

maksimum

by Hindarto Hindarto

Submission date: 29-Jun-2018 11:22AM (UTC+0700)

Submission ID: 979304729

File name: jurnal_hindarto_fgdt.docx (134.7K)

Word count: 2806

Character count: 17911

KOEFISIEN SUBBAND WAVELET UNTUK EKSTRAKSI CIRI SINYAL ELECTROENCEPHALOGRAPH (EEG)

Hindarto hindarto¹, Arif muntasa²

¹Informatika, Fakultas Teknik, Universitas Muhammadiyah Sidoarjo

²Informatika, Fakultas Teknik, Universitas Muhammadiyah Sidoarjo

Jl. Mojopahit 666B, Sidoarjo, Jawa Timur

Email: hindarto@umsida.ac.id

Abstrak

Penelitian ini menjelaskan aplikasi dari Backpropagation Neural Network sebagai klasifikasi dan Transformasi Wavelet Diskrit untuk ekstraksi fitur dengan mengambil nilai Maksimum pada setiap subband dari gelombang sinyal Electro Encephalo Graph (EEG). Tujuan dari Penelitian ini untuk mengidentifikasi sinyal EEG yang digunakan pada pergerakan kursor. Data yang digunakan adalah data EEG yang berasal dari BCI kompetisi 2003 (BCI Kompetisi 2003). Data ini berisi data kelas 0 (untuk pergerakan kursor ke atas) dan kelas 1 (untuk pergerakan kursor ke bawah). Pengambilan keputusan dilakukan dalam dua tahap. Pada tahap pertama, nilai energi pada setiap subband wavelet diskrit digunakan untuk mengekstrak fitur dari data sinyal EEG. Fitur ini sebagai input pada Backpropagation Neural Network. Pada tahap kedua proses identifikasi ke dalam dua kelas (kelas 0 dan kelas 1) file data sinyal EEG, terdapat 80 data training file sinyal EEG dan 20 dari data testing file sinyal EEG, sehingga keseluruhan menjadi 553 file data sinyal EEG. Hasil yang diperoleh untuk pengklasifikasian sinyal EEG adalah 77,9 % dari data sinyal yang diuji.

Kata kunci: EEG, BCI, Wavelet diskrit, Maksimum, BackPropagation

1. PENDAHULUAN

Untuk menggerakkan sebuah kursor pada layar komputer, biasanya seseorang memerlukan keyboard atau mouse untuk bisa menjalankannya. Hal ini tidak mungkin dilakukan terhadap seseorang yang tidak mempunyai tangan atau seseorang yang bisa menggerakkan tangannya. Awalnya mungkin hanya angan-angan tetapi ide-ide kreatif dan revolusioner para peneliti baik dari dalam maupun luar negeri untuk bisa menggerakkan kursor tanpa menggunakan tangan.

Pada tahun 1929, seorang psikiater Jerman yang bernama Hans Berger, mengumumkan bahwa dimungkinkan untuk merekam arus listrik yang lemah yang dihasilkan pada otak, tanpa membuka tengkorak, dan untuk melukiskannya ke suatu kertas. Berger menamakan format perekaman yang baru ini sebagai Electroencephalography (EEG). Sehingga untuk menghubungkan antara otak dan obyek yang akan dikendalikan oleh pikiran digunkannya alat yang bernama Brain Computer Interface (BCI) yaitu sistem yang mengakuisisi dan menganalisis sinyal saraf dengan tujuan menciptakan sebuah saluran komunikasi langsung antara otak (sinyal EEG) dan komputer. BCI juga merupakan sistem komunikasi yang tidak memerlukan kegiatan otot [1]. Sistem BCI memungkinkan subyek untuk mengirim perintah ke peralatan elektronik hanya dengan menggunakan aktifitas otak [2]. Sistem BCI juga dapat digunakan untuk memainkan game sederhana pada perangkat mobile [3].

