliki amplitude yang lebih rendah dibandingkan dengan ketika tidak terjadi pergerakan jari (merah).



Gbr. 4 PSD (Burg) pada C3 (rata-rata)

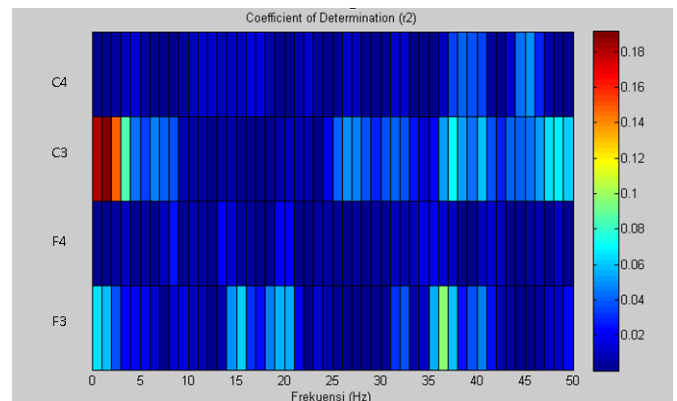


Gbr. 5 PSD (Burg) pada C4 (rata-rata)

Percobaan dilakukan menggunakan $\pm 80\%$ data untuk training sistem dan $\pm 20\%$ untuk pengujian. Jumlah *event* pada setiap *trial* adalah 100 *event*. Namun, percobaan hanya menggunakan *event* yang valid, yaitu stimulus yang muncul (gambar binatang/gambar bukan binatang) sesuai dengan respons yang dilakukan oleh subjek (mengangkat jari/tidak mengangkat jari), sehingga jumlah *event* yang digunakan adalah 99 sampai dengan 100 dalam setiap *trial*.

Seperti yang telah dijelaskan sebelumnya, fitur frekuensi dan kanal dipilih menggunakan r^2 . Gbr. 6 mengilustrasikan nilai r^2 setiap kanal dan frekuensi yang dihasilkan oleh perhitungan menggunakan (8). Nilai r^2 yang dipilih adalah nilai r^2 terbesar ($p < 0.05$), yang berada pada frekuensi 8 Hz sampai dengan 35 Hz (*mu rhythm* dan *beta rhythm*). Penggunaan PSD Burg dilatarbelakangi oleh penggunaan data

sampel yang terbatas dalam melakukan percobaan. Seperti yang telah dijelaskan sebelumnya pula, percobaan ini memisahkan data sampel ke dalam tiga segmen. yakni sinyal dengan sampel 1000 ms, 500 ms dan 250 ms.



Gbr. 6 Nilai r^2 pada percobaan lmi01ff08 (1000 ms)

Hasil pengenalan pola oleh sistem dapat dilihat pada Tabel I. Terlihat bahwa akurasi paling tinggi terjadi ketika sampel memiliki panjang 1000 ms. Sistem dapat mengenali kejadian pergerakan jari dengan tingkat keberhasilan rata-rata 65,37%. Dapat dilihat pula bahwa penggunaan *spatial filter* CAR pada sistem dapat meningkatkan akurasi dalam melakukan pengenalan pola pada sampel dengan panjang 1000 ms dan 250 ms. Tingkat akurasi yang dihasilkan ini merupakan hasil analisis percobaan secara *offline* dan belum dilakukan percobaan secara online.

TABEL I
AKURASI PENGENALAN POLA MENGGUNAKAN PSD BURG (%)

Subjek	Raw			CAR		
	1s	0,5s	0,25s	1s	0,5s	0,25s
cba01ff08	80	50	45	70	55	45
ega01ff08	52,63	68,42	52,63	73,68	57,89	52,63
fsa01ff08	50	65	55	55	50	55
gro01ff08	50	50	50	65	65	50
lmi01ff08	63,16	47,36	57,89	63,16	52,63	57,89
Rata-rata	59,16	56,16	52,10	65,37	56,10	58,16

Hal yang menarik terlihat ketika panjang sampel data pengenalan yang digunakan dibandingkan dengan waktu respons tiap subjek. Tabel II menunjukkan rata-rata waktu respons tiap subjek. Dapat dilihat bahwa rata-rata subjek melakukan respons mengangkat jari adalah pada waktu 339,2 ms. Perbandingan dilakukan menggunakan sampel dengan panjang 250 ms. Penggunaan fitur PSD pada sistem tidak memerlukan kalkulasi komputasi yang panjang dan lama [11]. Berdasarkan informasi ini, dapat disimpulkan bahwa sistem dapat digunakan untuk mendeteksi intensi pergerakan jari sebelum bergerak (berdasarkan waktu respons rata-rata) dengan tingkat keberhasilan rata-rata 58,15 %. Meskipun akurasi yang diperoleh masih kecil, hal ini membuka peluang pemanfaatan prediksi intensi pergerakan sebagai fitur

tambahan pada aktif *prosthesis* sehingga dapat memperpendek waktu respons sistem.

