

KOMPARASI METODE SCICA DAN WICA PADA PRAPROSES DATA EEG OTAK MANUSIA UNTUK DETEKSI PENYAKIT EPILEPSI

Aditya Bagusmulya¹⁾, Handayani Tjandrasa²⁾, dan Chastine Fatichah³⁾

^{1, 2, 3)} Jurusan Teknik Informatika, Fakultas Teknologi Informasi, Institut Teknologi Sepuluh Nopember

Jl. Arief Rahman Hakim, Surabaya 60111 Indonesia

e-mail: aditya.bagusmulya@gmail.com¹⁾, handatj@its.ac.id²⁾, chastine@cs.its.ac.id³⁾

ABSTRAK

Epilepsi merupakan salah satu kelainan pada otak manusia yang tidak dapat disembuhkan. Penyakit ini menimbulkan kejang pada tubuh dan sangat mengganggu aktivitas. Pada tingkat yang parah, epilepsi dapat membahayakan nyawa penderitanya. Oleh sebab itu, epilepsi harus dideteksi secara dini agar penderita segera mendapatkan penanganan yang tepat sehingga keadaannya tidak memburuk. Pada penelitian ini, deteksi epilepsi dilakukan dengan menggunakan beberapa metode, yaitu Independent Component Analysis (ICA), Wavelet Transform (WT), dan Multilayer Perceptron (MLP). Hasil deteksi diklasifikasikan ke dalam tiga kelas, yaitu normal, epilepsi tidak kejang, dan epilepsi kejang. Data rekaman electroencephalogram (EEG) yang digunakan berasal dari "Klinik für Epileptologie, Universität Bonn" yang diperoleh secara online. Data tersebut merupakan EEG single channel sehingga harus menggunakan teknik-teknik ICA untuk single channel, seperti Single Channel Independent Component Analysis (SCICA) dan Wavelet Independent Component Analysis (WICA). Penelitian ini membandingkan kedua teknik tersebut dalam melakukan praproses data sehingga akan terlihat teknik mana yang lebih baik. Hasil pendeteksian terbaik dihasilkan dari model yang menggunakan teknik SCICA sebagai penghilang derau dan ekstraksi fitur Discrete Wavelet Transform Daubechies 6 dengan 4 level. Berdasarkan uji coba, metode tersebut menghasilkan akurasi sebesar 92.09%.

Kata Kunci: Epilepsi, Independent Component Analysis, Wavelet Transform, Multilayer Perceptron, Klasifikasi

ABSTRACT

Epilepsy is one of disorders in human brain that cannot be healed. This disease triggers seizuring which bothers patients' activities. In the worst condition, it endangers patients' life. Therefore, the epilepsy must be detected since the early beginning so that patients get a proper treatment immediately for avoiding worse condition. In this research, epilepsy detection is built by using three methods; The Independent Component Analysis (ICA), Wavelet Transform (WT), and Multilayer Perceptron (MLP). The result of detection is classified into 3 classes. They are normal, epilepsy non-seizure, and epilepsy seizure. While the electroencephalogram (EEG) record data used was taken from "Klinik für Epileptologie, Universität Bonn" website. The data is single channel EEG so it has to be processed by single channel ICA techniques, like Single Channel Independent Component Analysis (SCICA) and Wavelet Independent Component Analysis (WICA). This research compares between two techniques in preprocessing the data so it can be concluded which one is better. The best result of classification is achieved by a model that is built by Single Channel Independent Component Analysis technique as noise removal and Discrete Wavelet Transform using Daubechies 6 with 4 levels as feature extraction. Based on test result, the method obtains an accuracy of 92.09%.

