

Brain Computer Interface Untuk Menggerakkan Animator Pemukul Bass Drum Menggunakan Wavelet dan Support Vector Machine

Azmira Mifti Harjana¹, Esmeralda C Djamal, Ridwan Ilyas
Jurusan Informatika, Fakultas Sains dan Informatika
Universitas Jenderal Achmad Yani
Cimahi
¹azmiramifti@gmail.com

Abstrak—Penderita kelumpuhan sering mengalami kesulitan untuk berinteraksi dengan perangkat eksternal disebabkan kinerja saraf untuk menyampaikan perintah dari otak ke otot menurun. Pengembangan teknologi Brain Computer Interface (BCI) memungkinkan seseorang dapat menggerakkan perangkat eksternal dengan menggunakan sinyal EEG sebagai komponen intermediate ketika membayangkan gerakan yang diinginkan (motor imagery) tanpa melibatkan fungsi motorik lainnya. Karakteristik sinyal EEG yang memiliki amplitudo rendah menyebabkan rentan terhadap noise dan mudah dipengaruhi variabel lain. Bentuk yang kompleks serta bersifat non stasioner menyebabkan variabel motor imagery tidak mudah untuk diidentifikasi. Penelitian ini membangun perangkat BCI yang dapat mengidentifikasi pikiran saat membayangkan suatu gerakan untuk menggerakkan animasi pemukul bass drum dengan lima kelas gerakan. Sistem dilatih terlebih dahulu menggunakan 2000 set data dari 10 naracoba untuk lima kelas dengan lima kali perulangan. Variabel motor imagery didapatkan dari sinyal EEG yang diekstraksi dengan Wavelet Daubechies10 untuk mendapatkan sinyal gelombang Alfa dan Beta serta ditambahkan analisa statistik dan sinkronisasi kanal simetrik sehingga menghasilkan 224 data untuk empat kanal. Data tersebut digunakan sebagai vektor fitur untuk tahap identifikasi dengan Support Vector Machine hyperplane Non Linier dengan kernel Polynomial orde 2. Hasil penelitian diperoleh akurasi sebesar 37% untuk data baru, sedangkan terhadap data latih sebesar 88%. Penggunaan fitur statistik amplitudo dan sinkronisasi kanal simetrik dapat meningkatkan akurasi sebesar 7%. BCI dan EEG diintegrasikan secara real time melalui implementasi perangkat lunak BCI, EEG dan animasi pemukul bass drum.

Kata kunci—*motor imagery; EEG; Wavelet; SVM; BCI*

I. PENDAHULUAN

Otot dan saraf merupakan komponen yang berperan penting pada seluruh aktivitas manusia baik secara sadar maupun tidak sadar. Saraf mengirimkan perintah yang diterima dari otak ke otot agar dapat berkomunikasi dan mengendalikan sensor motorik. Namun, kemampuan saraf yang menurun merupakan penyebab terjadinya kelumpuhan fisik sehingga penderita kelumpuhan mengalami keterbatasan gerakan dan kesulitan untuk berinteraksi dengan perangkat eksternal. Salah satu

alternatif untuk menangani permasalahan tersebut yaitu dengan memanfaatkan teknologi Brain Computer Interface (BCI).

BCI merupakan suatu teknologi yang mengolah sinyal otak lalu diterjemahkan menjadi sebuah perintah sehingga manusia dapat menggerakkan perangkat eksternal dengan kondisi pikiran saat membayangkan gerakan (*motor imagery*) yang diinginkan tanpa melibatkan gestur, otot, suara, dan fungsi motorik lainnya. Persoalan utama BCI terletak dari komponen *intermediate*, yang biasanya menggunakan Elektroensefalogram (EEG), Near-Infrared Spectroscopy (NIRS), atau Functional Magnetic Resonance Imaging (FRMI).

