

KLASIFIKASI SINYAL ELECTROENCEPHALOGRAM DENGAN POWER SPECTRA DENSITY BERBASIS METODE WELCH DAN MULTI LAYER PERCEPTRON BACKPROPAGATION

Nursuci Putri Husain¹⁾ dan Nurseno Bayu Aji²⁾

¹⁾Prodi Teknik Informatika, Fakultas Teknik, Universitas Islam Makassar

²⁾Prodi Sistem Informasi, Fakultas Teknik dan Informatika, Universitas Gajayana Malang
e-mail: nursuciputrihusain.dty@uim-makassar.ac.id¹⁾, bayu.nurseno@gmail.com²⁾

ABSTRACT

Electroencephalogram (EEG) signal is a signal that could become an information for study about disorders of brain function such as Epilepsi. EEG that detected in epileptic seizures produce patterns that allow doctors to distinguish it from normal conditions. However, a visual analysis can not be done continuously. This study proposed a new hybrid method of EEG signal classification using Power Spectral Density (PSD) based on Welch method, Principle Component Analysis (PCA), and Multi Layer Perceptron Backpropagation. There are 3 main stages in this study, firstly preprocessing the dataset of EEG signals by Power Spectral Density (PSD) based on Welch method, then Principle Component Analysis (PCA) as a method of dimensionality reduction of the EEG signal data and the Multi Layer Perceptron Backpropagation for classifying a signal. Based on experimental results, the proposed method is successfully obtain high accuracy for the 80-20% training-testing partition (99.68%). From the results of the evaluation, it was concluded that the proposed method could be used as a process of classifying EEG signals automatically.

Keywords: Classification, Electroencephalogram, Power Spectra Density, Principle Component Analysis, and Multi Layer Perceptron Backpropagation.

ABSTRAK

Sinyal Electroencephalogram (EEG) merupakan sinyal yang dapat menjadi sumber informasi untuk penelitian gangguan fungsi otak seperti epilepsi. Sinyal EEG yang dideteksi pada serangan epilepsi menghasilkan pola yang memungkinkan dokter untuk membedakannya dari kondisi normal. Namun, analisis secara visual tidak mungkin dilakukan secara terus menerus. Pada penelitian ini diajukan metode klasifikasi sinyal EEG menggunakan Power Spectral Density (PSD) berbasis metode Welch, Principle Component Analysis (PCA), dan Multi Layer Perceptron Backpropagation. Terdapat 3 tahapan utama pada penelitian ini, pertama pengolahan data sinyal EEG menggunakan Power Spectral Density (PSD) berbasis metode Welch, kemudian Principle Component Analysis (PCA) sebagai metode pengurangan dimensi pada data sinyal EEG dan Multi Layer Perceptron Backpropagation untuk mengklasifikasikan sinyal. Berdasarkan hasil uji coba, metode yang diusulkan tersebut berhasil mendapatkan akurasi yang tinggi untuk 80-20% training testing yaitu 99,68%. Dari hasil evaluasi tersebut, disimpulkan bahwa metode yang diusulkan dapat digunakan sebagai proses klasifikasi sinyal EEG secara otomatis.

Kata Kunci: Klasifikasi, Electroencephalogram, Power Spectra Density, Principle Component Analysis, dan Multi Layer Perceptron Backpropagation.

I. PENDAHULUAN

EPILEPSI merupakan suatu gangguan yang berhubungan dengan sistem saraf pusat otak, ditandai dengan terjadinya kejang yang disebabkan aktivitas berlebihan dari sekelompok sel neuron pada otak. Pasien yang mengidap penyakit epilepsi akan mengalami gangguan kesadaran, bengong sesaat, dan atau kejang-kejang. Untuk mengetahui aktivitas otak manusia maka dibutuhkan pengukuran sinyal otak seperti *electroencephalogram* (EEG), *Magneto-Encephalography* (MEG), atau *functional*

Magnetic Resonance Imaging (fMRI) [1]. Sinyal EEG dapat menjadi sumber informasi untuk penelitian gangguan fungsi otak seperti epilepsi. Pengukuran aktivitas otak dengan EEG merupakan teknik yang paling mudah dan paling murah dibandingkan dengan pengukuran fMRI dan MEG [2].

Proses perekaman sinyal EEG dilakukan dalam waktu singkat, adapun rekaman sinyal otak diperoleh dengan menempatkan elektroda pada berbagai posisi pada kulit kepala [3]. Sinyal EEG yang dideteksi pada serangan epilepsi menghasilkan pola yang memungkinkan dokter untuk membedakannya dari kondisi normal. Namun, analisis secara visual tidak mungkin dilakukan secara terus menerus [4], karena kurang jelasnya perbedaan sinyal EEG yang menunjukkan serangan epilepsi dan nonepilepsi [1].