Keywords: Epilepsy, Independent Component Analysis, Wavelet Transform, Multilayer Perceptron, Classification

I. PENDAHULUAN

EPILEPSI merupakan salah satu kelainan yang terjadi pada otak manusia. Ciri utama yang tampak adalah penderita mengalami kejang dan kehilangan kesadaran. Kejang ini terjadi minimal dua kali secara tiba-tiba tanpa sebab baik ringan maupun berat [1]. Penyebab secara pasti dari kelainan ini belum diketahui, namun sebagian besar dari para penderita memiliki riwayat epilepsi dari keluarga mereka sehingga bisa disebut dengan penyakit akibat genetik. Selain itu epilepsi juga bisa disebabkan oleh penyakit lain yang menyerang otak. Epilepsi bisa terjadi pada manusia di segala umur. Namun, gejalanya sangat terlihat pada anak-anak dan lansia di atas 65 tahun.

Epilepsi secara medis tidak dapat disembuhkan. Obat hanya mampu mengontrol frekuensi terjadinya kejang dan juga tingkat keparahan dari kejang tersebut. Namun perlu diwaspadai, pada tingkat yang parah epilepsi bisa mengakibatkan kematian bagi penderitanya. Selain dari sisi fisik, dampak negatif yang ditimbulkan dari epilepsi bagi penderitanya yaitu psikis dan kehidupan sosial. Secara psikis, penderita epilepsi akan merasa tidak nyaman, gelisah bahkan depresi karena kejang yang terus-menerus dialaminya. Sementara itu, kerugian yang diterima penderita dalam kehidupan sosialnya yaitu adanya diskriminasi. Penderita tidak akan diizinkan mengendarai kendaraan karena dapat membahayakan diri sendiri maupun orang lain apabila secara tiba-tiba terjadi kejang saat berkendara. Lebih jauh lagi, di beberapa negara, penderita epilepsi dilarang menikah [2]. Untuk meminimalisir terjadinya hal-

hal yang merugikan penderita maka epilepsi perlu dideteksi sejak dini dan segera diberikan perawatan yang tepat sehingga penderita bisa hidup layaknya manusia normal.

Teknologi selalu berkembang setiap saat. Tidak dapat dipungkiri, saat ini kehidupan manusia serba dimudahkan dengan adanya teknologi begitu juga dengan dunia kedokteran. Pengaplikasian yang sangat berguna yaitu adanya teknologi untuk mendeteksi penyakit atau kelainan pada tubuh manusia. Salah satu kelainan yang dapat dideteksi dengan teknologi yaitu epilepsi. Sebelumnya, diagnosis dilakukan secara manual yaitu dengan mengamati rekaman sinyal *electroencephalogram* (EEG) dari otak. Cara konvensional seperti ini membutuhkan waktu yang cukup lama dan kurang efisien. Sehingga dibuatlah pendeteksi otomatis data EEG yang diolah sedemikian rupa. Beberapa penelitian sudah pernah dilakukan dengan menggunakan metode-metode yang berbeda, baik pra proses maupun klasifikasi, diantaranya menggunakan algoritma *Fuzzy* dan *Support Vector Machine* [3] dan *Permutation Entropy* dan *Support Vector Machine* [4]. Pada penggunaan *Permutation Entropy* dan *Support Vector Machine* menghasilkan rata-rata keakuratan sebesar 84.18% dengan hanya menggunakan 2 kelas saja.

Berdasarkan hasil akurasi di atas, pada penelitian ini akan dibangun sebuah perangkat lunak yang sama namun menggunakan metode yang berbeda. Metode yang akan diimplementasikan yaitu *Independent Component Analysis* (ICA) sebagai pra proses di mana ada dua teknik *single channel* ICA yang akan dibandingkan yaitu *Single Channel Component Analysis* (SCICA) dan *Wavelet Independent Component Analysis* (WICA). Selain itu untuk ekstraksi fitur data digunakan *Wavelet Transform* (WT) serta *Multilayer Preceptron* (MLP) sebagai klasifikasi. Data yang digunakan sebagai masukan yaitu data rekam EEG otak manusia. Diharapkan nilai akurasi pendeteksian bisa lebih baik dari penelitian yang sudah pernah dilakukan. Hal ini tentu akan membuat deteksi menjadi lebih tepat sehingga penderita epilepsi bisa mendapatkan perawatan yang sesuai.