EEG adalah suatu alat elektromedik untuk merekam sinyal bioelektrik yang berasal dari aktivitas listrik pada otak. Hasil perekaman sinyal EEG ketika membayangkan gerakan tidak dapat langsung diidentifikasi menjadi sebuah perintah karena mengandung banyak informasi dari variabel lain seperti emosi, kesehatan, usia, dan lingkungan pengguna sehingga pola sinyal EEG menjadi lebih kompleks. Selain itu, sinyal EEG memiliki amplitudo yang rendah dan bersifat *nonstationer* sehingga dibutuhkan suatu pemrosesan untuk mendapatkan fitur unik dari sinyal EEG ketika membayangkan gerakan.

Sinyal EEG jika direkam dengan frekuensi sampling 128 Hz, diperoleh sinyal dengan frekuensi 0-64 Hz. Komponen gelombang sinyal EEG yang ditinjau dari rentang frekuensi di antaranya gelombang Alfa (8-13 Hz) ketika kondisi sedang rileks, gelombang Beta (14-30 Hz) ketika terdapat aktifitas berpikir, gelombang Teta (4-7 Hz) ketika tidur ringan, mengantuk atau stress emosional, gelombang Delta (0.5-3 Hz) ketika tidur nyenyak, gelombang Gama (>30 Hz) serta gelombang Mu (7.5 – 12.5 Hz) ketika membayangkan suatu gerakan badan. Dari penelitian terdahulu, aktivitas membayangkan gerakan biasanya menggunakan gelombang Alfa (8-13 Hz) dan gelombang Beta (17-24 Hz)[1]. Selain itu, ketika membayangkan suatu gerakan maka terjadi peningkatan dan penurunan nilai amplitudo tiap gelombang pada bagian kontralateral[2]. Oleh karena itu, penggunaan fitur statistik amplitudo dibutuhkan untuk menganalisa amplitudo pada sinyal sehingga dapat meningkatkan kemampuan identifikasi.

Penelitian sebelumnya memanfaatkan BCI untuk mengendalikan perangkat keras seperti pengendalian robot secara *mobile*[3] dan mengendalikan peralatan rumah[4],

asisten pasien untuk tindakan buka tutup pintu dan menyalakan atau mematikan lampu[5], hingga mengendalikan teknologi rangka tangan untuk rehabilitasi stroke[6]. BCI juga digunakan untuk mengendalikan perangkat lunak seperti menggerakkan karakter *game*[7], menggerakkan kursor[8], mengendalikan komputer[9], menggerakkan mouse otomatis[10], hingga permainan catur[11].

Dalam mengendalikan perangkat eksternal secara langsung dari pikiran melalui sinyal EEG, diperlukan metode ekstraksi dan identifikasi yang tepat. Beberapa metode untuk ekstraksi menggunakan Wavelet[12][1], Fast Fourier Transform[7], dan Autoregressive[13]. Sementara itu, sistem identifikasi yang dibangun dari sinyal EEG biasanya tergantung dari variabel yang ditinjau. Beberapa penelitian menggunakan algoritma Support Vector Machine [14] dan Learning Vector Quantization[7] untuk aksi *player game*, Adaptive Backpropagation[13] untuk memikirkan gerakan tangan

Penelitian ini telah membuat sistem yang dapat menerjemahkan pikiran ketika membayangkan gerakan berbasis sinyal EEG yang dapat menggerakkan perangkat eksternal secara *real time*. Dalam sistem identifikasi, hal yang paling penting adalah kualitas data latih pada kelas yang sudah ditentukan. Oleh karena itu, perekaman sinyal EEG untuk data latih diberikan instruksi audio visual berupa video gerakan memukul bass drum.

Sistem identifikasi dibangun menggunakan ekstraksi Wavelet dan Support Vector Machine (SVM) yang diawali dengan pelatihan menggunakan 2000 set data. Luaran sistem difokuskan untuk identifikasi pikiran ketika membayangkan gerakan saat mengoperasikan perangkat eksternal berupa animasi pemukul bass drum dengan gerakan memukul sekali menggunakan tangan kanan (Kanan1), memukul sekali menggunakan tangan kiri (Kiri1), gerakan diam (Diam), gerakan memukul berkali-kali menggunakan tangan kanan (Kanan2) dan gerakan memukul bass drum berkali-kali menggunakan tangan kiri (Kiri2). BCI diintegrasikan dengan *wireless* EEG tipe Insight Emotiv secara *real time* setiap detik.

