

Modifikasi Fitur dengan *Differential Asymmetry* untuk Meningkatkan Akurasi Klasifikasi *EEG Motor Imagery*

Yulianto Tejo Putranto^{1,2}, Tri Arief Sardjono^{3,4}, Mochamad Hariadi^{3,5}, Mauridhi Hery Purnomo^{3,5}

Abstract— Brain-Computer Interface (BCI) technology has enabled people with motor disabilities to interact with their environment. The electroencephalograph (EEG) signals related to a motor imagery movement were used as a control signal. In this paper, EEG motor imagery signals from the 2-class data have been processed into features and classified. The power and standard deviation of EEG signals, mean of absolute wavelet coefficients, and the average power of the wavelet coefficients were used as features. The purpose of this paper is to apply the differential asymmetry of these features as new features to improve the system accuracy. As a classifier, Support Vector Machine (SVM), *k*-Nearest Neighbor (*k*-NN), and Tree were used. The result shows that for dataset I the use of differential asymmetry as feature can increase the system accuracy up to 47.8%, from 52.20% to 100%, with Tree as a classifier. For dataset II, it can increase accuracy by 8.46%, from 54.42% to 62.48%.

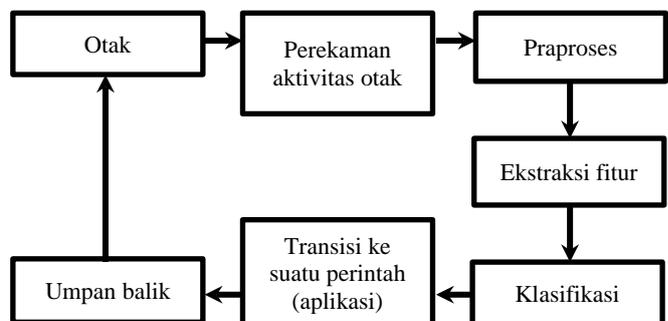
Intisari—Teknologi *Brain-Computer Interface (BCI)* memungkinkan orang dengan keterbatasan kemampuan motorik berinteraksi dengan lingkungannya. Sinyal EEG yang berhubungan dengan keadaan membayangkan menggerakkan digunakan sebagai sinyal pengendali. Dalam makalah ini, sinyal *EEG motor imagery* dari data 2-kelas diolah menjadi fitur-fitur dan diklasifikasikan menurut kelasnya. Sebagai fitur digunakan *power* dan standar deviasi sinyal EEG, juga rata-rata dari nilai mutlak koefisien wavelet, dan rata-rata *power* dari koefisien wavelet. Tujuan dari makalah ini adalah menerapkan *differential asymmetry* dari fitur-fitur tersebut sebagai fitur baru

untuk meningkatkan akurasi sistem. Sebagai pengklasifikasi digunakan SVM, *k*-NN, dan *Tree*. Hasil eksperimen menunjukkan bahwa untuk *dataset I*, penggunaan fitur *differential asymmetry* mampu meningkatkan akurasi hingga 47,80%, dari semula 52,20% menjadi 100%, dengan *Tree* sebagai pengklasifikasi. Sedangkan *dataset II* mampu meningkatkan akurasi sebesar 8,46%, dari semula 54,42% menjadi 62,48%.

Kata Kunci— *Brain-Computer Interface, EEG motor imagery, differential asymmetry, SVM, k-NN, Tree.*

I. PENDAHULUAN

Teknologi antarmuka otak-komputer atau yang dikenal luas sebagai *Brain-Computer Interface (BCI)* mengalami perkembangan yang cepat. BCI adalah suatu sistem yang mampu menerjemahkan aktivitas otak yang direpresentasikan oleh gelombang otak ke dalam perintah atau pesan terhadap aplikasi interaktif. Sistem BCI menyangkut perangkat keras dan perangkat lunak yang digunakan untuk memanipulasi sinyal otak untuk mengendalikan komputer atau peranti komunikasi lain. BCI memungkinkan seseorang dengan keterbatasan fisik dapat berinteraksi dengan lingkungannya. Gelombang atau sinyal yang dihasilkan otak digunakan sebagai sumber informasi. Pada umumnya, gelombang otak yang digunakan adalah *Electroencephalograph (EEG)*. Gbr. 1 menunjukkan suatu sistem BCI kalang tertutup yang terdiri atas enam tahap, yaitu perekaman aktivitas otak, praproses, ekstraksi fitur, klasifikasi, transisi ke suatu perintah (aplikasi), dan umpan balik [1].



Gbr. 1 Diagram blok sistem BCI kalang tertutup.

Secara garis besar langkah awal yang dilakukan setelah diperoleh sinyal EEG hasil pengukuran adalah menapis sinyal dengan tapis *bandpass* untuk mereduksi derau atau artifak dan mendapatkan sinyal EEG dalam *range* frekuensinya. Dalam beberapa penelitian, dirinci dengan *sub-bandpass filter* menjadi frekuensi gelombang-gelombang penyusun EEG [2], [3].

Setelah sinyal EEG hasil penapisan diperoleh, dalam proses selanjutnya beberapa penelitian mencoba menerapkan metode

¹ Mahasiswa, Departemen Teknik Elektro, Fakultas Teknologi Elektro, Institut Teknologi Sepuluh Nopember, Jl. Teknik Mesin, Gedung B, C, dan AJ, Kampus ITS, Sukolilo, Surabaya 60111, Jawa Timur, Indonesia (telp: 031-5994251, fax : 031-5931237, e-mail: yulianto15@mhs.ee.its.ac.id).

² Dosen, Universitas Katolik Soegijapranata Semarang, Jl. Pawiyatan Luhur IV/1, Semarang 50234, Jawa Tengah, Indonesia (telp: 024-8441555, fax: 024-8445265, e-mail: yulianto@unika.ac.id).

³ Dosen, Departemen Teknik Elektro, Fakultas Teknologi Elektro, Institut Teknologi Sepuluh Nopember, Jln. Teknik Mesin, Gedung B,C, dan AJ, Kampus ITS, Sukolilo, Surabaya 60111, Jawa Timur, Indonesia (telp:031-5994251,fax :031-5931237, e-mail: sardjono@elect-eng.its.ac.id, mochar@ee.its.ac.id, hery@ee.its.ac.id).