II. DASAR TEORI

A. *Independent Component Analysis* (ICA)

ICA adalah sebuah metode statistik yang dapat menemukan faktor-faktor tersembunyi yang ada dalam sekumpulan variabel acak atau sinyal [5]. ICA mampu memisahkan sinyal-sinyal yang saling bertumpangan menjadi beberapa sinyal yang mempunyai karakteristik statistik yang berbeda [6]. Metode ini termasuk dalam *Blind Source Separation* yaitu menemukan sumber-sumber sinyal yang tidak teramati karena saling bertumpangan. Sinyal yang dapat dipisahkan dengan ICA antara lain suara dan sinyal kedipan mata pada EEG. Contohnya yaitu pada kasus “cocktail party” di mana dua orang berhitung secara bersamaan dengan menggunakan microphone yang berbeda sehingga suara keduanya menjadi satu sinyal. Model dari ICA dapat dilihat pada Persamaan 1.

$$x = A \cdot s \tag{1}$$

Dimana $x = [x_1, x_2, \dots, x_n]^T$ adalah sinyal campuran yang akan dipisahkan komponen-komponennya. Vektor x ini adalah hasil perkalian dari matriks penyampur A dan $s = [s_1, s_2, \dots, s_m]^T$ yang merupakan vektor independen. Namun, kedua komponen tersebut tidak diketahui. Sehingga perlu dibentuk sebuah persamaan untuk memprediksi nilai s . Persamaan tersebut seperti pada Persamaan 2.

$$u = W \cdot x \tag{2}$$


Dimana $u = [u_1, u_2, \dots, u_m]^T$ adalah vektor prediksi dari s dan W adalah matriks pemisah yang merupakan invers dari matriks A . Pada dasarnya ICA adalah metode yang digunakan untuk sinyal *multi channel*, namun dapat dimodifikasi untuk sinyal *single channel* [7].

SCICA adalah salah satu metode hasil pengembangan dari ICA yang ditujukan bagi sinyal yang hanya memiliki *channel* tunggal [8]. Metode ini diawali dengan membagi sinyal menjadi beberapa bagian dan mengubahnya menjadi sebuah matriks.

$$x(k) = [x(k\tau), \dots, x(k\tau + N - 1)]^T \tag{3}$$

$$X = [x(1), \dots, x(K)]^T \tag{4}$$

Simbol $x(t)$ adalah sinyal asli. $x(k)$ sinyal yang telah dibagi. N adalah panjang sinyal masing-masing bagian. Matriks X adalah gabungan semua bagian sinyal $x(k)$ untuk $k=1, 2, \dots, K$. Simbol τ merupakan panjang waktu tiap bagian dan $(K\tau + N - 1)$ panjang sinyal asli.



Gambar. 1. Proses dekomposisi DWT [12]

Pada matriks X dilakukan ICA kemudian dari proses tersebut dihasilkan matriks pencampuran dan pemisahan, A dan W . Selanjutnya, untuk mendapatkan sinyal yang bersih derau dengan cara mengalikan X dengan W . Terakhir kembalikan ke bentuk sinyal asli dengan menggabungkan kembali menjadi satu sinyal tunggal.

WICA mengubah *single channel* menjadi *multi channel* [7] dengan cara mendekomposisi sinyal menjadi beberapa level dengan *Stationary Discrete Wavelet Transformation*. Pemilihan tipe *mother wavelet* yang digunakan tergantung dengan bentuk sinyal. Setelah dilakukan dekomposisi sebanyak level yang diinginkan, selanjutnya dilakukan ICA pada sinyal tersebut. Hasilnya adalah berupa matriks pemisahan. Matriks ini kemudian dikalikan dengan sinyal dekomposisi sehingga menghasilkan sinyal yang bersih derau. Sinyal tersebut dikembalikan ke bentuk asal dengan cara invers wavelet.