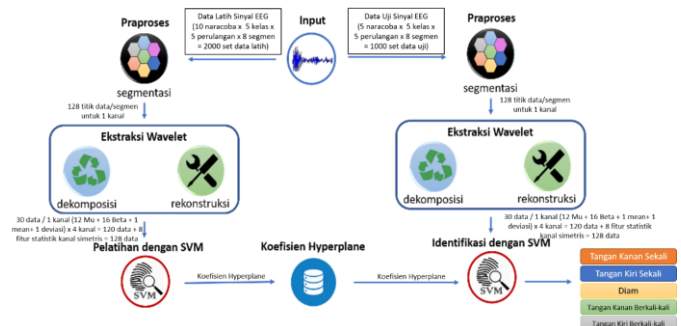
II. METODE

Tahap identifikasi sinyal EEG untuk menggerakkan animasi pemukul bass drum dapat dilihat pada **Error! Reference source not found.** Sistem Brain Computer Interface untuk menggerakkan animasi pemukul bass drum diawali dengan perekaman sinyal EEG terhadap 10 naracoba sehingga diperoleh 2000 set data latih. Setelah itu, dilanjutkan dengan tahap ekstraksi menggunakan Wavelet agar mendapatkan fitur sinyal EEG ketika membayangkan gerakan di antaranya gelombang Alfa pada frekuensi 8-13 Hz dan gelombang Beta pada frekuensi 17-24 Hz. Kedua fitur gelombang tersebut ditambahkan dengan analisa fitur statistik amplitudo yaitu nilai minimum, nilai maksimum dan nilai rata-rata dari tiap 16 titik data yang digunakan sebagai *input* dalam tahap pelatihan menggunakan Support Vector Machine *hyperplane* Non Linear kernel Polynomial orde 2.

A. Akuisisi Data

Tahap akuisisi data dilakukan dengan perangkat *wireless* EEG Emotiv Insight empat kanal AF3, AF4, T7, dan T8

dengan frekuensi sampling 128 Hz pada 10 naracoba. Perekaman dilakukan selama 90 detik dengan perulangan sebanyak lima kali. Selama 90 detik perekaman, naracoba diberikan video instruksi disertai rangsangan suara dari lima perintah gerakan tangan yang harus dibayangkan saat memukul bass drum secara bergantian tiap 18 detik. Kemudian tiap kelas disegmentasi kembali menjadi tiga bagian, lima detik pertama untuk instruksi, lima detik terakhir untuk jeda berpikir serta delapan detik ditengah adalah waktu untuk membayangkan gerakan. delapan detik tersebut akan disegmentasi kembali tiap satu detik. Tahap ini menghasilkan sebanyak 2000 set data latih untuk lima kelas.



Gambar 1 Perancangan BCI untuk menggerakkan pemukul bass drum

B. Wavelet

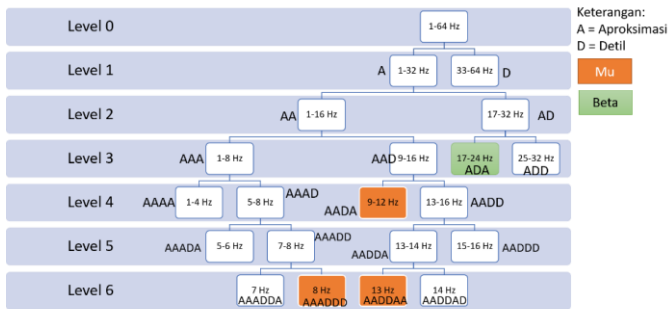
Transformasi Wavelet adalah metode pengolahan untuk mengubah sinyal dari domain waktu ke bentuk wavelet. Wavelet adalah sebuah gelombang kecil yang mempunyai energi terkonsentrasi dalam waktu untuk menganalisis suatu sinyal dengan fenomena transien, nonstasioner, dan berubah waktu sehingga tepat digunakan untuk analisa sinyal EEG. Transformasi Wavelet menggunakan dua proses utama yaitu dekomposisi untuk mengekstraksi sinyal dan rekonstruksi untuk mengembalikan sinyal seperti semula. Pada tahap dekomposisi, terdapat operasi matematis *inner product* dua fungsi dengan melewati koefisien *low-pass filter* (Aproksimasi) dan *high-pass filter* (Detil) yang disebut proses konvolusi. Kemudian sinyal dilakukan pengurangan menjadi setengah bagian dengan mengambil data berindeks ganjil saat *high-pass filter* yang bisa didapatkan melalui Persamaan (1) dan mengambil data berindeks genap saat *low-pass filter* melalui Persamaan (2).