⁴ Dosen, Departemen Teknik Biomedik, Fakultas Teknologi Elektro, Institut Teknologi Sepuluh Nopember, Jln. Teknik Mesin, Gedung B, C dan AJ, Kampus ITS, Sukolilo, Surabaya 60111, Jawa Timur, Indonesia (telp: 031-5923644, e-mail: sardjono@bme.its.ac.id)

⁵ Dosen, Departemen Teknik Komputer, Fakultas Teknologi Elektro, Institut Teknologi Sepuluh Nopember, Jln. Teknik Mesin, Gedung B,C, dan AJ, Kampus ITS, Sukolilo, Surabaya 60111, Jawa Timur, Indonesia (telp: 031-5922936, e-mail: mochar@ee.its.ac.id, hery@ee.its.ac.id)

autoregressive (AR), *discrete wavelet transform (DWT)*, *singular value decomposition (SVD)*, *common spatial pattern (CSP)* untuk mendapatkan fitur. Fitur-fitur yang relevan atau signifikan dalam hal menjadi pembeda antar kelas sangat berpengaruh terhadap akurasi pengklasifikasi. Metode CSP paling luas digunakan, di samping digunakan sebagai tapis spasial, sekaligus digunakan untuk memilih segmen aktif yang akan diproses klasifikasi [4]. Metode CSP juga digunakan untuk memilih kanal elektrode [5] dan fitur [2]. Dalam [3] digunakan CSP untuk masing-masing *sub-band* frekuensi gelombang EEG untuk mendapatkan fitur. Di samping CSP, metode DWT juga sering digunakan untuk dekomposisi sinyal EEG [6]-[8]. Metode AR banyak digunakan sebagai proses awal untuk mendukung proses ekstraksi fitur berikutnya [9]-[11]. Algoritme evolusioner *particle swarm optimization (PSO)* digunakan untuk menyeleksi fitur yang memberi kontribusi besar dalam proses klasifikasi [8]. Dalam [3], PSO yang telah digabungkan dengan integral *fuzzy* digunakan sebagai pengklasifikasi.

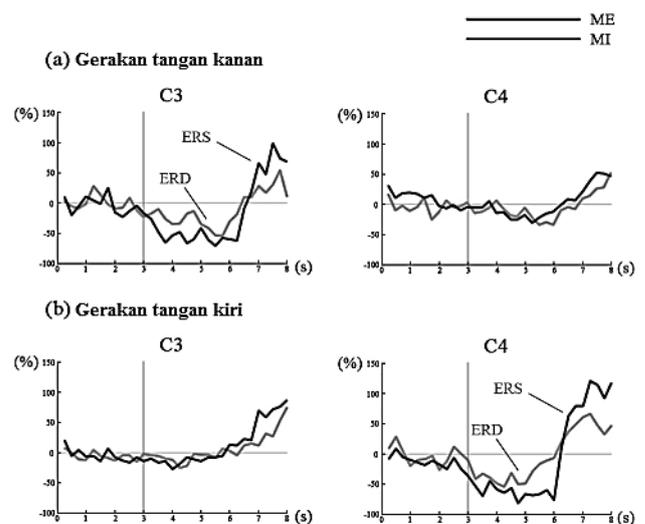
Sebagai pengklasifikasi, beberapa penelitian masih menggunakan pengklasifikasi *support vector machines (SVM)* [12], [13], [7], *linear discriminant analysis (LDA)* [12], [4], [3], dan *k-Nearest Neighbor (k-NN)* [14]. Penggunaan pengklasifikasi ini masih relevan, meskipun penyebab utamanya adalah penelitian-penelitian tersebut tidak memfokuskan pada unit pengklasifikasi. Penggunaan *neural network* sebagai pengklasifikasi juga masih dilakukan, tetapi dengan menggabungkan sistem lain. Dalam [6] digunakan *Neural-Fuzzy* adaptif sebagai pengklasifikasi fitur hasil dekomposisi DWT. *Neural network* juga digunakan sebagai pengklasifikasi dan dimodifikasi fungsi aktivasinya dengan fungsi *wavelet Morlet* [9]. Referensi [5] mengombinasikan *10-fold cross validation* dan algoritme pembelajaran *perceptron* sebagai pengklasifikasi. Dan model *deep convolutional neural network (CNN)* juga telah diterapkan sebagai pengklasifikasi sinyal *single-trial EEG* untuk *motor imagery* [15].

Salah satu aktivitas yang dapat dideteksi dari sinyal EEG adalah *motor imagery*, yaitu keadaan dari seseorang yang sedang membayangkan menggerakkan organ motoriknya seperti menggerakkan tangan kiri, tangan kanan, kaki, atau lidah [16]. Sinyal *motor imaginary EEG* ini paling banyak diaplikasikan dalam sistem BCI untuk mengendalikan peralatan, luar khususnya bagi penderita *neuromuscular disorders* [17].

Gelombang *alpha* berada dalam rentang frekuensi 8-12 Hz. Gelombang *alpha* dihasilkan di bagian korteks *posterior*, termasuk *oksipital*, *parietal*, dan daerah otak *temporal posterior*. Gelombang *alpha* memiliki korelasi fungsional yang diasosiasikan dengan fungsi sensorik, motor, dan memori. Gelombang yang mempunyai jangkauan frekuensi menyerupai *alpha* adalah gelombang *mu*, meskipun ada perbedaan fisiologis antara keduanya. Gelombang *mu* ada keterkaitan kuat dengan aktivitas motorik, yang muncul bersama gelombang *beta* [18].

Osilasi dalam rentang 12-25 Hz sering disebut aktivitas gelombang *beta*. Frekuensi ini dihasilkan di daerah *posterior* dan *frontal*. Aktif, sibuk berpikir atau cemas, serta berkonsentrasi penuh umumnya diketahui berkorelasi dengan

level *beta* yang lebih tinggi. Di sepanjang korteks tengah, level *beta* menjadi lebih kuat saat seseorang merencanakan atau melakukan gerakan, terutama pada saat meraih atau menggenggam. Aktivitas ini membutuhkan gerakan rinci dari jari dan fokus perhatian. Studi yang dikaitkan dengan gelombang *beta* adalah kontrol motorik. Gelombang *beta* mengalami desinkronisasi pada saat melakukan gerakan riil (*motor execution*) maupun pada saat membayangkan menggerakkan (*motor imagery*). Peristiwa ini disebut dengan *event related desynchronization (ERD)*. Sedangkan pada saat selesai gerakan, gelombang *beta* akan kembali seperti semula, atau disebut *event related synchronization (ERS)*. Sifat inilah yang kemudian diamati dan dijadikan masukan dalam sistem BCI yang berbasis EEG [18]. Gbr. 2 menunjukkan fenomena ERD/ERS. Pembahasan lebih lanjut mengenai ERD/ERS terdapat di bagian Hasil dan Pembahasan.