B. Discrete Wavelet Transform (DWT)

DWT digunakan untuk mendekomposisi melalui teknik filterisasi [9]. Sinyal dilewatkan pada filter yang memiliki frekuensi dan skala yang berbeda. Terdapat dua jenis filter yaitu *highpass filter* dan *lowpass filter*. Persamaan dari kedua filter tersebut terdapat pada Persamaan 5 dan 6 berikut ini.

$$Y_{high}[k] = \sum_n X[n]h[2k - n] \quad (5)$$

$$Y_{low}[k] = \sum_n X[n]g[2k - n] \quad (6)$$

Dimana Y_{high} adalah hasil dari *highpass filter* atau disebut dengan *Detail (D)* dan Y_{low} adalah hasil dari *lowpass filter* atau *Approximation (A)*. Proses dekomposisi ini diulang berkali-kali pada *approximation* sesuai dengan jumlah level yang dikehendaki dan menghasilkan D dan A baru. Setiap dekomposisi berarti mengurangi lebar pita frekuensi. Contoh hasil dekomposisi terdapat pada Gambar 1.


Pada Gambar 1 tampak sinyal $x[n]$ didekomposisi menjadi $d^1[n]$ atau D1 dan $a^1[n]$ atau A1. Artinya, hasil dekomposisi masih pada level 1. Selanjutnya pada A1 dilakukan dekomposisi lagi sehingga menjadi $d^2[n]$ atau D2 dan $a^2[n]$ atau A2. Jika dilakukan wavelet diskrit dengan 4 level maka hasil akhir koefisien waveletnya yaitu D1, D2, D3, D4, dan A4.

C. Stationary Discrete Wavelet Transform (SWT)


SWT atau biasa disebut dengan *Undecimate Wavelet Transform* adalah modifikasi dari DWT. Hal yang menjadi pembeda adalah pada SWT panjang sinyal transformasi yang dihasilkan setiap levelnya tetap atau tidak adanya *downsampling*. Pemilihan *mother wavelet* yang digunakan disesuaikan secara manual dengan bentuk sinyal masukan. Gambar 2 menunjukkan proses dekomposisi satu dimensi dengan SWT sebanyak 3 level. Pada setiap level (j), sinyal didekomposisi menjadi dua *subband*, yaitu G (detail) dan H (aproksimasi). Masing-masing *subband* berukuran tetap yaitu sebanyak N . Wavelet terdiri dari berbagai macam *family*, diantaranya Haar, Daubechies, Coiflet, dan Symlet.

D. Multilayer Perceptron Neural Network

Kasus klasifikasi yang memiliki lebih dari dua kelas dapat diselesaikan dengan menggunakan *Multilayer Perceptron Neural Network* (MLP). Lapisan yang terdapat dalam struktur MLP lebih dari tiga atau lebih. Strukturnya tampak seperti Gambar 3. Lapisan pertama adalah *input* atau masukan kemudian sebelum lapisan *output* atau keluaran terdapat lapisan *hidden* atau tersembunyi.



Gambar. 2. Dekomposisi dengan SWT [12]



Gambar. 3. Struktur MLP [13]

MLP memiliki bobot dan bias seperti *Single-layer Perceptron*. Namun yang membedakan dengan *Single-layer Perceptron* yaitu adanya lapisan tersembunyi atau *hidden layer* di antara masukan dan keluaran. Jumlah lapisan tersembunyi bisa saja lebih dari satu.


Algoritma *Backpropagation* merupakan algoritma yang bisa diterapkan pada MLP. Algoritma ini terdiri dari dua tahap, yaitu *feedforward* dan *backpropagation*. Pada saat *feedforward*, sinyal masukan dihitung oleh semua neuron di setiap lapisan sehingga menghasilkan keluaran tanpa melakukan perubahan bobot. Sedangkan pada *backpropagation*, semua bobot diperbarui berdasarkan kesalahan jaringan. Kedua tahap ini diulang hingga bobot membuat keluaran yang sama atau mendekati hasil yang sebenarnya.