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

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

Dimana, x adalah data sinyal EEG, k dan n adalah indeks ke 1 hingga panjang sinyal asli, serta $g(n)$ adalah koefisien *low-pass filter* sedangkan $h(n)$ adalah koefisien *high-pass filter*. Pada penelitian ini digunakan Wavelet Daubechies order 10 dikarenakan menghasilkan performa yang paling tinggi untuk kasus *motor imagery* dibandingkan dengan Discrete Meyer, Wavelet Coiflets5, Rbio1[15]. Wavelet Daubechies10 memiliki 20 koefisien pada masing-masing filter. Dimana $g(n)$ adalah koefisien *low-pass filter* dan $h(n)$ adalah koefisien *high-pass filter*. Proses dekomposisi dilakukan berulang-ulang sesuai

dengan rentang frekuensi yang ditargetkan seperti pada Gambar 2



Gambar 2 Multilevel Dekomposisi

Ekstraksi gelombang Alfa berfungsi untuk mendapatkan sinyal Alfa yang terdapat pada rentang 8Hz, 9-12Hz, dan 13Hz dengan melakukan transformasi sinyal sebanyak enam, empat dan enam kali konvolusi. Untuk mendapatkan Gelombang Alfa dengan rentang 8Hz dilakukan dekomposisi dengan rangkaian tiga aproksimasi dan tiga detil. Gelombang Alfa dengan rentang 9-12Hz didapatkan langkah dua aproksimasi, satu detil, satu aproksimasi. mendapatkan Gelombang Alfa dengan rentang 13Hz didapatkan langkah dengan dua aproksimasi, dua detil, dan dua aproksimasi. Sehingga proses ekstraksi gelombang Alfa menghasilkan data sebanyak menghasilkan $2+8+2 = 12$ data untuk tiap segmen/kanal.

Ekstraksi gelombang Beta berfungsi untuk mendapatkan sinyal Beta yang terdapat pada rentang 17-24Hz dengan melakukan transformasi sinyal sebanyak tiga kali konvolusi. Untuk mendapatkan Gelombang Beta dengan rentang 17-24Hz didapatkan langkah satu aproksimasi, satu detil dan satu aproksimasi. Sehingga proses ekstraksi gelombang Beta menghasilkan data sebanyak 16 data untuk tiap segmen/kanal. Hasil dari dekomposisi gelombang Alfa dan Beta untuk satu segmen adalah $12 + 16 = 28$ data dari satu kanal.

Kemudian, untuk meningkatkan akurasi pada tahap identifikasi, perhitungan statistik terhadap sinyal EEG hasil perekaman digunakan sebagai fitur tambahan dari karakteristik sinyal *motor imagery*. Fitur statistik diambil tiap 16 titik data dari tiap segmen perkanal. Fitur statistik yang ditinjau yaitu Nilai minimum(min), nilai maksimum (max), dan nilai rata-rata(mean). Tiap segmen perkanal menghasilkan 8 nilai untuk masing-masing fitur. Sehingga data yang digunakan sebagai input untuk tahap identifikasi sebanyak 28 data gelombang + 24 data statistik = 52 data tiap kanal per segmen Selain itu, terdapat fitur yang menunjukkan sinkronisasi dari dua kanal yang diambil dari tiap 16 titik data untuk tiap dari segmen.