Beberapa penelitian dengan mengambil data sampel data set dari BCI Competition 2003-Data Set Ia (Data sinyal EEG untuk menggerakkan kursor ke atas dan kebawah yang dikendalikan oleh pikiran manusia). Diantaranya Mensh, B.D, Werfel, J, Seung, H.S, pada tahun 2004. Data yang mereka gunakan terdiri dari Empat channel, empat fitur (dua dari rata – rata dari SPC dan dua dari gamma band power), Hasil dari proses klasifikasi sebesar 88,7 % [4]. Penelitian selanjutnya adalah Baojun Wang, Liu Jun, Jing Bai, Le Peng, Yan Li dan Guang Li pada tahun 2005. Peneliti menggunakan dua channel, empat buah fitur dengan mengkombinasikan slow cortical potentials (SCPs) dan wavelet packet transform, Hasil dari proses klasifikasi sebesar 91,47 % [5]. Penelitian lainnya adalah Wu Ting, Yan Guo-zheng, Yang Bang-hua dan Sun Hong pada tahun 2007. Penelitian yang mereka lakukan dengan menggunakan enam channel dan mengambil 17 (tujuh belas) fitur dengan neural network sebagai proses klasifikasi, Hasil dari proses klasifikasi sebesar 90,80 % [6]. Pada tahun 2005, Shiliang Sun dan Changshui Zhang menggunakan data

penelitian competition 2003 dengan menggunakan enam dan fitur yang digunakan sebanyak tujuh buah fitur (RMS, spectral centroid, bandwidth, zero crossing rate, spectral roll-off frekwency, band energy ratio dan delta spectrum magnitude) dengan Bayesian sebagai proses klasifikasi. Hasil dari proses klasifikasi sebesar 90,44 % [7]. Pada tahun 2010 Temel Kayikcioglu dan Onder Aydemir juga menggunakan data kompetisi BCI 2003 dengan menggunakan satu channel (channel 1) sebagai data percobaan dan mengambil 2 fitur dengan menggunakan metode polynomial fitting dengan mengambil fitur nilai h dan koefisien b serta KNN sebagai proses klasifikasi. Hasil dari proses klasifikasi sebesar 92,15 % [8].

Dalam penelitian ini, pendekatan baru berdasarkan Jaringan Syaraf Tiruan disajikan untuk mengklasifikasi gerakan kursor. Metode pemrosesan sinyal dengan menggunakan ekstraksi fitur wavelet Transform sinyal EEG untuk memindahkan kursor ke atas atau ke bawah pada layar komputer saat SCP-nya direkam. Jaringan Syaraf Tiruan digunakan untuk mendeteksi gerakan kursor ketika satu set fitur statistik yang berupa nilai maksimum diambil dari subband Wavelet Transform digunakan sebagai masukan.

2. BAHAN DAN METODE

2.1. Bahan

Dataset sinyal EEG diambil dari data kompetisi BCI 2003 berasal dari Dr. Birbaumer dan timnya di University of Tuebingen, Jerman (Blankertz 2004) [16]. Enam saluran EEG direkam dari seorang subjek yang sehat dan the sampling rate of 256 Hz dan panjang perekaman selama 3.5 detik. Hasil setiap percobaan tiap channel sebesar 896 sample. Subjek diminta membayangkan memindahkan kursor ke atas atau ke bawah pada layar komputer saat SCP-nya direkam. Subjek menerima umpan balik visual dari SCPs (fase umpan balik). Dataset dibagi menjadi pelatihan (268 percobaan) dan uji coba (293 percobaan), sesuai dengan diskripsi BCI 2003 Ia.

2.2. Transformasi Wavelet

Teori Wavelet menyediakan kerangka kerja terpadu untuk sejumlah teknik yang dikembangkan untuk berbagai aplikasi pemrosesan sinyal. Khususnya, itu menarik minat untuk analisis sinyal non-stasioner seperti EEG, karena menyediakan alternatif untuk Transformir Waktu-Pendek Fourier Transform (STFT) klasik atau transformasi Gabor. Perbedaan mendasar adalah, berbeda dengan STFT, yang menggunakan jendela analisis tunggal, Wavelet Transform (WT) menggunakan jendela pendek pada frekuensi tinggi dan jendela panjang pada frekuensi yang lebih rendah. Ini mirip dengan "Constant Q" atau analisis frekuensi bandwidth relatif Konvenan [9][10].