Gbr. 2 Fenomena ERD/ERS saat melakukan gerakan riil (*motor execution/ME*) dan saat membayangkan menggerakkan (*motor imagery/MI*) tangan kanan maupun tangan kiri [19].

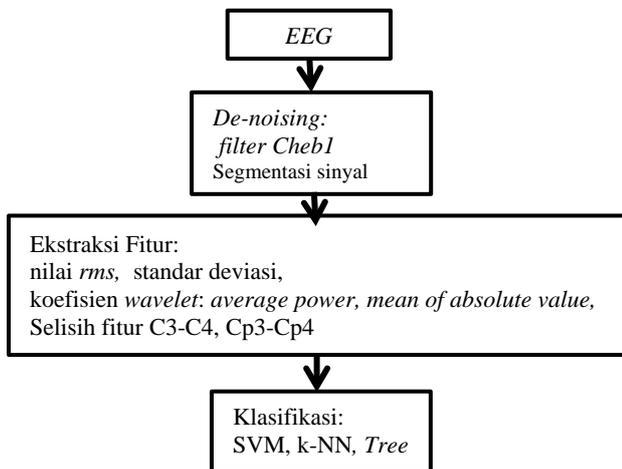
Referensi [20] menunjukkan bahwa peningkatan jumlah kanal tidak menjamin peningkatan akurasi klasifikasi. Oleh karena itu, ada usaha agar jumlah kanal yang digunakan dalam EEG sesedikit mungkin. Dalam sebuah review, dicatat untuk *EEG motor imagery channel* yang banyak digunakan dalam penelitian adalah C3, C4, dan Cz [21]. Dalam [22] digunakan kanal C3, C4, F3, dan F4 untuk mendeteksi pergerakan jari tangan.

Pada makalah ini dirancang sistem BCI berbasis EEG, khususnya untuk mengenali aktivitas *motor imagery*, dengan mengambil fitur nilai selisih antara hasil pengukuran sinyal otak bagian kiri dan kanan. Makalah tidak difokuskan pada pencarian fitur, tetapi memodifikasi fitur yang telah ada untuk mendapatkan fitur yang baru. Berdasarkan fakta bahwa otak bagian kanan akan mengendalikan saraf motorik organ sebelah kiri dan sebaliknya, maka sinyal EEG yang dihasilkan elektrode sebelah kanan dan kiri berbeda dalam suatu aktivitas *motor imagery* tertentu. Hal ini telah ditunjukkan dalam fenomena ERD/ERS. Perbedaan ini semakin tajam jika diambil nilai selisih atau rasio dari keduanya. Pada penelitian-

penelitian tentang *EEG motor imagery* sebelumnya, perbedaan ini tidak dimanfaatkan untuk meningkatkan kinerja sistem. Metode mempertajam perbedaan ini diterapkan sebagai suatu fitur baru dengan tujuan untuk meningkatkan akurasi sistem BCI yang diteliti.

II. PENGKLASIFIKASI EEG MOTOR IMAGERY DENGAN FITUR DIFFERENTIAL ASYMMETRY

Metode yang diusulkan ditunjukkan dalam diagram alir seperti pada Gbr. 3.



Gbr. 3 Diagram alir metode penelitian.

A. Pengambilan Data

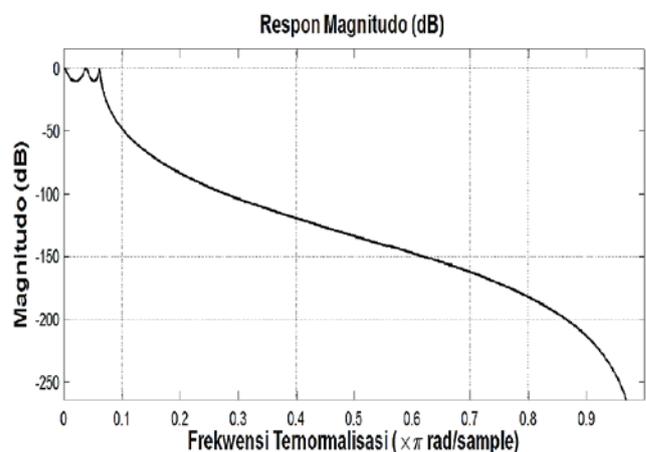
Dalam makalah ini digunakan *open dataset* yaitu *dataset EEG motor imagery* disediakan oleh laboratorium Prof. Cichocki, BSI, RIKEN, berkolaborasi dengan Prof. Liqing Zhang, University of Shanghai Jiao Tong, seperti ditunjukkan dalam Tabel I, yang selanjutnya disebut *Dataset I*. Sinyal EEG dicuplik dengan frekuensi 256 Hz dan ditapis *bandpass* antara 2 dan 30 Hz. Sinyal juga ditapis dengan tapis *notch* 50 Hz untuk menghilangkan derau jala-jala. Jumlah elektrode yang digunakan adalah 5 atau 6. Untuk 6 kanal digunakan C3, Cp3, C4, Cp4, Cz, and Cpz. Dalam makalah ini hanya

digunakan empat kanal, yaitu C3, Cp3, C4, dan Cp4 untuk 2-kelas *motor imagery: left (LH)* dan *right hand (RH)* [23].

Dataset II adalah *dataset 2a* dari *BCI Competition IV*. Data ini merupakan data *EEG motor imagery* multikelas yang disediakan oleh C. Brunner, R. Leeb, G. R. Müller-Putz, G. Pfurtscheller, dan A. Schlögl dari Graz (Austria) [24].

B. Penapisan dan Segmentasi Sinyal EEG

Setelah diperoleh sinyal EEG hasil perekaman, sinyal ditapis menggunakan tapis *lowpass* IIR Chebyshev tipe 1. Tapis ini memiliki karakteristik memiliki *ripple* pada *passband* dan atenuasi turun secara bertahap dari pusat *passband* menuju titik -3 dB. Frekuensi *cut-off* diatur pada 30 Hz sesuai gelombang *beta* yang digunakan dalam *motor imaginary*. Frekuensi cuplik yang digunakan adalah 250 Hz, sehingga frekuensi ternormalisasi sebesar 30/125 atau 0,24. Dengan bantuan MATLAB, kurva karakteristik tapis Chebyshev tipe 1 IIR *lowpass* ditunjukkan dalam Gbr. 4.



Gbr. 4 Kurva karakteristik tapis Chebyshev IIR tipe 1 *lowpass* orde 5.