C. Support Vector Machine

Support Vector Machine (SVM) merupakan metode analisis data untuk memisahkan sekumpulan objek antara dua kelas linear berdasarkan ciri dengan mencari nilai *hyperplane* yang optimal. Jarak data terdekat dari tiap kelas atau sering disebut *support vector* dengan nilai *hyperplane* disebut Margin.

Untuk mendapatkan *hyperplane* yang optimal maka diperlukan jarak margin maksimal dari kedua kelas dengan mencari

koefisien w dan b menggunakan Persamaan (3). Pada kasus pemisahan data dengan teknik SVM nonlinier, data dikonversi ke dalam pemetaan dimensi yang lebih tinggi.

$$\psi_{\sigma, \tau}(n) = \frac{1}{\sqrt{|\sigma|}} \psi\left(\frac{n-\tau}{\sigma}\right) \quad (3)$$

Dalam memetakan data input ke dalam dimensi yang lebih tinggi digunakan metode kernel seperti Polynomial, Gaussian Radial Basis Function, Sigmoid, dan Invers Multi Kuadratik. Penelitian ini menggunakan kernel Polynomial orde dua yang memiliki fungsi kernel seperti pada Persamaan (4).

$$K(x, x_i) = (\overline{x_i \cdot x_i} + 1)^2 \quad (4)$$

Dimana K adalah nilai kernel, x_i adalah vektor fitur data latih, x_j adalah vektor fitur data baru. Pada tahap ekstraksi, dihasilkan data sebanyak 52 data untuk tiap kanal sehingga vektor fitur yang digunakan untuk input tahap identifikasi yaitu 52 data x 4 kanal = 208 data + 16 data sinkronisasi dari 2 pasang kanal = 224 data. Vektor fitur untuk input tahap identifikasi dijelaskan pada Tabel I

TABEL I VEKTOR FITUR

No	Vektor fitur	Komponen	Kanal
1.	x1-x12	Alfa	AF3
2.	x13-x28	Beta	AF3
3.	x29-x36	Min	AF3
4.	x37-x44	Max	AF3
5.	x45-x52	Mean	AF3
6.	x52-x64	Alfa	T7
7.	x65-x80	Beta	T7
8.	x81-x88	Min	T7
9.	x89-x96	Max	T7
10.	x97-x104	Mean	T7
11.	x105-x116	Alfa	T8
12.	x117-x132	Beta	T8
13.	x133-x140	Min	T8
14.	x141-x148	Max	T8
15.	x149-x156	Mean	T8
16.	x157-x168	Alfa	AF4
17.	x169-x184	Beta	AF4
18.	x185-x192	Min	AF4
19.	x193-x200	Max	AF4
20.	x201-x208	Mean	AF4
21.	x209-x216	Sinkronisasi1	AF3-AF4
22.	x217-x224	Sinkronisasi2	T7-T8

Sehingga untuk koefisien b didapat dengan Persamaan (5) dan koefisien fungsi *hyperplane* pemisah w didapatkan dengan Persamaan (6) yang disebut dengan perhitungan *constraint*.

$$\sum_{i=1}^N \alpha_i y_i = 0 \quad (5)$$

$$w = \sum_{i=1}^N \alpha_i y_i (\bar{x}_i, \bar{x}_i + 1)^2 \quad (6)$$


Nilai α dari *support vector* digunakan untuk menentukan kelas dari data yang diidentifikasi dengan memasukkannya ke dalam Persamaan (8) yang menghasilkan nilai antara +1 dan -1.

$$\text{Sign} \left(\sum_{i=1}^N \alpha_i y_i (\bar{x}_i, \bar{x}_i + 1)^2 + b \right) \quad (7)$$

Dimana N adalah jumlah fitur data latih, α_i adalah koefisien alfa ke- i , y adalah kelas dari *support vector*, \bar{x}_i, \bar{x}_j hasil dot-product vektor data latih dan vektor data uji dan b adalah bias.