TABEL III
RATA-RATA WAKTU RESPONS SUBJEK

Subjek	Waktu respons (ms)
cba01ff08	294,0
ega01ff08	381,8
fsa01ff08	384,4
gro01ff08	321,1
lmi01ff08	315,3

V. KESIMPULAN

Kesimpulan yang diperoleh dari penelitian ini adalah bahwa PSD Burg dapat digunakan untuk melakukan klasifikasi sinyal EEG. Namun, jumlah sampel yang digunakan dalam perhitungan PSD perlu diperhatikan. Hasil percobaan memperlihatkan bahwa semakin kecil jumlah sampel yang digunakan, semakin kecil pula akurasi klasifikasi yang didapatkan. Selain hal tersebut, penggunaan *spatial filter* CAR pada sistem dapat meningkatkan akurasi klasifikasi hingga rata-rata $\pm 7\%$ pada penelitian ini.

Pada penelitian selanjutnya, akan dilakukan klasifikasi pergerakan menggunakan analisis *time-frequency*. Hal ini dilakukan untuk meningkatkan akurasi klasifikasi sistem. Selain itu, pendeteksian intensi pergerakan sebelum pergerakan terjadi menjadi nilai tambah yang dapat meningkatkan kemampuan sistem aktif *prosthesis* yang telah ada.

UCAPAN TERIMA KASIH

Terima kasih kepada Dalorme et al. yang telah menyediakan data eksperimen pada Swartz Center for Computational Neuroscience [10].

REFERENSI

- [1] Dennis J. McFarland, Laurie A. Miner, Theresa M. Vaughan, and Jonathan R. Wolpaw, "Mu and Beta Rhythm Topographies During

- Motor Imagery and Actual Movements", *Brain Topography*, Volume 12, Number 3, 2000.
- [2] Tatum, W., et al. "Handbook of EEG Interpretation", Demos Medical Publishing, USA, 2008.
- [3] Sanei, S. and Chambers, A., "EEG Signal Processing", John Willey & Sons, Ltd, United Kingdom, 2007.
- [4] Juergen Mellinger, "User Tutorial: Mu Rhythm BCI Tutorial", 2007. [Online]. Available: <http://www.bci2000.org/wiki/>
- [5] Wolpaw, J.R., et al. *Brain-computer interfaces for communication and control*. Clinical Neurophysiology 113 (2002) 767-791. Elsevier. 2002.
- [6] Garcia, Gary. Direct Brain-Computer Communication Through Scalp Recorded EEG Signal. Lausanne, EPFL. 2004.
- [7] (2014) BCI2000 website. [Online]. Available: <http://www.schalklab.org/research/bci2000>
- [8] Ludwig, K.A. et al. *Using a Common Average Reference to Improve Cortical Neural Recording From Microelectrode Arrays*. *Journal of Neurophysiology*, 101(3):1679-1689. 2009.
- [9] Darmakusuma R., et al., "Revisit: Pattern Recognition of Mu-Rhythm Using Autoregressive and Linear Classifier", ICSET2014, Bandung. 2014.
- [10] (2014) Swartz Center for Computational Neuroscience website [Online]. Available: <http://sccn.ucsd.edu>
- [11] Ahmadi, A., et al., "Light-weight Single Trial EEG Signal Processing Algorithms: Computational Profiling for Low Power Design", International Conference of the IEEE Engineering in Medicine and Biology Society, 2011:4426-30. 2011.
- [12] Carlos A. Pardo, M.D., *Brain, Spinal Cord and Cells: A Neuro-primer for Non-neurologists*, Transverse Myelitis Association Journal Volume 1, Article 8. Johns Hopkins Transverse Myelitis Center; Johns Hopkins University School of Medicine. 2006.
- [13] Melissa Conrad Stöpler, MD., "Paralysis", 2012. [Online] Available: <http://www.medicinenet.com/paralysis/symptoms.htm>
- [14] Malmivuo, J. and Plonsey, R., *Bioelectromagnetism: Principles and Application of Bioelectric and Biomagnetic Fields*. Oxford University Press. 1995.
- [15] Selim R Benbadis, MD, et al., "Normal Awake EEG", 2013. [Online] Available: <http://emedicine.medscape.com/article/1140143-overview>
- [16] Pires, G, Nunes, U, and Castelo-Branco M., "Single-Trial EEG Classification of Movement Related Potential", IEEE 10th International Conference on Rehabilitation Robotics, June 12-15, Noordwijk, The Netherlands. 2007.
- [17] Delorme, A., Rousselet, G., Mace, M., Fabre-Thorpe M. Interaction of Bottom-up and Top-down processing in the fast visual analysis of natural scenes. *Cognitive Brain Research*, 103-113.
- [18] (2015), Mathworks website [Online], Available: <http://www.mathworks.com/>