2.3 Transformasi Wavelet Diskrit

Sinyal dikatakan stasioner jika tidak banyak berubah dari waktu ke waktu. Transformasi Fourier dapat diterapkan pada sinyal stasioner. Namun, seperti EEG, banyak sinyal dapat mengandung karakteristik non-stasioner atau sementara. Jadi tidak ideal untuk langsung menerapkan transformasi Fourier ke sinyal semacam itu. Dalam situasi seperti ini, metode frekuensi waktu seperti transformasi wavelet harus digunakan. Dalam analisis wavelet, berbagai fungsi probing yang berbeda dapat digunakan. Konsep ini mengarah pada persamaan mendefinisikan untuk transformasi wavelet kontinu (CWT):

$$W(a, b) = \int_{-\infty}^{\infty} x(t) \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) dt \dots\dots\dots (1)$$

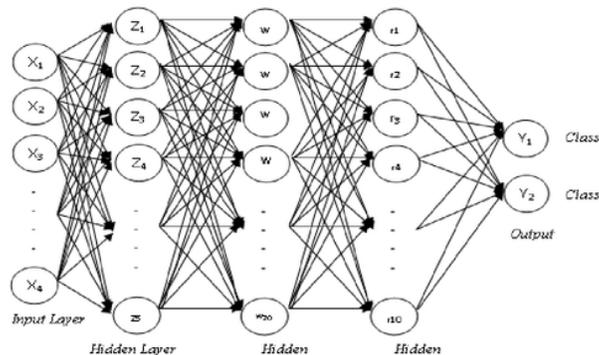
di mana **b** bertindak untuk menerjemahkan fungsi di x (t), dan variabel suatu tindakan untuk memvariasikan skala waktu dari fungsi probing, ψ . Jika a lebih besar dari satu, fungsi wavelet, ψ , ditarik sepanjang sumbu waktu, dan jika kurang dari satu (tapi masih positif) kontak fungsi. Sementara fungsi ψ probing dapat menjadi salah satu dari sejumlah fungsi yang berbeda, ia selalu mengambil bentuk osilator, maka istilah " wavelet". Menunjukkan operasi konjugasi kompleks, dan faktor normalisasi $1/\sqrt{|a|}$ memastikan bahwa energi adalah sama untuk semua nilai a. Dalam aplikasi yang membutuhkan transformasi bilateral, akan lebih disukai transformasi yang menghasilkan jumlah minimum koefisien yang diperlukan untuk memulihkan secara akurat sinyal asli. Transformasi wavelet diskrit (DWT) mencapai parsimoni ini dengan membatasi variasi dalam terjemahan dan skala, biasanya untuk kekuatan 2. Untuk kebanyakan aplikasi pemrosesan sinyal

dan gambar, analisis berbasis DWT paling baik dijelaskan dalam bentuk bank filter. Penggunaan sekelompok filter untuk membagi sinyal menjadi berbagai komponen spektral disebut sub-band coding. Prosedur ini dikenal sebagai dekomposisi multi-resolusi dari sinyal $x[n]$. Setiap tahap skema ini terdiri dari dua filter digital dan dua down-samplers oleh 2. Filter pertama, $h[.]$ adalah mother wavelet diskrit, high-pass di alam, dan yang kedua, $g[.]$ adalah versi cerminannya, rendah di alam. Output down-sample dari filter high-pass dan low-pass pertama memberikan detail, masing-masing $D1$ dan aproksimasi, $A1$ [11][12].

Pemilihan wavelet yang tepat dan jumlah tingkat dekomposisi sangat penting dalam analisis sinyal menggunakan DWT. Jumlah tingkat dekomposisi dipilih berdasarkan pada komponen frekuensi dominan dari sinyal. Tingkat dipilih sedemikian rupa sehingga bagian-bagian dari sinyal yang berkorelasi dengan baik dengan frekuensi yang diperlukan untuk klasifikasi sinyal dipertahankan dalam koefisien wavelet. Karena sinyal EEG tidak memiliki komponen frekuensi yang berguna di atas 30 Hz, jumlah tingkat dipilih menjadi 5. Dengan demikian sinyal didekomposisi menjadi rincian $D1 - D5$ dan satu pendekatan akhir, $A5$. Perkiraan dan catatan detail ini direkonstruksi dari filter wavelet Daubechies 4 (DB4) [13] [14]. Koefisien wavelet yang diekstrak menyediakan representasi kompak yang menunjukkan distribusi energi dari sinyal EEG dalam waktu dan frekuensi. Tabel 1 menyajikan frekuensi yang sesuai dengan tingkat dekomposisi yang berbeda untuk Daubechies memesan 4 wavelet dengan frekuensi sampling 256 Hz. Untuk lebih mengurangi dimensi dari vektor fitur diekstraksi, Ekstraksi ciri sinyal EKG diperoleh dengan cara mendekomposisi sinyal tersebut hingga 5 tingkat menggunakan transformasi *wavelet diskrit*. Fungsi *wavelet* yang digunakan adalah db4. Ilustrasi dekomposisi sinyal EEG 5 tingkat dengan frekuensi cuplik 256 Hz seperti Gambar 2. Tiap sinyal EEG didekomposisi hingga 5 tingkat sehingga diperoleh sinyal detil ($D1, D2, D3, D4, dan D5$) dan sinyal aproksimasi ($A5$). Pada penelitian ini, nilai maksimum dari masing-masing koefisien dari $D3, D4, D5$ dan $A5$ digunakan sebagai ciri dari sinyal EEG.