Oleh karena itu, dari 2000 set data latih yang digunakan sebanyak 224 set data untuk pelatihan tiap SVM. Jumlah titik data latih tersebut digunakan untuk langkah pertama saat dimasukkan ke dalam SVM yaitu dengan menghitung nilai kernel menggunakan Polynomial Ordo 2 berdasarkan Persamaan (7). Data latih tersebut menghasilkan 50.176 nilai kernel (224×224).

Pada penelitian ini, terdapat lima kelas yang diidentifikasi yaitu tangan kanan memukul sekali, tangan kiri memukul sekali, gerakan diam, tangan kanan memukul berkali-kali, tangan kiri memukul berkali-kali seperti pada sehingga proses SVM dilakukan sebanyak empat kali untuk mendapatkan empat *hyperplane* seperti pada Gambar 3. Pada *hyperplane* pertama memisahkan antara kelas tangan kanan memukul sekali, (+1) dan lainnya (-1). Kemudian pada *hyperplane* kedua, kelas -1 dipisahkan antara kelas tangan kiri memukul sekali (+1) dan lainnya (-1). Pada *hyperplane* ketiga, kelas -1 dipisahkan menjadi kelas gerakan diam (+1) dan lainnya (-1). Lalu pada *hyperplane* terakhir kelas -1 dibagi menjadi kelas tangan kanan memukul berkali-kali (+1) dan kelas tangan kiri memukul berkali-kali (-1).



Gambar 3 SVM 5 kelas

III. HASIL DAN DISKUSI

Pengujian yang dilakukan dalam penelitian ini di antaranya pengujian terhadap pengaruh fitur statistik amplitudo dan sinkronisasi kanal, pengaruh penggunaan kanal simetris, serta pengujian akurasi data latih dan data baru.

Pengujian terhadap pengaruh fitur statistik amplitudo dilakukan untuk mengetahui akurasi sistem berdasarkan pengaruh fitur statistik dari nilai minimum, nilai maksimum

dan nilai rata-rata serta sinkronisasi kanal tiap 16 titik data. Dari data latih yang digunakan sebanyak 224 akan dihasilkan dua jenis akurasi sistem yaitu dengan menggunakan fitur statistik dan tanpa menggunakan fitur statistik sehingga dapat dilakukan perbandingan akurasi yang lebih baik. Hasil pengujian pengaruh fitur statistik dapat dilihat pada Tabel II

TABEL II HASIL PENGUJIAN PENGARUH FITUR STATISTIK

No	Jumlah Data	Jenis Praproses	Tingkat Pengujian (%)	
			Data Latih	Data Baru
1.	224	Tanpa fitur statistik	100	49
2.	224	Dengan fitur statistik	100	56

Berdasarkan Tabel II dapat disimpulkan bahwa penggunaan fitur statistik menghasilkan akurasi yang lebih baik sebesar 7% dibandingkan tanpa penggunaan fitur statistik meskipun penggunaan fitur statistik membutuhkan waktu komputasi yang lebih lama.

Identifikasi pikiran saat membayangkan gerakan juga dapat dipengaruhi oleh kanal yang merupakan sumber pengambilan data sinyal EEG. Tahap identifikasi ini melakukan perbandingan hasil dari dua kanal simetris yaitu AF3-AF4 dan T7-T8. Hasil pengujian pengaruh kanal dapat dilihat pada Tabel III

TABEL III HASIL PENGUJIAN PENGARUH KANAL SIMETRIS

No	Jumlah Data	Kanal	Tingkat Akurasi Pengujian (%)	
			Data Latih	Data Baru
1.	224	AF3-AF4	100	49
2.	224	T7-T8	100	42

Berdasarkan Tabel III dapat dilihat bahwa kanal AF3-AF4 menghasilkan akurasi yang lebih baik sebesar 7% sehingga dapat disimpulkan bahwa kanal AF3-AF4 lebih baik dibandingkan kanal T7-T8 dalam proses identifikasi pikiran saat membayangkan gerakan.