Saat ini telah banyak metode klasifikasi yang mampu membedakan seorang pasien mengalami serangan epilepsi dan nonepilepsi. Adeli dkk., menggunakan *wavelet transform* untuk menganalisis karakteristik sinyal EEG pasien Epilepsi dengan rentang *spike* 3-Hz pada pasien yang mengalami kejang. Dengan menggunakan *wavelet* pada analisis sinyal EEG, fitur - fitur sementara terekam secara akurat. Güler dkk., menggunakan *recurrent neural networks* (RNNs) dan reduksi fitur *Lyapunov* yang dioptimasi dengan algoritme Levenberg–Marquardt. Nigam dkk. 2004, untuk deteksi otomatis serangan epilepsi pada sinyal EEG menggunakan *preprocessing filter multistage nonlinear* yang digabungkan dengan *artificial neural network* (ANN). Kemudian Übeyli, menggunakan kombinasi metode *neural network* dengan koefisien *wavelet* untuk klasifikasi sinyal EEG. Sinyal EEG set A adalah sinyal EEG yang direkam dari pasien sehat dengan mata terbuka [5]. Sinyal set D direkam pada zona *epileptogenic*, dan berada pada interval tanpa kejang. Kemudian Sinyal EEG set E adalah sinyal EEG yang direkam dari pasien epilepsi saat terjadi serangan kejang [11] Tingkat akurasi yang dihasilkan adalah 94,83 %.

Banyak peneliti mencari metode yang tepat untuk meningkatkan akurasi dari klasifikasi sinyal EEG. Naderi, dkk. 2010, mengusulkan metode *Recurrent Neural Networks* (RNNs) dan *Power Spectral Density* menggunakan metode *Welch*. Penelitian ini terdiri atas tiga tahapan yaitu menggunakan metode *Welch* untuk fitur ekstraksi, mereduksinya menggunakan nilai statistik dan klasifikasi menggunakan *Recurrent Neural Networks*. Subasi, dkk., juga mengusulkan metode *hybrid* untuk menentukan penyakit *Epileptic Seizure* dengan menggunakan *Discreet Wavelet Transform* (DWT) untuk fitur ekstraksi yang kemudian direduksi menggunakan PCA, *Independent Component Analysis* (ICA) dan *Linear Discriminant Analysis* (LDA). Lan Ma, dkk., 2015 menggunakan *Convolutional Neural Network* (CNN)[6]. Kemudian, Faust, dkk. 2015 menggunakan *Wavelet* untuk mengklasifikasikan 3 kelas EEG epilepsi. [7]

Paper ini mengusulkan metode *hybrid* untuk pengolahan data awal menggunakan *Power Spectral Density* (PSD) berbasis metode *Welch*, kemudian PCA sebagai metode pengurangan dimensi dan *Multi Layer Perceptron Backpropagation* untuk mengklasifikasikan sinyal EEG set A dan set E. Penambahan metode kombinasi ekstraksi fitur tersebut diharapkan mampu meningkatkan hasil akurasi pada klasifikasi data sinyal EEG set A dan set E.


II. DATASET

Data sinyal EEG digital dapat diperoleh dari database yang tersedia di Universitas Bonn. Data ini tersedia secara online dan dibuat oleh Dr. Ralph Andrzejak dari Pusat Epilepsi di Universitas Bonn, Jerman [11]. Data sinyal EEG dari Universitas Bonn terdiri atas lima kelas *dataset* yaitu A, B, C, D, dan E. Tiap *dataset* berisi 100 segmen EEG saluran tunggal dengan durasi selama 23,6 detik. Set A dan B adalah sinyal yang diambil dari rekaman EEG yang dilakukan pada lima pasien sehat dengan skema penempatan elektroda standar. Pasien dalam kondisi santai dan terjaga dengan mata terbuka untuk data set A dan mata tertutup untuk data set B. Set C dan D berisi aktivitas yang hanya diukur selama interval tanpa kejang, sedangkan set E hanya berisi aktivitas kejang. Semua sinyal EEG direkam dengan sistem *amplifier* dengan kanal 128. Digitalisasi data dengan frekuensi 173,61 sampel per detik menggunakan *A/D converter* 12 bit. *Band pass filter* diatur pada 0,53 40 Hz (12 dB / oct) [11]. Masing-masing data sinyal EEG digital tersebut terdiri atas 4097 data diskrit.