2.4 Backpropagation Neural Network

Jaringan syaraf tiruan (JST) adalah sistem pemrosesan informasi yang mempunyai karakteristik kinerja tertentu seperti jaringan syaraf biologis. JST telah dikembangkan sebagai generalisasi model matematik dari kognisi manusia atau syaraf biologi. Jaringan syaraf dikarakteristikan dengan pola interkoneksi antara *neuron* (arsitektur), metode penentuan bobot pada koneksi (pembelajaran atau algoritma), dan fungsi aktivasinya. Pembelajaran jaringan syaraf tiruan penjalaran balik meliputi 3 tahap yaitu perambatan maju, perambatan mundur dan perubahan bobot [15]. Ada dua parameter pembelajaran utama dalam penjalaran balik yaitu laju pembelajaran α dan momentum μ . Laju pembelajaran digunakan untuk mengatur cepat lambatnya pembelajaran. Momentum digunakan untuk menghindari perubahan bobot yang mencolok akibat adanya data yang berbeda dengan yang lain. Bagian dari Jaringan Syaraf Tiruan adalah BackPropagation, dimana arsitekturnya dapat dilihat pada Gambar 1. Untuk penelitian jumlah masukan sebanyak 4 *neuron*, dengan satu *hidden layer*, dan dua kelas sebagai *output*.



Gambar 1. Arsitektur Backpropagation Neural Network dengan 3 hidden layer

Pada penelian ini, proses klasifikasi data dilakukan dengan memisahkan sinyal EEG ke dalam dua bagian, yaitu data untuk proses pelatihan sebanyak 268 data vektor dan data untuk proses pengujian data yang digunakan sebanyak 293 data. Jaringan ini mempunyai *input* 4 (x_1, x_2, x_3, x_4) berasal dari fitur DWT, 5 node pada hidden layer 1 (z_1, z_2, \dots, z_5), 20 node pada hidden layer 2 (w_1, w_2, \dots, w_{20}), 10 node pada hidden layer 3 (r_1, r_2, \dots, r_{10}) dan *output* bertipe Biner untuk identifikasi kondisi (y_1, y_2). Arsitektur jaringan pada penelitian dapat dilihat pada Gambar 1. Pola keluaran dengan 2 target keluaran dalam bentuk biner. Jenis pola tersebut dapat dilihat pada Tabel 1.

Tabel 1. Pola Vektor Keluaran

No	Klasifikasi Data	Pola Keluaran
1.	Gerakan Kursor Keatas	0
2.	Gerakan Kursor Kebawah	1

3. RESULTS AND DISCUSSION

Penelitian ini menjelaskan deteksi pergerakan kursor dari sinyal EEG yang didapat dari dataset BCI Kompetisi 2003. Data EEG tersebut diproses menggunakan DWT sebagai ekstraksi ciri dari sinyal EEG. Pada Proses DWT, nilai fitur sinyakl EEG diambil dari nilai maksimum pada frekuensi sub-band DWT.