Jumlah data latih memiliki kemungkinan dalam mempengaruhi akurasi sistem sehingga perlu dilakukan identifikasi dengan jumlah data latih yang berbeda. Identifikasi dilakukan dari jumlah data latih yang sedikit kemudian ditambah sampai jumlah data latih terbanyak sehingga dapat terlihat perubahan akurasi pada Tabel IV

TABEL IV HASIL UJI PENGARUH JUMLAH DATA LATIH

No	Jumlah Data	Rata-rata waktu identifikasi	Tingkat Akurasi Pengujian (%)	
			Data Latih	Data Baru
1.	56	0,018	77	29
2.	112	0,024	75	22
3.	168	0,031	76	24
4.	224	0,035	78	28
5.	280	0,042	76	24
6.	336	0,046	78	32

No	Jumlah Data	Rata-rata waktu identifikasi	Tingkat Akurasi Pengujian (%)	
			Data Latih	Data Baru
7.	392	0,050	76	28
8.	448	0,077	79	33
9.	504	0,093	82	35
10.	560	0,121	88	37

Berdasarkan Tabel IV maka dapat disimpulkan sistem identifikasi paling baik dibangun dengan jumlah data latih sebanyak 560 data latih untuk empat SVM dimana tiap SVM menguji 224 data. Selama tahap identifikasi, belum didapatkan akurasi di bawah 75% untuk data latih karena data latih SVM-I dipastikan seluruhnya dikenali. Oleh karena itu, jika data latih lebih dari 560 data diharapkan dapat meningkatkan akurasi sistem. Waktu identifikasi dipengaruhi oleh banyaknya jumlah data sehingga semakin banyak jumlah data latih maka akan semakin lama pula waktu identifikasi. Hal ini disebabkan karena pada saat perhitungan terdapat penjumlahan data sebanyak jumlah koefisien yang mengikuti jumlah data latihnya.

IV. KESIMPULAN

Penelitian ini telah menghasilkan sistem identifikasi pikiran saat membayangkan gerakan memukul Bass Drum berdasarkan sinyal Elektroensefalogram yang menghasilkan lima kelas yaitu tangan kanan memukul sekali (Kanan1), Tangan kiri memukul sekali (Kiri1), tangan Diam, tangan kanan memukul berkali-kali (Kanan2), dan tangan kiri memukul berkali-kali (Kiri2). Sistem dibangun menggunakan ekstraksi Wavelet untuk ekstraksi fitur dan Support Vector Machine dengan tipe Non Linier kernel Polynomial Ordo 2 sebagai metode identifikasi. Berdasarkan hasil pengujian, penggunaan fitur statistik dapat meningkatkan akurasi sebesar 7%. Pengujian terhadap pengaruh kanal simetrik juga dapat mempengaruhi akurasi sistem, penggunaan kanal AF3-AF4 menghasilkan akurasi yang lebih baik sebesar 7% dibandingkan dengan kanal T7-T8. Sistem identifikasi paling baik dibangun menggunakan jumlah data latih sebanyak 560 data dengan akurasi sebesar 37% untuk data baru dan 88% untuk data latih serta waktu identifikasi sebesar 0,121 detik sehingga dapat direalisasikan pada identifikasi *real time*.

Hasil penelitian menunjukkan Brain Computer Interface (BCI) menggunakan Wavelet dan SVM dapat menggerakkan animasi pemukul bass drum. Fitur-fitur gelombang Alfa, gelombang Beta, fitur statistik amplitudo dari nilai minimum, nilai maksimum, dan nilai rata-rata, serta sinkronisasi kanal simetrik dapat menginformasikan *motor imagery* dari sinyal EEG yang digunakan sebagai komponen intermediate.

REFERENSI

[1] L. Qin and B. He, "A wavelet-based time-frequency analysis approach for classification of motor imagery for brain-computer interface applications," *J. Neural Eng.*, vol. 2, no. 4, pp. 65–72, 2005.