Gambar 1. Sinyal EEG Set A (a) dan Set E (b)

Plot sinyal EEG set A dan set E dalam bentuk gelombang ditunjukkan Gambar 1. Sumbu vertikal menunjukkan nilai tegangan sinyal listrik dalam μV , sedangkan sumbu horizontal adalah urutan data sampel. Dari Gambar 1 dapat dilihat bahwa sinyal EEG set E mempunyai amplitudo tegangan lebih besar daripada EEG set A. Sinyal set A mempunyai rentang *spike* antara $-200 \mu\text{V}$ sampai dengan $200 \mu\text{V}$. Sedangkan sinyal EEG set E mempunyai rentang yang lebih lebar.



Gambar 2. Diagram Sistem

III. METODE PENELITIAN

A. Epilepsi

Epilepsi merupakan gangguan pada sistem syaraf otak manusia yang mengakibatkan terjadinya aktivitas yang berlebihan dari sel neuron pada otak. Epilepsi menyebabkan berbagai reaksi pada tubuh manusia seperti kesemutan, bengong sesaat, kejang-kejang gangguan kesadaran, dan kontraksi otot pada tubuh manusia.

Epilepsi memiliki beberapa karakteristik tertentu [12] :

- 1) Terjadi gangguan yang bervariasi yang diakibatkan adanya proses disfungsi sistem saraf pusat.
- 2) Dalam sehari serangan dapat terjadi hanya 1 kali serangan sampai beberapa kali serangan tergantung beratnya serangan yang dialami.
- 3) Epilepsi dapat berakibat buruk pada kehidupan sosial penderita karena adanya stigma yang terbangun pada saat terjadinya serangan.
- 4) Disebabkan oleh efek samping pemakaian obat jangka panjang yang mungkin diremehkan.

B. Electroencephalography

Electroencephalogram (EEG) adalah metode yang digunakan dalam mengukur aktivitas listrik spontan dari otak yang diperoleh dengan menangkap sinyal listrik yang ditembakkan dari neuron ke

neuron dalam otak. Proses perekaman sinyal EEG dilakukan dalam waktu singkat, biasanya selama 20-40 menit. Rekaman diperoleh dengan menempatkan elektroda di berbagai posisi pada kulit kepala. Tingginya resolusi temporal yang EEG miliki akan membuat respon terhadap segala perubahan aktivitas otak lebih cepat [1].

Terdapat dua pendekatan untuk mendapatkan sinyal EEG sesuai dengan lapisan otak mana yang akan diambil sinyalnya. Pendekatan pertama adalah pendekatan invasif, yaitu dengan menanam elektroda yang sangat kecil secara langsung di atas korteks melalui bedah saraf. Keuntungan dari pendekatan ini adalah mampu memberikan sinyal EEG dengan kualitas sangat tinggi. Pendekatan lain adalah pendekatan non invasif, yaitu dengan menempatkan elektroda pada permukaan kulit kepala. Hasil rekaman EEG non invasif memiliki kualitas sinyal yang kurang bagus karena tengkorak memperkecil sinyal, mendispersi, dan mengaburkan gelombang elektromagnetik yang dihasilkan oleh neuron. Selain itu juga memiliki resolusi spasial rendah sehingga sulit untuk menentukan wilayah otak yang menghasilkannya atau respon masing-masing neuron [1].

Sinyal EEG terbukti cukup membantu proses pemantauan dan pendiagnosian sejumlah kasus klinis, yaitu: Epilepsi, Penyakit Alzheimer, Penyakit Huntington, Gangguan tidur. EEG digunakan ahli saraf untuk mempelajari fungsi otak. Penggunaan metode dalam *Computational Intelligence* (CI) dan pemodelan matematika membantu proses analisis EEG. Selain itu juga telah dikembangkan beberapa aplikasi *Brain Computer Interface* (BCI) untuk membantu penderita cacat melakukan kegiatan sehari-hari. BCI dapat memfasilitasi komunikasi individu cacat fisik dengan bantuan komputer dengan menggunakan karakteristik sinyal EEG. Aplikasi EEG lainnya adalah pembangkitan kemampuan atau respon otak yang muncul terhadap suara, sentuhan, dan cahaya, yang berguna untuk mengevaluasi sejumlah kondisi neurologis [1].

Berdasarkan frekuensi, amplitudo, sinyal EEG dapat dibagi menjadi 4 gelombang, yaitu gelombang *delta* (kurang dari 4 Hz), *theta* (4 – 7 Hz), *alpha* (8 – 12 Hz), *beta* (13 – 20 Hz) dan *gamma* (21 – 40 Hz) [12].