III. PERANCANGAN PERANGKAT LUNAK


A. Data Masukan

Data masukan adalah data yang digunakan sebagai masukan awal dari sistem. Data yang digunakan dalam perangkat lunak deteksi penyakit epilepsi dengan Menggunakan *Independent Component Analysis*, *Wavelet Transform*, dan *Multilayer Perceptron* adalah data sinyal otak manusia (EEG) yang diunduh dari website milik "Klinik für Epileptologie, Universität Bonn". Data ini terdiri dari 5 set rekaman EEG (A-E) yang mana setiap set berisi 100 data sinyal otak *single-channel* masing-masing data berdurasi 23,6 detik dan dengan frekuensi 173.61 Hz serta 4097 nilai. Kelima data set tersebut diambil dari orang-orang yang berbeda dengan kondisi yang berbeda pula. Keseluruhan data telah diperiksa ada tidaknya derau secara kasat mata.

Perekaman data A dan B diambil dari sukarelawan yang sehat namun dengan kondisi yang berbeda. A direkam dengan mata terbuka sedangkan B dengan mata tertutup. Data C, D, dan E merupakan data sinyal otak dari pasien penderita epilepsi, namun sama halnya dengan A dan B, perekaman dilakukan dalam kondisi yang berbeda. Data D diambil dari bagian kepala yang berada dalam zona kejang sedangkan C pada formasi hippocampal belahan kepala yang lainnya. Keduanya direkam dalam keadaan tidak kejang. Data E merupakan sinyal otak pasien yang sedang dalam keadaan kejang. Berdasarkan penjelasan di atas dapat disimpulkan bahwa ada 200 data sinyal otak manusia sehat, 200 data epilepsi tidak kejang, dan 100 data epilepsi kejang. Contoh sinyal dari masing-masing data set mulai A hingga E secara berurutan ditunjukkan pada Gambar 4.



Gambar. 4. Contoh data masukan masing-masing data set. [14]



Gambar. 5. Diagram alir rancangan perangkat lunak secara umum


B. Data Keluaran

Data masukan akan diproses dengan menggunakan metode *Independent Component Analysis*, *Wavelet Transform*, dan *Multilayer Perceptron*. Pada metode klasifikasi, *Multilayer Perceptron*, data akan dibagi menjadi dua yaitu data pembelajaran dan pengujian. Hasil dari proses klasifikasi tersebut adalah nama kelas dan nilai-nilai performa yang mencakup *accuracy*, *specificity*, dan *sensitivity*.


C. Desain Umum Sistem

Rancangan perangkat lunak deteksi penyakit epilepsi dengan menggunakan *Independent Component Analysis*, *Wavelet Transform*, dan *Multilayer Perceptron* dimulai dengan melakukan praproses yaitu menghilangkan derau dari kelima data sinyal otak manusia dengan menggunakan *Independent Component Analysis*. Ada dua jenis *Independent Component Analysis* yang digunakan yaitu *Single Channel* dan *Wavelet*. Hasil dari praproses tersebut adalah sinyal otak yang sudah bersih dari derau. Sinyal-sinyal tersebut digunakan sebagai masukan untuk tahap selanjutnya.

Tahap selanjutnya adalah ekstraksi fitur dari masing-masing sinyal dengan menggunakan metode *Discrete Wavelet Transform*. Satu rekaman sinyal otak manusia yang telah bersih dari derau dibagi menjadi beberapa bagian kemudian setiap bagian akan didekomposisi menggunakan *Discrete Wavelet Transform* sebanyak 4 level. Hasil



Gambar. 6. Hasil SCICA sampel data set E, S003.txt



Gambar. 7. Hasil WICA sampel data set A, Z006.txt

dekomposisi akan menghasilkan fitur yang diperoleh dari perhitungan nilai rata-rata, minimum, maksimum, dan standar deviasi.