[2] G. Pfurtscheller, C. Neuper, A. Schl, and K. Lugger, "Separability of EEG Signals Recorded During Right and Left Motor Imagery Using Adaptive Autoregressive Parameters," *Rehabilitation*, vol. 6, no. 3, pp. 316–325, 1998.

[3] S. Ramesh, M. G. Krishna, and M. Nakirekanti, "Brain Computer Interface System for Mind Controlled Robot using Bluetooth," *Int. Journa Comput. Appl.*, vol. 104, no. 15, pp. 20–23, 2014.

[4] A. I. N. Alshbatat, P. J. Vial, P. Premaratne, and L. C. Tran, "EEG-based Brain-computer Interface for Automating Home Appliances," *J. Comput.*, vol. 9, no. 9, pp. 2159–2166, 2014.

[5] C. Manasa, S. Thejaswini, M. S. Sumathi, S. Raashi, R. P. Tarun, and T. Akash, "Brain Computer Interface Systems To Assist Patients Using EEG Signals," *Int. J. Innov. Res. Comput. Commun. Eng.*, vol. 3, no. 6, pp. 4994–5001, 2015.

[6] A. A. Frolov, D. Húsek, E. V. Biryukova, P. D. Bobrov, O. A. Mokienko, and A. V. Alexandrov, "Principles of motor recovery in post-stroke patients using hand exoskeleton controlled by the brain-computer interface based on motor imagery," *Neural Netw. World*, vol. 27, no. 1, pp. 107–137, 2017.

[7] E. C. Djamal, M. Y. Abdullah, and F. Renaldi, "Brain Computer Interface Game Controlling Using Fast Fourier Transform and Learning Vector Quantization," *J. Telecommun. Electron. Comput. Eng.*, vol. 9, no. 2–5, pp. 71–74, 2017.

[8] Hindarto, M. Hariadi, and M. H. Purnomo, "Identifikasi Sinyal Elektro Encephalo Graph Untuk Menggerakkan Cursor Menggunakan Teknik Sampling Dan Jaringan Syaraf Tiruan," in *The 13th Industrial Electronics Seminar 2011 (IES 2011)*, 2011, pp. 978–979.

[9] J. F. D. Saa, M. S. Gutierrez, U. Del, and N. Barranquilla, "EEG Signal Classification Using Power Spectral Features and linear Discriminant Analysis: A Brain Computer Interface Application," in *Eighth LACCEI Latin American and Caribbean Conference for Engineering and Technology (LACCEI'2010)*, 2010, pp. 1–7.

[10] M. H. Alomari, A. Abubaker, A. Turani, A. M. Baniyounes, and A. Manasreh, "EEG Mouse: A Machine Learning-Based Brain Computer Interface," *Int. J. Adv. Comput. Sci. Appl.*, vol. 5, no. 4, pp. 193–198, 2014.

[11] L. Vokorokos, S. Republic, and N. Adam, "Non-Invasive Brain Imaging Technique for Playing Chess with Brain-Computer Interface," *Int. J. Comput. Inf. Technol.*, vol. 3, no. 5, pp. 877–882, 2014.

[12] E. Mohamed, "Enhancing EEG Signals in Brain Computer Interface Using Wavelet Transform," *Int. J. Inf. Electron. Eng.*, vol. 4, no. 3, pp. 234–238, 2014.

[13] E. C. Djamal, Suriyanto, and S. J. Setiadi, "Classification of EEG-Based Hand Grasping Imagination Using Autoregressive and Neural Networks," *J. Teknol.*, vol. 78, no. 6–6, pp. 105–110, 2016.

[14] B. H. Yang, T. Wu, Q. Wang, and Z. J. Han, "Motor Imagery EEG Recognition Based on WPD-CSP and KF-SVM in Brain Computer Interfaces," *Appl. Mech. Mater.*, vol. 556–562, pp. 2829–2833, 2014.

[15] B.-G. Xu and A.-G. Song, "Pattern Recognition of Motor Imagery EEG using Wavelet Transform," *J. Biomed. Sci. Eng.*, vol. 1, no. 1, pp. 64–67, 2008.