Setelah penapisan, proses berikutnya adalah segmentasi. Sinyal dipotong sesuai dengan waktu pengambilan *task* untuk masing-masing kelas.

TABEL I
DATASET EEG MOTOR IMAGERY 2 KELAS [23]

Dataset	Subjek	Kelas	Kanal	Durasi	Jumlah trial	Laju Sample	Peranti
SubA_6chan_2LR_s1	A	LH/RH	6	3s	130	256Hz	g.tec
SubA_6chan_2LR_s2					134		
SubF_6chan_2LR	B	LH/RH	6	4s	162	250Hz	Neuroscan
SubC_6chan_2LR_s1	C	LH/RH	6	3s	170	256Hz	g.tec
SubC_6chan_2LR_s2				3s	158		
SubC_6chan_2LR_s3				5s	48		
SubC_6chan_2LR_s4				3s	120		
SubC_6chan_2LR_s5				3s	90		
SubD_5chan_2LR	D	LH/RH	5	4s	80	256Hz	g.tec
SubE_5chan_2LR	E	LH/RH	5	4s	48	256Hz	g.tec
SubF_6chan_2LR	F	LH/RH	6	4s	80	256Hz	g.tec
SubG_6chan_2LR	G	LH/RH	6	4s	120	256Hz	g.tec
SubH_6chan_2LR	H	LH/RH	6	3s	150	256Hz	g.tec

C. Ekstraksi Fitur

Seperti yang telah dijelaskan dalam bagian Pendahuluan, fenomena ERD/ERS yaitu sinyal EEG mengalami penurunan tegangan pada saat melakukan atau membayangkan gerakan. Mengingat hal tersebut, maka fitur-fitur statistik masih akan digunakan. Pada makalah ini digunakan fitur statistik nilai standar deviasi dan nilai *rms* sinyal.

Nilai standar deviasi sinyal (σX) dihitung menggunakan (1).

$$\sigma X = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \mu X)^2} \quad (1)$$

Nilai *root mean square* (*rms*) sinyal dihitung menggunakan (2).

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

dengan x_i adalah nilai amplitud sinyal cuplik ke- i dan μX adalah nilai rata-rata sinyal.

Selanjutnya digunakan metode DWT dengan *mother wavelet* Daubechies untuk proses dekomposisi sinyal EEG menjadi bagian-bagian menurut frekuensinya. Model dekomposisi *wavelet* pernah digunakan untuk mendapatkan fitur dalam klasifikasi sinyal elektrokardiogram (EKG) [25]. Karena frekuensi cuplik *dataset* 250 Hz, maka dilakukan dekomposisi sinyal dengan DWT 5-level. Diperoleh koefisien CA1 (0–125 Hz), CD1 (126–250 Hz); CA2 (0–62 Hz), CD2 (63–250 Hz); CA3 (0–31 Hz); CD3 (32–62 Hz); CA4 (0–15 Hz), CD4 (16–31 Hz); CA5 (0–7 Hz), dan CD5 (8–15 Hz). Sinyal yang digunakan untuk ekstraksi fitur dipilih koefisien CD4 dan CD5 yang merepresentasikan gelombang *alpha* dan *beta* EEG.

Sebagai fitur, dihitung rata-rata *power* dan rata-rata nilai absolut dari koefisien-koefisien tersebut. Penggunaan fitur-fitur *rms*, standar deviasi, rata-rata *power* koefisien *wavelet*, dan rata-rata nilai absolut koefisien *wavelet* pernah digunakan dan berhasil dengan baik [26].

Selanjutnya dari masing-masing fitur statistik dan koefisien *wavelet* dicari nilai selisih dan rasio untuk pasangan simetri kanal. Nilai-nilai ini juga dijadikan fitur. Fitur menggunakan nilai selisih dan rasio dari pasangan kanal simetri ini telah diterapkan dalam penelitian EEG untuk mendeteksi emosi dan dikenal dengan istilah *differential asymmetry* dan *rational asymmetry* [27].

Differential asymmetry adalah nilai selisih antara dua fitur, misalnya rata-rata *power*, hasil pengukuran pasangan kanal (elektrode):

$$dx = x_l - x_r \quad (3)$$

dengan x_l dan x_r adalah nilai fitur pasangan simetri belahan kiri/kanan (l, r) dari bagian kepala. Dalam hal *motor imagery*, dipilih pasangan kanal C4-C3 dan Cp4-Cp3. Sedangkan *rational asymmetry* adalah nilai perbandingan antara dua fitur hasil pengukuran pasangan kanal:

$$rx = \frac{x_l}{x_r} \quad (4)$$

Makalah ini difokuskan pada penggunaan *differential asymmetry* sebagai fitur yang diberi label “Dengan DA”.

Hasilnya dibandingkan dengan penggunaan fitur statistik dan koefisien *wavelet* secara langsung yang diberi label “Tanpa DA”. Sebagai pengklasifikasi, digunakan tiga macam pengklasifikasi, yaitu SVM, k -NN, dan *Tree*.

TABEL II
HASIL AKURASI TANPA MENERAPKAN FITUR *DIFFERENTIAL ASYMETRY* UNTUK DATASET I

Klasifikasi	Rasio #train:#test	Akurasi Pelatihan (%)	Akurasi Pengujian (%)	Akurasi 10-fold CV (%)
SVM	50:50	100	72,62	72,40
	60:40	100	74,66	
	70:30	100	74,94	
k -NN	50:50	100	72,62	70,90
	60:40	100	74,66	
	70:30	100	74,94	
Tree	50:50	58,93	51,28	52,20
	60:40	53,69	50,34	
	70:30	53,40	50,56	

TABEL III
HASIL AKURASI DENGAN MENERAPKAN FITUR *DIFFERENTIAL ASYMETRY* UNTUK DATASET I

Klasifikasi	Rasio #train:#test	Akurasi Pelatihan (%)	Akurasi Pengujian (%)	Akurasi 10-fold CV (%)
SVM	50:50	99,73	90,74	91,70
	60:40	99,66	90,94	
	70:30	99,81	90,60	
k -NN	50:50	95,03	93,29	94,80
	60:40	95,53	94,30	
	70:30	95,49	94,63	
Tree	50:50	100	100	100
	60:40	100	100	
	70:30	100	100	