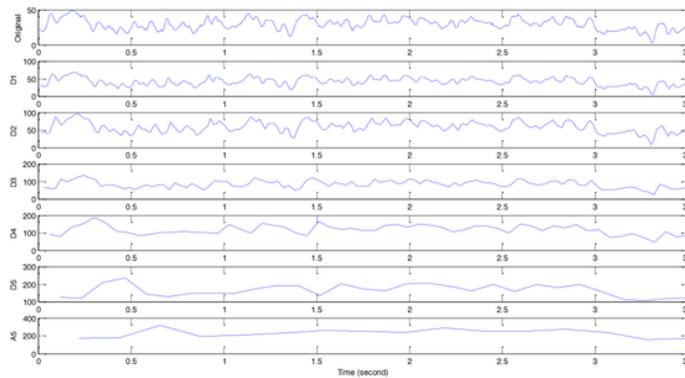
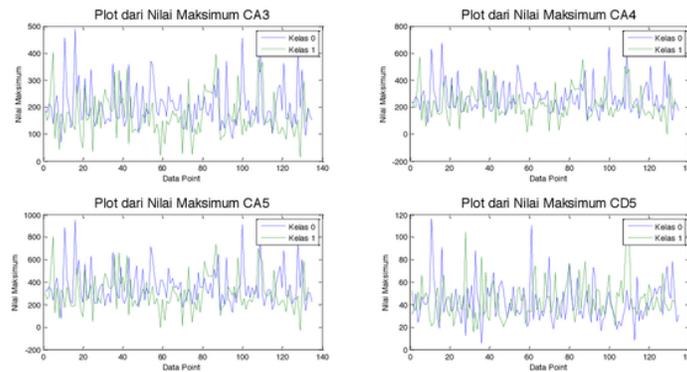


Fig. 2. Approximate and detailed coefficients of EEG signal taken from a healthy subject

Rekaman EEG dibagi menjadi frekuensi sub-band seperti koefisien wavelet A5, D5, D4, dan D3 dengan menggunakan DWT terlihat pada Gambar 2. Kemudian satu set fitur diekstraksi dari frekuensi sub-band wavelet (0-4 Hz), (4-8 Hz), (8-16 Hz) dan (16-32 Hz). Setelah normalisasi, sinyal EEG didekomposisi menggunakan DWT dan fitur diekstraksi dari sub-band. Fitur berikut digunakan untuk mewakili distribusi frekuensi waktu dari sinyal yang diteliti yaitu nilai maksimum dari setiap subband koefisien Wavelet.

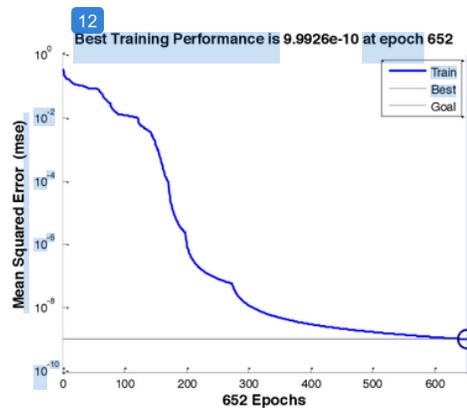


Gambar 3. Nilai maksimum dari kelas 0 dan kelas 1 dari setiap subband

Pada gambar 3 menunjukkan bahwa untuk nilai maksimum pada masing – masing subband untuk kelas 0 dan kelas 1 mempunyai nilai perbedaan. Dengan perbedaan nilai yang tidak sama menunjukkan bahwa tingkat pengklasifikasian dengan mengambil nilai maksimum cukup baik. Klasifikasi menggunakan Jaringan Syaraf Tiruan Backpropagation diimplementasikan dengan menggunakan fitur nilai maksimum dari proses DWT sebagai masukan. Dalam penelitian ini, set pelatihan berjumlah 260 data sampel dan data uji coba 293 data sampel. 260 sampel data (dari subyek normal) untuk channel 1 digunakan untuk pelatihan dan 293 sampel data (dari subjek normal) untuk tiap channel digunakan untuk pengujian. Distribusi kelas sampel dalam kumpulan data pelatihan dan validasi dirangkum dalam Tabel 2. Untuk meningkatkan kemampuan backpropagation, pelatihan dan rangkaian uji coba dibentuk oleh data yang diperoleh dari subyek yang berbeda. Set data pelatihan digunakan untuk melatih backpropagation, sedangkan kumpulan data pengujian digunakan untuk memverifikasi keakuratan dan keefektifan Backpropagation yang telah terlatih untuk mendeteksi gerakan kursor keatas dan kebawah.