Keluaran dari tahap di atas adalah data set baru yang siap untuk masukan tahap selanjutnya yaitu *Multilayer Perceptron*. Data dibagi menjadi data pembelajaran dan pengujian sehingga dapat diperoleh nilai performa. Dari data pembelajaran akan dihasilkan sebuah model yang digunakan untuk pengujian performa. Pengujian performa dari model menggunakan metode *K-Fold Cross Validation* dengan parameter yang berbeda-beda sesuai dengan skenario. Diagram alir desain umum perangkat lunak ditunjukkan pada Gambar 5. Penghilangan *noise* merupakan *preprocessing* sedangkan ekstraksi fitur dan klasifikasi adalah *processing*.

IV. IMPLEMENTASI

Perangkat lunak ini dibangun dengan menggunakan perangkat keras berprocessor Intel® Pentium® 2020M 2.40GHz dan RAM 6 GB. Sedangkan perangkat lunak yang digunakan antara lain sistem operasi Microsoft Windows 8.1 64 bit dan perangkat pengembang Matlab R2013a.

Data masukan sistem adalah sebuah rekaman sinyal. Pada praproses dengan SCICA, data tersebut dipotong menjadi 16 bagian sehingga membentuk matriks yang selanjutnya digunakan sebagai masukan proses ICA dengan EEGLAB untuk menghilangkan derau. Keluaran akhir dari SCICA adalah matriks berukuran 16x256. Untuk praproses dengan WICA, langkah pertama yaitu mendekomposisi sinyal dengan SWT sebanyak 5 level dengan *mother wavelet* Daubechies 2. Selanjutnya, hasil dekomposisi dimasukkan ke dalam EEGLAB unntuk dihilangkan deraunya. Agar kembali menjadi satu sinyal yang utuh, perlu dilakukan rekonstruksi, namun tahap ini hanya berlaku pada WICA sedangkan SCICA tidak perlu. Contoh hasil dari SCICA dan WICA ditunjukkan pada Gambar 6 dan 7. Kedua gambar tersebut menunjukkan bentuk sinyal sebelum dan sesudah ICA sesuai dengan metodenya, *single channel* dan wavelet. Pada Gambar 6, sebelah kiri (a) menunjukkan sebelum dan kanan (b) menunjukkan sesudah ICA. Sedangkan Gambar 7, sebelah atas (a) menunjukkan sebelum dan bawah (b) menunjukkan sesudah ICA.

Tahap selanjutnya yaitu melakukan ekstraksi fitur dengan DWT. Skenario uji coba dari penelitian ini terletak pada perbedaan *mother wavelet* dan level. Maka dari itu, sebagai contoh adalah Daubechies 2 dengan 4 level. Pada

TABEL I
RINGKASAN HASIL UJI COBA

Skenario Uji Coba	1	2
<i>Accuracy</i>	90.31	92.09
<i>Sensitivity</i>	1	93.8
	2	85.9
	3	91.72
<i>Specificity</i>	1	93.62
	2	95.31
	3	96.18

SCICA setiap baris matriks diambil kemudian didekomposisi dengan DWT seperti di atas. Dekomposisi menghasilkan 5 *subband* dan setiap *subband* dihitung 4 nilai yang digunakan sebagai fitur, yaitu mean, maksimum, minimum, dan standar deviasi. Sehingga untk setiap baris matriks diperoleh 20 fitur. Dan 20 fitur ini dianggap satu buah data. Sedangkan pada WICA, proses ekstraksi fiturnya didahului dengan memotong sinyal hasil ICA menjadi 16 bagian. Langkah selanjutnya sama seperti pada SCICA. Pada akhir ekstraksi fitur ini untuk setiap satu sinyal menghasilkan 16 data baru. Sebelum masuk ketahap selanjutnya data perlu dinormalisasi terlebih dahulu.