III. HASIL DAN PEMBAHASAN

Dalam makalah ini hanya digunakan fitur *differential asymmetry*, sedangkan fitur *rational asymmetry* tidak digunakan karena dalam beberapa kasus dapat menyebabkan *division by zero* (DBZ), sehingga proses komputasi terhenti atau *error*. Hasil percobaan terhadap *Dataset* I dengan dan tanpa menerapkan fitur *differential asymmetry* disajikan dalam Tabel II. Sedangkan dengan menerapkan *differential asymmetry* sebagai fitur, hasilnya ditunjukkan pada Tabel III. Percobaan dilakukan dengan memvariasi rasio jumlah data untuk pelatihan dan pengujian. Pemilihan data pelatihan dan pengujian dilakukan secara acak. Di samping itu, metode *10-fold cross validation* juga dicoba terhadap masing-masing pengklasifikasi. Kinerja sistem diwakili oleh nilai persentase akurasi, yaitu jumlah *trial* yang dikenali dengan benar kelasnya dibagi dengan jumlah total *trial*. Dengan bantuan MATLAB, nilai akurasi untuk ketiga macam pengklasifikasi diperlihatkan dalam Tabel II. Pengklasifikasi SVM menggunakan fungsi *kernel* Gaussian, nilai $\gamma = 1$, dan *box constraint* level 1. Untuk pengklasifikasi k -NN diambil nilai $k = 5$ dan menggunakan rumus jarak Euclidean dengan bobot jarak merata. Sedangkan untuk *Tree* digunakan *Simple*

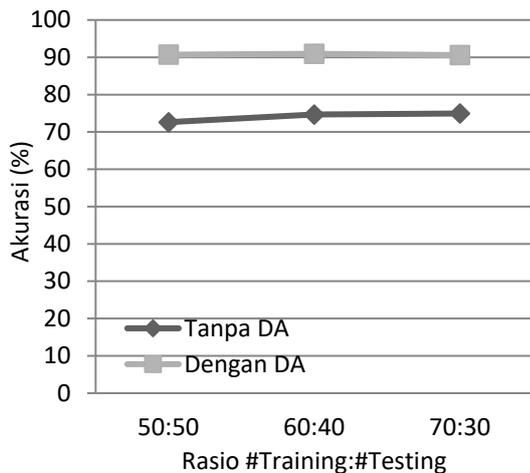
Tree, dengan jumlah maksimal *split* 4 dan indeks diversitas Gini untuk kriteria *split*. Dari Tabel II secara umum dapat dilihat bahwa hasil terbaik dicapai pada komposisi perbandingan data pelatihan dan data pengujian 70%:30% .

Contoh hasil klasifikasi Tree dengan menerapkan *differential asymmetry* dalam bentuk matriks *confusion* disajikan dalam Gbr. 5.

		Kelas yang Diprediksi	
		LH(1)	RH(2)
Kelas Asli	LH(1)	745 50%	0 0%
	RH(2)	0 0%	745 50%
		LH(1)	RH(2)

Gbr. 5 Matriks *confusion* pengklasifikasi Tree dengan menerapkan fitur *differential asymmetry* untuk Dataset I.

Perbandingan secara grafis antara menggunakan *differential asymmetry* dan tanpa *differential asymmetry* ditunjukkan pada Gbr. 6 sampai Gbr. 9. Untuk pengklasifikasi SVM, nilai akurasi tertinggi dicapai pada 91,70% berdasarkan uji *10-fold cross validation* (CV). Hasil ini merupakan peningkatan sebesar 19,30% dari nilai semula 72,40%.

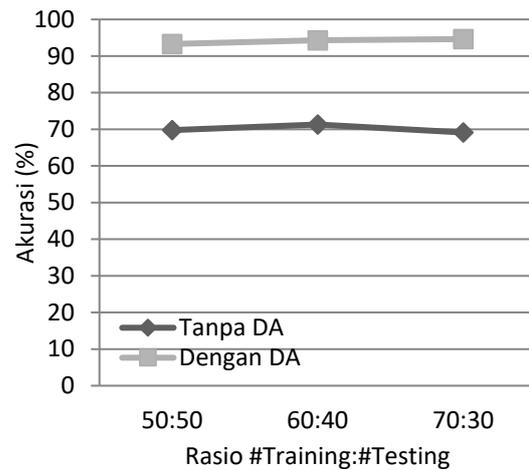


Gbr. 6 Grafik perbandingan akurasi pengujian pengklasifikasi SVM dengan dan tanpa *differential asymmetry* (DA) untuk Dataset I.

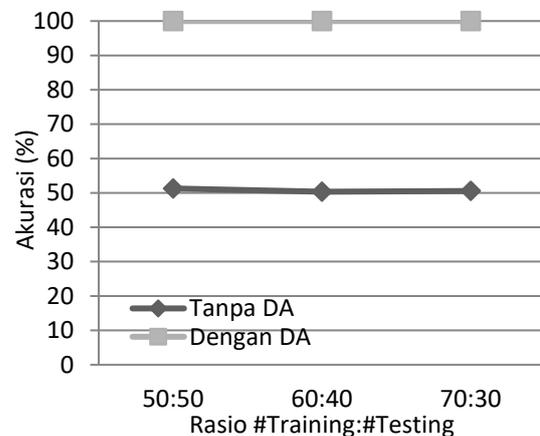
Untuk pengklasifikasi *k*-NN, nilai akurasi tertinggi dicapai pada 94,80% berdasarkan uji *10-fold cross validation* (CV). Hasil ini merupakan peningkatan sebesar 23,90% dari nilai semula 70,90%.

Jika melihat kembali fenomena ERD/ERS yaitu sinyal EEG mengalami penurunan tegangan pada saat melakukan aktivitas motorik, baik *motor imagery* maupun *motor execution*, maka *power* sinyal yang dalam hal ini diwakili oleh nilai rms-nya akan terjadi perubahan. Demikian pula cekungan sinyal yang terjadi pada saat aktivitas motorik tersebut akan menyebabkan

deviasi yang melebar terhadap nilai rata-ratanya. Hal ini menyebabkan terjadi perubahan pula terhadap nilai standar deviasinya.



Gbr. 7 Grafik perbandingan akurasi pengujian pengklasifikasi k-NN dengan dan tanpa *differential asymmetry* (DA) untuk Dataset I.