Tabel 2. Distribusi kelas dari data pelatihan dan data ujicoba

Kelas	Training set	Test set
Kursor Keatas (class 0)	130 x 6 Channel	293 x 6
Kursor Kebawah (class 1)	130 x 6 Channel	channel (mix)



Gambar. 4. Training Performance dari jaringan syaraf tiruan menggunakan 2 hidden layer

260 data pelatihan dari channel 1 dalam 652 periode pelatihan dan ukuran langkah untuk adaptasi parameter memiliki nilai awal $9,99 \cdot 10^{-10}$. Performance Backpropagation dengan

menggunakan 3 hidden layer mampu untuk melakukan proses pelatihan dengan melewati batas error minimal, sehingga 100% mempunyai keakuratan proses pelatihan.

Tabel 3. Hasil akurasi Backpropagation dengan 3 hidden layer untuk semua channel

	Channel 1	Channel 2	Channel 3	Channel 4	Channel 5	Channel 6
Akurasi	67,0 %	66,0 %	77,9 %	77,4 %	72,3 %	73,4 %

Dari tabel 3 terlihat bahwa channel 3 yang menduduki tingkat akurasi yang baik dibandingkan dengan channel yang lainnya.

Tabel 4. Kinerja jaringan syaraf tiruan terhadap jumlah *Hidden Layer* yang berbeda

	MSE (1 Hidden Layer)	MSE (2 Hidden Layer)	MSE (3 Hidden Layer)
Waktu	13 second	34 second	32 second
Iterasi	1000	833	652
MSE	$1,70 \cdot 10^{-1}$	$9,86 \cdot 10^{-10}$	$9,99 \cdot 10^{-10}$
ketepatan	65,9 %	75,5 %	77,9 %

Dari tabel 4 terlihat bahwa dengan menggunakan 3 hidden layer pada backpropagation sudah dapat mencapai nilai akurasi 77,9 % dari proses pengujian.

4. KESIMPULAN

Pada makalah ini peneliti memperkenalkan Wavelet Diskrit untuk mengekstrak fitur dengan mengambil nilai energi pada setiap subband. Proses pengklasifikasian sinyal EEG dibagi dalam dua kelas yaitu kelas 0 dan kelas 1. Penelitian ini menggunakan 553 data file sinyal EEG untuk training dan testing. ketepatan klasifikasi Backpropagation mencapai 77,9 % untuk data pengujian. Pekerjaan peneliti yang akan datang, akan meneliti teknik pencarian yang sesuai untuk ekstraksi fitur dan klasifikasi sinyal EEG, sehingga tingkat akurasi untuk perintah menggerakkan kursor akan lebih baik. Hasil yang diperoleh akan dibandingkan dengan metode yang sudah diteliti.

UCAPAN TERIMA KASIH

Penulis berterima kasih kepada Pimpinan Universitas Muhammadiyah Sidoarjo yang memberikan waktu untuk penelitian yang peneliti kerjakan dan Direktorat Riset dan Pengabdian Masyarakat, Direktorat Jendral Penguatan Riset, dan Pengembangan Kementerian Riset, Teknologi, dan Pendidikan Tinggi Republik Indonesia yang mensupport dana untuk penelitian ini.

DAFTAR PUSTAKA

- [1] J. R. Wolpaw, N. Birbaumer, D. J. McFarland, G. Pfurtscheller, and T. M. Vaughan, "Brain-computer interfaces for communication and control.," *Clin. Neurophysiol.*, vol. 113, no. 6, pp. 767–91, Jun. 2002.
- [2] T. M. Vaughan, "Guest editorial. Brain-Computer interface technology: a review of the second international meeting.," *IEEE Trans. Neural Syst. Rehabil. Eng.*, vol. 11, no. 2, pp. 111–109, 2003.
- [3] P. A. Pour, T. Gulrez, O. AlZoubi, G. Gargiulo, and R. a. Calvo, "Brain-computer interface: Next generation thought controlled distributed video game development platform.," *2008 IEEE Symp. Comput. Intell. Games*, pp. 251–257, Dec. 2008.
- [4] B. D. Mensh, J. Werfel, and H. S. Seung, "BCI Competition 2003--Data set Ia: combining gamma-band power with slow cortical potentials to improve single-trial classification of electroencephalographic signals.," *IEEE Trans. Biomed. Eng.*, vol. 51, no. 6, pp. 1052–6, Jun. 2004.
- [5] B. Wang, L. Jun, J. Bai, L. Peng, G. Li, and Y. Li, "EEG recognition based on multiple types of information by using wavelet packet transform and neural networks.," *Conf. Proc. IEEE Eng. Med. Biol. Soc.*, vol. 5, pp. 5377–80, 2005.
- [6] W. Ting, Y. Guo-zheng, Y. Bang-hua, and S. Hong, "EEG feature extraction based on