Tahap terakhir adalah pembuatan model dengan MLP. Pertama, seluruh data ekstraksi fitur dibagi menjadi dua, yaitu data pembelajaran dan pengujian. Data pembelajaran ini yang digunakan sebagai masukan dari MLP. MLP yang dibangun terdiri dari satu lapisan tersembunyi dengan jumlah node 15. Sesuai aturan *Rule of Thumb* yang pertama [10], yaitu nilai di antara jumlah node masukan dan keluaran. Model yang dihasilkan diujicobakan pada data pengujian. Pengujian menghasilkan sebuah *confusion matrix* 3x3 karena menggunakan 3 kelas. Dari *confusion matrix* tersebut dihitung *accuracy*, *sensitivity*, dan *specificity*. Karena menggunakan 3 kelas maka ada 3 nilai *sensitivity* dan *specificity* Masing-masing nilai tersebut dihitung dengan Persamaan 7,8, dan 9 [11].

$$Accuracy = \frac{tp_A + tp_B + tp_C}{n} \quad (7)$$

$$Sensitivity_{class} = \frac{tp_{class}}{tp_{class} + fn_{class}} \quad (8)$$

$$Specificity_{class} = \frac{tn_{class}}{tn_{class} + fp_{class}} \quad (9)$$

V. UJI COBA

Seperti yang telah dijelaskan di atas, data diambil dari “Klinik für Epileptologie, Universität Bonn”, namun tidak semua data digunakan. Data diambil 20 file setiap data set secara acak sehingga total terdapat 100 file.

Terdapat dua skenario dalam uji coba perangkat lunak ini. Pertama, mengubah level pada DWT dalam tahap ekstraksi fitur. Level diubah menjadi 4, 5, 6, dan 7 level. Sedangkan *mother wavelet* yang digunakan pada keempat level tetap, yaitu Daubechies 2. Setelah melalui tahap ekstraksi fitur tersebut, jumlah fitur yang dihasilkan setiap masukan DWT baris matriks untuk setiap level berbeda, yaitu 20, 24, 28, dan 32. Setelah semua fitur dihasilkan, langkah selanjutnya tahap klasifikasi.

Skenario kedua yaitu mengubah *mother wavelet* menjadi Daubechies 2, 4, 6, dan 8. Sedangkan untuk jumlah level tetap, yaitu 4. Keempat jenis *mother wavelet* ini tetap menghasilkan fitur sebanyak 20 setiap DWT. Selanjutnya yaitu tahap klasifikasi. Uji coba dilakukan dengan *K-Fold Cross Validation* dengan $K=10$ sebanyak 5 kali. Uji coba berlaku untuk kedua praproses, SCICA dan WICA. Ringkasan dari kedua hasil uji coba skenario ditunjukkan pada Tabel I.

Berdasarkan kedua uji coba skenario di atas, diketahui bahwa praproses SCICA memiliki nilai yang lebih baik dibandingkan dengan praproses WICA. Hasil akurasi kedua skenario terdapat pada Tabel 1. Skenario pertama, SCICA dengan ekstraksi fitur DWT Daubechies 2, jumlah level yang terbaik saat mendekomposisi yaitu 7 sehingga fitur yang terekstrasi adalah 28 dengan akurasi sebesar 90.31%. Skenario kedua, SCICA dengan ekstraksi fitur DWT 4 level, jenis *mother wavelet* yang terbaik adalah Daubechies 6 dengan akurasi sebesar 92.09%. Kedua skenario berjalan dengan rata-rata waktu komputasi yang sama yaitu 17 menit. Bila dibandingkan, akurasi terbaik yaitu pada skenario kedua.

VI. KESIMPULAN

Dari hasil uji coba yang telah dilakukan, dapat diambil kesimpulan bahwa metode penghilangan derau *Single Channel Independent Component Analysis* (SCICA) pada ICA menghasilkan akurasi yang lebih baik bila dibandingkan dengan *Wavelet Independent Component Analysis* (WICA) dalam *preprocessing* data. Sehingga, fitur dan model yang dihasilkan melalui tahap ekstraksi fitur dengan WT dan klasifikasi MLP untuk pendeteksian epilepsi juga lebih baik.