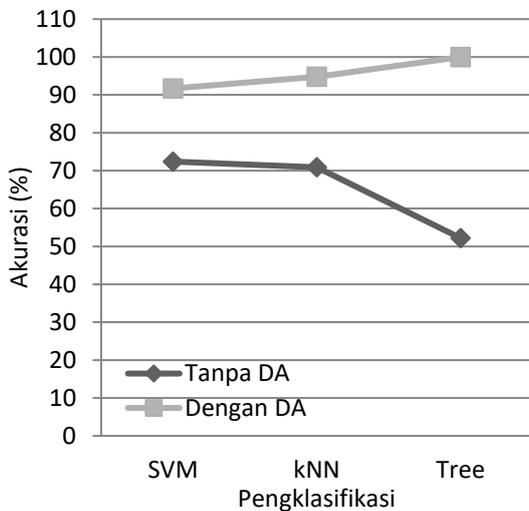


Gbr. 8 Grafik perbandingan akurasi pengujian pengklasifikasi Tree dengan dan tanpa *differential asymmetry* (DA) untuk Dataset I.

Nilai akurasi mencapai nilai maksimal 100% untuk pengklasifikasi Tree untuk semua komposisi. Jika dilihat dari uji *10-fold cross validation* (CV), hasil ini mengalami peningkatan sebesar 47,80% dari nilai semula 52,20%. Nilai ini adalah yang terbesar di antara pengklasifikasi yang digunakan.

Dalam aktivitas *motor imagery* 2 kelas, yaitu gerakan tangan kanan dan tangan kiri, fenomena ERD/ERS hanya terjadi pada satu sisi belahan otak saja. Pada saat membayangkan menggerakkan tangan kanan, ERD/ERS terjadi pada belahan otak sebelah kiri, atau yang terukur pada kanal C3. Pada saat yang sama, sinyal yang terukur di kanal C4 tidak mengalami ERD/ERS, sehingga sinyal hanya berfluktuasi di sekitar keadaan stasionernya. Hal yang sebaliknya terjadi jika sedang membayangkan menggerakkan tangan kiri, seperti ditunjukkan pada Gbr. 2. Perbedaan nilai-nilai yang diambil sebagai fitur pada kanal C3, Cp3 terhadap C4, Cp4 menentukan keberhasilan pengklasifikasi. Apabila diambil nilai selisih fitur pada kanal yang bersesuaian, yaitu

C4-C3 dan Cp4-Cp3, maka perbedaan nilai yang masing-masing mewakili kelas RH dan LH semakin besar. Ilustrasi dari hal ini ditunjukkan dalam Tabel IV. Keadaan stasioner sinyal diwakili oleh nilai "+" dan keadaan ERD/ERS diwakili oleh nilai "-", sedangkan nilai selisih yang membesar diwakili nilai "++" yaitu hasil pengurangan "-" terhadap "+", atau "--" yaitu hasil pengurangan "+" terhadap "-".



Gbr. 9 Grafik perbandingan akurasi 10-fold CV dengan dan tanpa differential asymmetry (DA) untuk Dataset I.

TABEL IV
ILUSTRASI KEADAAN YANG TERJADI PADA C3, C4 DAN C4-C3 DALAM KELAS RH DAN LH

	C3	C4	C4-C3
RH	-	+	++
LH	+	-	--

Untuk dataset 2a BCI Competition IV yang hanya diambil kelas LH dan RH diterapkan uji 10-fold cross validation dan hasilnya ditunjukkan pada Tabel V. Dengan fitur yang sama, hasil akurasi terbaik dicapai oleh pengklasifikasi SVM, yaitu 66,91%. Hasil ini mengalami kenaikan sebesar 4,87% dari semula 62,04% setelah menggunakan differential asymmetry. Kenaikan terbesar terjadi untuk Tree, yaitu sebesar 8,46% dari semula 54,02% menjadi 62,48%. Sedangkan untuk k-NN terjadi kenaikan

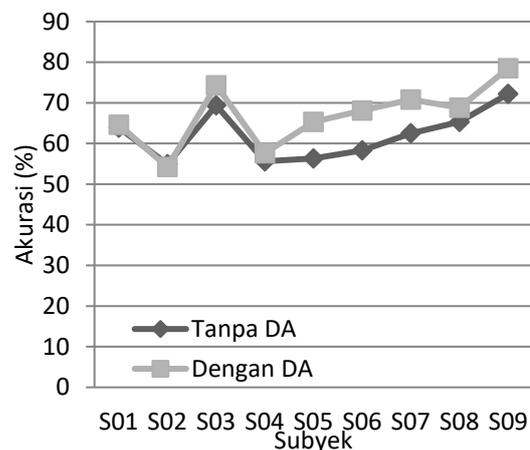
Secara grafis, hasil akurasi untuk masing-masing pengklasifikasi terhadap semua subjek diperlihatkan pada Gbr. 10 sampai Gbr. 12. Dari grafik dapat dilihat bahwa tidak semua subjek memberikan hasil kenaikan akurasi. Hanya untuk pengklasifikasi Tree hampir semua subjek mengalami kenaikan nilai akurasi. Secara keseluruhan, penggunaan fitur differential asymmetry mampu menaikkan akurasi sistem. Untuk pengklasifikasi SVM, k-NN, dan Tree kenaikan nilai akurasinya berturut-turut 4,87%, 7,11%, dan 8.46%, seperti ditunjukkan pada Gbr. 13.

Dibandingkan dengan nilai kenaikan akurasi yang terjadi pada Dataset I, nilai kenaikan pada Dataset II jauh lebih kecil. Rata-rata kenaikan untuk seluruh pengklasifikasi hanya sebesar 6,81%, sedangkan untuk Dataset I sebesar 30,33%. Hal ini dapat disebabkan karakteristik data yang berbeda.

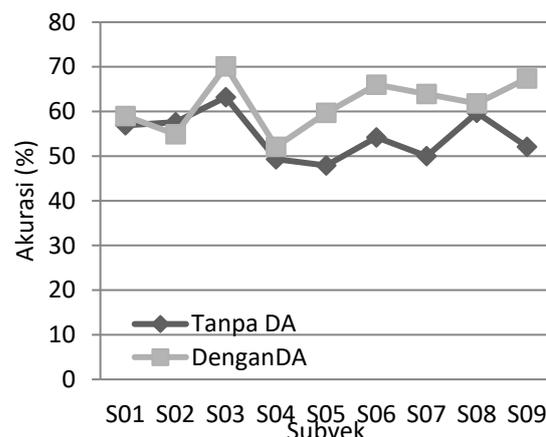
Dataset I didesain untuk 2 kelas motor imagery, sementara Dataset II merupakan dataset 4 kelas motor imagery yang diambil 2 kelas untuk diolah. Oleh sebab itu, perlu digali lebih lanjut fitur-fitur yang dapat meningkatkan nilai akurasi sehingga penggunaan fitur differential asymmetry dapat memberikan hasil yang lebih baik lagi untuk Dataset II.