C. Power Spectral Density (PSD) berbasis metode Welch

Desain sistem yang diusulkan pada penelitian ini dapat dilihat pada Gambar 2. Proses pertama adalah pengolahan fitur EEG. Pengolahan fitur dalam penelitian ini akan dilakukan dalam dua tahap. Tahap pertama adalah membagi data sinyal EEG menjadi segmen – segmen dengan ukuran 256 untuk masing data yang ada dalam set A dan set E yang masing – masing memiliki 100 buah data. Setiap data EEG untuk masing – masing set memiliki panjang 4097 buah data diskrit, sehingga untuk masing – masing dataset akan terbagi menjadi 16 segmen data. Dengan pembagian segmen tersebut data yang akan dipakai dalam penelitian ini sebanyak 3200 segmen data.

Tahapan kedua adalah melakukan proses pengenalan pola pada masing – masing segmen data menggunakan *Power Spectral Density* (PSD) berbasis metode *Welch*. Data yang telah diolah menggunakan PSD tersebut kemudian akan di reduksi untuk mengurangi fitur yang ada. Bagian yang dapat diambil dari sinyal EEG adalah *spectrum* frekuensi dengan cara mentransformasi sinyal dari kawasan waktu ke kawasan frekuensi sehingga akan diperoleh informasi tentang frekuensi yang terkandung pada sinyal tersebut. Metode untuk mendapatkan *spectrum* frekuensi suatu sinyal berdasarkan perhitungan estimasi *spectrum* daya adalah metode *Welch* [8].

Pada metode ini, sinyal masukan dibagi menjadi segmen - segmen yang pendek dan perhitungan periodogram dilakukan berdasarkan perhitungan nilai imajiner *Fast Fourier Transform*, sehingga mencari estimasi spectrum daya dapat dilakukan dengan lebih efisien. Setiap segmen data dimodifikasi dengan mengalikan pada suatu fungsi jendela (*window*), sebelum dilakukan perhitungan periodogram. Selanjutnya periodogram yang telah dimodifikasi dirata-ratakan untuk menghasilkan estimasi *spectrum* yang lebih baik [8].

Algoritme PSD menggunakan metode *Welch* adalah sebagai berikut [9]:

a. Sinyal inputan $x[N]$ yang dibagi menjadi sebanyak L *overlapping* segmen menjadi(1):

$$x_l(n) = x(n + (l - 1)M) \quad (1)$$

b. Dimana, $n = 0, \dots, N - 1$ dan $l = 1, \dots, L$ dengan rekomendasi untuk metode *welch* $M = N/2$. Lalu masing-masing segmen akan dicari *window*-nya (2). Setelah didapat *windowed* segmen akan diolah dengan FFT (3).

$$A_l(k) = \sum_{n=0}^{N-1} x_l(n)w(n)e^{-j\frac{2\pi}{N}nk} \tag{2}$$

$$\Phi_l(k) = \frac{1}{NP} |A_l(k)|^2 \tag{3}$$

Dimana A_l adalah FFT *windowed* segmen, Φ_l adalah periodogram, dan P menunjukkan *power window* ($w(n)$), dengan (4)

$$P = \frac{1}{N} \sum_{n=0}^{N-1} |w(n)|^2 \tag{4}$$

dan akan diestimasi dengan metode *welch* dari PSD dengan melihat rata rata dari periodogram, dengan (5)

$$S(k) = \frac{1}{L} \sum_{l=1}^L \Phi_l(k) \tag{5}$$

D. Principle Component Analysis (PCA)

PCA merupakan metode yang digunakan untuk mereduksi jumlah data yang besar. Prinsip dasar dari algoritme PCA adalah mengurangi dimensi suatu set data namun tetap mempertahankan sebanyak mungkin informasi penting dalam set data tersebut.

Dalam menentukan banyaknya fitur yang digunakan dalam tahapan berikutnya, secara umum terdapat 4 cara :

- 1) Kriteria *eigen value*, ditentukan dengan memilih komponen utama yang memiliki nilai *eigen* lebih besar atau sama dengan satu. Komponen utama dengan nilai *eigen* kurang dari satu dikeluarkan dari analisis.
- 2) Kriteria apriori, dalam hal ini peneliti sudah menetapkan terlebih dahulu berapa banyak komponen utama yang akan diekstrak.
- 3) Kriteria persentase varians, dalam hal ini banyaknya komponen utama yang akan diekstrak ditentukan oleh persentase kumulatif varians (bahasan sebelumnya)
- 4) Kriteria *Scree test*, dalam hal ini dilakukan dengan membuat plot *eigen value* terhadap komponen utama berdasarkan urutan perolehannya. Kurva yang diperoleh menjadi dasar penetapan banyaknya komponen utama yang akan diekstrak. Banyak komponen utama ditentukan apabila kurva menjadi datar dengan melihat pada sumbu komponen utama.