- wavelet packet decomposition for brain computer interface,” *Measurement*, vol. 41, no. 6, pp. 618–625, Jul. 2008.
- [7] “ASSESSING FEATURES FOR ELECTROENCEPHALOGRAPHIC SIGNAL CATEGORIZATION State Key Laboratory of Intelligent Technology and Systems , Department of Automation ,” pp. 417–420, 2005.
- [8] T. Kayikcioglu and O. Aydemir, “A polynomial fitting and k-NN based approach for improving classification of motor imagery BCI data,” *Pattern Recognit. Lett.*, vol. 31, no. 7, pp. 1207–1215, Aug. 2010.
- [9] L. A. Barford, R. S. Fazzio, and D. R. Smith, “An introduction to wavelets,” *Hewlett-Packard Labs, Bristol, UK, Tech. Rep. HPL-92-124*, vol. 2, pp. 1–29, 1992.
- [10] A. S. Chavan and M. Kolte, “EEG Signal Preprocessing using Wavelet Transform,” vol. 3, no. 1, pp. 5–10, 2011.
- [11] M. Murugappan, N. Ramachandran, and Y. Sazali, “Classification of human emotion from EEG using discrete wavelet transform,” vol. 2010, no. April, pp. 390–396, 2010.
- [12] H. Adeli, Z. Zhou, and N. Dadmehr, “Analysis of EEG records in an epileptic patient using wavelet transform,” *J. Neurosci. Methods*, vol. 123, no. 1, pp. 69–87, 2003.
- [13] A. Nakate, “Feature Extraction of EEG Signal using Wavelet Transform,” *Int. J. Comput. Appl.*, vol. 124, no. 2, pp. 21–24, 2015.
- [14] M. H. Alomari, E. A. Awada, A. Samaha, and K. Alkamha, “Wavelet-Based Feature Extraction for the Analysis of EEG Signals Associated with Imagined Fists and Feet Movements,” vol. 7, no. 2, pp. 8–12, 2014.
- [15] W. N. Networks, W. Now, H. Are, and N. Networks, “Fundamental of Neural Network.”
- [16] <http://bbci.de/competition/ii/>

maksimum

ORIGINALITY REPORT

18%

SIMILARITY INDEX

16%

INTERNET SOURCES

6%

PUBLICATIONS

6%

STUDENT PAPERS

PRIMARY SOURCES

1	publikasiilmiah.ums.ac.id Internet Source	5%
2	repo.pens.ac.id Internet Source	2%
3	Shenkai Gu, Yaochu Jin. "Heterogeneous classifier ensembles for EEG-based motor imaginary detection", 2012 12th UK Workshop on Computational Intelligence (UKCI), 2012 Publication	1%
4	irwananeukteknik.blogspot.com Internet Source	1%
5	journal.umsida.ac.id Internet Source	1%
6	www.slideshare.net Internet Source	1%
7	Submitted to University of Sheffield Student Paper	1%
8	androidmax.ru Internet Source	1%

9	repository.unikom.ac.id Internet Source	1%
10	www.cs.tut.ac.jp Internet Source	1%
11	Marshall, D., D. Coyle, S. Wilson, and M. Callaghan. "Games, Gameplay, and BCI: The State of the Art", IEEE Transactions on Computational Intelligence and AI in Games, 2013. Publication	1%
12	Submitted to Indian School of Mines Student Paper	1%
13	lppm.trigunadharma.ac.id Internet Source	1%
14	www2.dbd.puc-rio.br Internet Source	1%
15	airccse.org Internet Source	1%
16	jurnal.uii.ac.id Internet Source	1%
17	dces.essex.ac.uk Internet Source	1%

Exclude quotes On

Exclude matches < 1%

Exclude bibliography On