TABEL V
HASIL AKURASI DENGAN (DDA) DAN TANPA (TDA) MENERAPKAN FITUR DIFFERENTIAL ASYMMETRY UNTUK DATASET II (%)

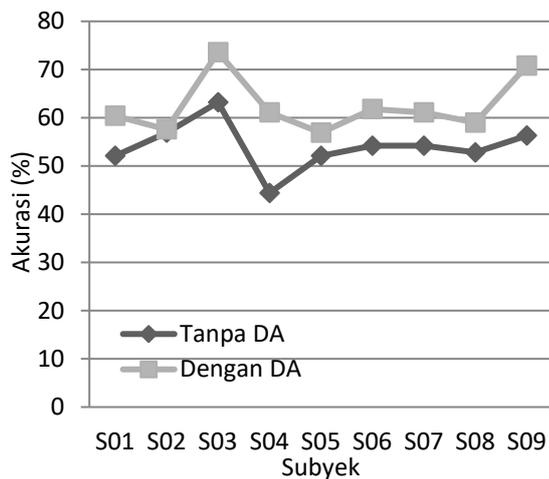
Subyek	SVM		k-NN		Tree	
	TDA	DDA	TDA	DDA	TDA	DDA
S01	63,90	64,60	56,90	59	52,10	60,40
S02	54,90	54,20	57,60	54,90	56,90	57,60
S03	69,40	74,30	63,20	70,10	63,20	73,60
S04	55,60	57,60	49,30	52,10	44,40	61,10
S05	56,30	65,30	47,90	59,70	52,10	56,90
S06	58,30	68,10	54,20	66	54,20	61,80
S07	62,50	70,80	50	63,90	54,20	61,10
S08	65,30	68,80	59,70	61,80	52,80	59
S09	72,20	78,50	52,10	67,40	56,30	70,80
Rata-rata	62,04	66,91	54,54	61,65	54,02	62,47



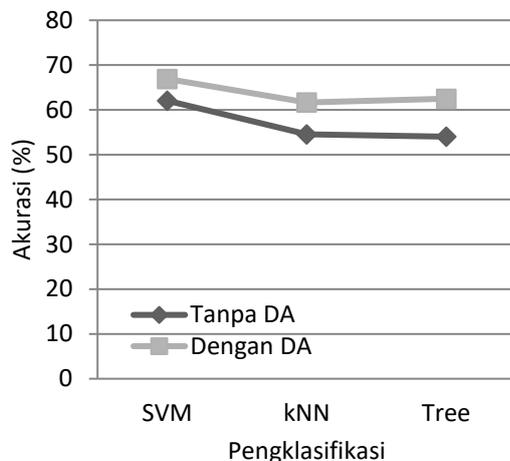
Gbr. 10 Grafik perbandingan akurasi 10-fold CV pengklasifikasi SVM dengan dan tanpa differential asymmetry (DA) untuk Dataset II.



Gbr. 11 Grafik perbandingan akurasi 10-fold CV pengklasifikasi k-NN dengan dan tanpa differential asymmetry (DA) untuk Dataset II.



Gbr. 12 Grafik perbandingan akurasi 10-fold CV pengklasifikasi *Tree* dengan dan tanpa *differential asymmetry* (DA) untuk *Dataset I*.



Gbr. 13 Grafik perbandingan akurasi 10-fold CV dengan dan tanpa *differential asymmetry* (DA) untuk *Dataset II*.

Dari eksperimen terhadap dua *dataset* yang digunakan, diperoleh hasil bahwa penggunaan fitur *differential asymmetry* dapat meningkatkan hasil akurasi sistem dibandingkan jika digunakan fitur asal secara langsung. Catatan lain adalah jumlah total fitur yang digunakan menjadi setengahnya. Hal ini dapat dijelaskan sebagai berikut. Apabila fitur-1 didapatkan dari sinyal pada kanal C3, Cp3, C4, dan Cp4, maka dalam sistem tanpa fitur *differential asymmetry*, fitur-1 dari keempat kanal tersebut digunakan sebagai masukan pada proses selanjutnya. Untuk kasus yang sama, dalam sistem dengan fitur *differential asymmetry*, masukan pada proses selanjutnya hanya dua, yaitu selisih fitur-1 pada kanal C4-C3 dan Cp4-Cp3.

IV. KESIMPULAN

Pada makalah ini telah dilakukan proses klasifikasi sinyal *EEG motor imagery* dengan mengambil fitur *differential asymmetry*, yaitu selisih nilai fitur-fitur semula. Dibandingkan dengan hanya menggunakan fitur semula, hasil yang diperoleh menunjukkan bahwa fitur *differential asymmetry* mampu meningkatkan hasil akurasi rata-rata sebesar 30,33% untuk

Dataset I dan 6,81% untuk *Dataset II*. Disamping itu, dengan hanya mengambil selisih nilai dua fitur asal, maka jumlah fitur total yang digunakan dalam sistem menjadi setengahnya.

UCAPAN TERIMA KASIH

Diucapkan terima kasih kepada Panitia *BCI Competition IV* dan juga Prof. Cichocki's Lab, BSI, RIKEN, dan Prof. Liqing Zhang atas ketersediaan *dataset* penelitian. Penelitian ini juga didukung oleh program BPPDN Kemenristek Dikti Indonesia.