Pada tahap ekstraksi fitur dengan *Wavelet Transform*, tingkat akurasi yang terbaik pada klasifikasi adalah dengan menggunakan *mother wavelet* Daubechies 6 dengan 4 level, yaitu 92.09%.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Direktorat Pendidikan Tinggi, Kementerian Riset, Teknologi dan Pendidikan Tinggi.

DAFTAR PUSTAKA

- [1] World Health Organization, Oktober 2012. [Online]. Available: <http://www.who.int/mediacentre/factsheets/fs999/en/>.
- [2] "Epilepsy: social consequences and economic aspects," [Online]. Available: http://www.allcountries.org/health/epilepsy_social_consequences_and_economic_aspects.html. [Diakses 3 Juni 2015].
- [3] R. Harikumar dan T. Vijayakumar, "Performance Analysis of Patient Specific Elmanchaotic Optimization Model for Fuzzy Based Epilepsy Risk Level Classification from EEG Signals," *International Journal on Smart Sensing and Intelligent Systems*, Vol. 2, p. 612, 2009.
- [4] N. Nicolau dan J. Gergiou, "Detection of Epileptic Electroencephalogram Based on Permutation Entropy and Support Vector Machines," 2012.
- [5] Riwinoto dan B. Kusumoputro, "Penggunaan Independent Component Analysis (ICA) untuk Pembuangan Noise dan Artefak pada Sinyal Campuran," *National Conference: Design and Application of Technology*, 2010.
- [6] W. Zhou dan J. Gotman, "Automatic Removal of Eye Movement Artifacts from the EEG Using ICA and the Dipole Model," *Progress in Natural Science*, vol. 19, p. 1165, 2009.
- [7] M. Sheoran, S. Kumar dan A. Kumar, "Wavelet-ICA based Denoising of Electroencephalogram Signal," *International Journal of Information & Computation Technology*, vol. 4, p. 1205, 2014.
- [8] B. Mijovic, M. De Vos, I. Gligorijevic, J. Taelman dan S. Van Huffel, "Source Separation From Single-Channel Recordings by Combining Empirical-Mode Decomposition and Independent Component Analysis," *IEEE Transactions on Biomedical Engineering*, vol. 57, p. 2189, 2010.
- [9] H. Susanto, "Transformasi Wavelet Haar," 10 Maret 2010. [Online]. Available: <http://www.scribd.com/doc/50467423/Transformasi-Wavelet-Haar>.
- [10] G. Panchal, A. Ganatra, Y. P Kosta dan D. Panchal, "Behaviour Analysis of Multilayer Perceptron with Multiple Hidden Neurons an Hidden Layer," *International Journal of Computer Theory and Engineering*, Vol. %1 dari %23, No. 2, p. 333, 2011.
- [11] [Online]. Available: <http://www.compumine.com/web/public/newsletter/20071/precision-recall>. [Diakses 5 Mei 2015].
- [12] A. Quotb, Y. Bornat dan S. Renaud, "Wavelet transform for real-time detection of action potentials in neural signals," 15 Juli 2011. [Online]. Available: <http://journal.frontiersin.org/article/10.3389/fneng.2011.00007/full>. [Diakses 3 Juni 2015].
- [13] C. W. Dawson, R. L. Wilby, C. Harpham, M. R. Brown, E. Cranston dan E. J. Darby, "Modelling Ranunculus Presence in the Rivers Test and Itchen Using Artificial Neural Networks," [Online]. Available: <http://www.geocomputation.org/2000/GC016/Gc016.htm>. [Diakses 20 Januari 2015].
- [14] P. Jahankhani, V. Kodogiannis dan K. Revett, "EEG Signal Classification Using Wavelet Feature Extraction and Neural Networks," *International Symposium on Modern Computing*, p. 52, 2006.