REFERENSI

- [1] L. Bougrain, M. Clerc, dan F. Lotte, Ed., *Brain-Computer Interfaces. 1: Foundations and Methods*, First published. London, UK: ISTE Ltd, 2016.
- [2] M. Bentlemsan, E.-T. Zemouri, D. Bouchaffra, B. Yahya-Zoubir, dan K. Ferroudji, "Random Forest and Filter Bank Common Spatial Patterns for EEG-Based Motor Imagery Classification," *2014 Fifth International Conference on Intelligent Systems, Modelling and Simulation*, 2014, hal. 235–238.
- [3] S.L. Wu, Y.T. Liu, T.Y. Hsieh, Y.Y. Lin, C.Y. Chen, C.H. Chuang, dan C.T. Lin, "Fuzzy Integral With Particle Swarm Optimization for a Motor-Imagery-Based Brain-Computer Interface," *IEEE Trans. Fuzzy Syst.*, Vol. 25, No. 1, hal. 21–28, Feb. 2017.
- [4] N. Tomida, T. Tanaka, S. Ono, M. Yamagishi, dan H. Higashi, "Active Data Selection for Motor Imagery EEG Classification," *IEEE Trans. Biomed. Eng.*, Vol. 62, No. 2, hal. 458–467, Feb. 2015.
- [5] S.-M. Park, X. Yu, P. Chum, W.-Y. Lee, dan K.-B. Sim, "Symmetrical Feature for Interpreting Motor Imagery EEG Signals in the Brain-Computer Interface," *Opt. - Int. J. Light Electron Opt.*, Vol. 129, hal. 163–171, Jan. 2017.
- [6] W.-Y. Hsu, "Motor Imagery Electroencephalogram Analysis Using Adaptive Neural-Fuzzy Classification," *Int. J. Fuzzy Syst.*, Vol. 16, No. 1, hal. 111–120, 2014.
- [7] M. Li, X. Luo, dan J. Yang, "Extracting the Nonlinear Features of Motor Imagery EEG Using Parametric t-SNE," *Neurocomputing*, Vol. 218, hal. 371–381, Des. 2016.
- [8] S.U. Kumar dan H.H. Inbarani, "PSO-Based Feature Selection and Neighborhood Rough Set-Based Classification for BCI Multiclass Motor Imagery Task," *Neural Comput. Appl.*, Vol. 28, No. 11, hal. 3239–3258, Nov. 2017.
- [9] A. Subasi, A. Alkan, E. Koklukaya, dan M. K. Kiymik, "Wavelet Neural Network Classification of EEG Signals by Using AR Model with MLE Preprocessing," *Neural Netw.*, Vol. 18, No. 7, hal. 985–997, Sep. 2005.
- [10] H. Baali, A. Khorshidtalab, M. Mesbah, dan M.J.E. Salami, "A Transform-Based Feature Extraction Approach for Motor Imagery Tasks Classification," *IEEE J. Transl. Eng. Health Med.*, Vol. 3, hal. 1–8, 2015.
- [11] S. Theodoridis dan K. Koutroumbas, *Pattern Recognition*, 4th. ed. Amsterdam, Netherlands: Elsevier Acad. Press, 2009.
- [12] F. Lotte, M. Congedo, A. Lécuyer, F. Lamarche, dan B. Arnaldi, "A Review of Classification Algorithms for EEG-Based Brain-Computer Interfaces," *J. Neural Eng.*, Vol. 4, No. 2, hal. R1–R13, 2007.
- [13] Q. Zhao, T.M. Rutkowski, L. Zhang, dan A. Cichocki, "Generalized Optimal Spatial Filtering Using a Kernel Approach with Application to EEG Classification," *Cogn. Neurodyn.*, Vol. 4, No. 4, hal. 355–358, Des. 2010.
- [14] S.K. Bashar, A.R. Hassan, dan M.I.H. Bhuiyan, "Identification of Motor Imagery Movements from EEG Signals Using Dual Tree Complex Wavelet Transform," *2015 International Conference on Advances in Computing, Communications and Informatics (ICACCI)*, 2015, hal. 290–296.
- [15] Z. Tang, C. Li, dan S. Sun, "Single-Trial EEG Classification of Motor Imagery Using Deep Convolutional Neural Networks," *Opt. - Int. J. Light Electron Opt.*, Vol. 130, hal. 11–18, Feb. 2017.
- [16] M. Tangermann, K.-R. Müller, A. Aertsen, N. Birbaumer, C. Braun, C. Brunner, R. Leeb, C. Mehring, K. Miller, G. Mueller-Putz, G. Nolte, G.

- Pfurtscheller, H. Preissl, G. Schalk, A. Schlögl, C. Vidaurre, S. Waldert, dan B. Blankertz, "Review of the BCI Competition IV," *Front. Neurosci.*, Vol. 6, hal 55-85, 2012.
- [17] S. Sanei dan J.A. Chambers, *EEG signal processing*, Reprinted with corr. Chichester, UK: Wiley, 2009.
- [18] L.F. Nicolas-Alonso dan J. Gomez-Gil, "Brain Computer Interfaces, a Review," *Sensors*, Vol. 12, No. 12, hal. 1211–1279, Jan. 2012.
- [19] Z. Tang, S. Sun, S. Zhang, Y. Chen, C. Li, dan S. Chen, "A Brain-Machine Interface Based on ERD/ERS for an Upper-Limb Exoskeleton Control," *Sensors*, Vol. 16, No. 12, hal. 1-14, Des. 2016.
- [20] G.K. Verma dan U.S. Tiwary, "Multimodal Fusion Framework: A Multiresolution Approach for Emotion Classification and Recognition from Physiological Signals," *NeuroImage*, Vol. 102, hal. 162–172, Nov. 2014.
- [21] M.K.M. Rahman dan M.A.M. Joadder, "A Review on the Components of EEG-based Motor Imagery Classification with Quantitative Comparison," *Appl. Theory Comput. Technol.*, Vol. 2, No. 2, hal. 1, Mar. 2017.
- [22] R. Darmakusuma, A.S. Prihatmanto, A. Indayanto, dan T.L. Mengko, "Deteksi Intensi Pergerakan Jari Menggunakan Metode Power Spectral Density dengan Stimulus Visual," *J. Nas. Tek. Elektro dan Teknol. Inf. JNTETI*, Vol. 4, No. 2, , hal. 125-129. 2015.
- [23] (2014) Brain Science Institute RIKEN Website. "EEG Datasets from BCI Experiment," [Online] <http://www.bsp.brain.riken.jp/~qibin/homepage/Datasets.html>, tanggal akses: 8 Mar. 2016.
- [24] (2008) BCI Competition Website. "Data sets 2a", [Online] <http://www.bbci.de/competition/iv/#dataset2a>, tanggal akses: 22 Agt. 2017 .
- [25] A. Rizal, "Perbandingan Skema Dekomposisi Paket Wavelet untuk Pengenalan Sinyal EKG," *J. Nas. Tek. Elektro Dan Teknol. Inf. JNTETI*, Vol. 4, No. 2, hal 80-86, 2015.
- [26] Y.T. Putranto, M. Hariadi, T.A. Sardjono, dan M.H. Purnomo, "Enhancement of EEG Signals Classification for Imaginary Movement By Detailing Discriminant Parameters," *2016 IEEE Region 10 Conference (TENCON)*, 2016, hal. 47–50.
- [27] R. Jenke, A. Peer, dan M. Buss, "Feature Extraction and Selection for Emotion Recognition from EEG," *IEEE Trans. Affect. Comput.*, Vol. 5, No. 3, hal. 327–339, Jul. 2014.