Pada penelitian ini digunakan cara yang ke-4 dimana berdasarkan kurva *eigen value* yang didapatkan akan dilakukan pembatasan fitur yang akan digunakan pada tahapan berikutnya Secara matematis PCA mentransformasikan sejumlah fitur yang berkorelasi ke dalam bentuk yang bebas tidak berkorelasi [10].

Bila satu set data disajikan dalam matrik X, maka algoritme PCA meliputi tahap-tahap berikut:

a. Mencari komponen rata-rata dari matrik X yang dirumuskan dengan persamaan berikut:

$$\bar{x}_l = \frac{1}{n} \sum_{k=1}^n x_{1,k} \tag{6}$$

b. Mencari matrik *covariance* dengan menggunakan persamaan berikut:

$$C = X * X^T \tag{7}$$

c. Mencari *eigenvalue* dan *eigenvector* dari matrik *covariance* dengan menggunakan persamaan berikut:

$$Q = \lambda Q \tag{8}$$

dimana λ adalah *eigenvalue* dan Q adalah *eigenvector*.

d. Mencari *Feature Principal Component* dengan mentransformasi data set ke dalam ruang *eigen* dengan menggunakan persamaan:

$$f = \sum_{i=1}^m Q x (I_i - \bar{x}_i), \tag{9}$$

i menyatakan data ke- i , m adalah jumlah data dan Q menyatakan matriks *eigenvector*).

E. Multilayer Perceptron Backpropagation

Algoritme pelatihan *Backpropagation Neural Network* pertama kali dirumuskan oleh Werbos dan dipopulerkan oleh Rumelhart & Mc.Clelland. *Backpropagation neural network* merupakan tipe *Artificial Neural Network* yang membentuk model dengan bobot yang terbaik dari *input* dan *output* pada data yang digunakan untuk data latih.

Algoritme ini memiliki proses pelatihan yang didasarkan pada interkoneksi yang sederhana, yaitu apabila *output* memberikan hasil yang salah, maka bobot dikoreksi agar galat dapat diperkecil dan bobot yang baru diharapkan dapat mendekati nilai yang benar atau setidaknya membuat galat menjadi sekecil mungkin. Algoritme *Bacpropagation* terdiri dari dua tahap, yaitu *feed forward propagation* dan *feed backward propagation*. Secara umum langkah dalam pelatihan *Bacpropagation Neural Network* adalah sebagai berikut :

- a. Menentukan jumlah *input* (pola masukan), *hidden layer*, dan *output* (target pelatihan).
- b. Memberi nilai awal secara random bagi seluruh *weight* antara bagi seluruh penghubung antar layer.
- c. Input data *training* dan kalkulasikan kedalam *input layer*, *hidden layer* dan *output layer* (*feed forward propagation*)
- d. Hitung galat dengan membandingkan hasil dari model yang sudah ada dengan target yang sebenarnya.
- e. Berdasarkan galat yang dihasilkan apabila masih terlalu besar dilakukan proses *feed backward propagation*. Dengan persamaan

$$W_{baru} = W_{lama} + \Delta W \tag{10}$$

dimana

$$\Delta W = -\eta \sum_p \frac{\partial + E_p}{\partial \omega} \tag{11}$$

- f. Lakukan langkah c-f sampai kriteria yang kita tetapkan terpenuhi.

Proses pelatihan biasanya dilakukan hanya menggunakan *training set* dan dihentikan berdasarkan kondisi tertentu (dalam paper ini proses *training* akan dihentikan ketika nilai *epoch* telah tercapai).

F. Evaluasi Uji Coba

Proses pelatihan biasanya dilakukan hanya menggunakan *training set* dan dihentikan berdasarkan kondisi tertentu (dalam paper ini proses *training* akan dihentikan ketika nilai *epoch* telah tercapai). Dalam mengukur performa hasil prediksi dari model klasifikasi yang diusulkan, dihitung akurasi, sensitivitas dan spesifisitas klasifikasi. Formula akurasi, sensitivitas, dan spesifisitas dapat dilihat pada persamaan (9), (10), (11). Pada persamaan tersebut, TP (*True Positive*) adalah jumlah data yang teridentifikasi secara benar, TN (*True Negative*) adalah jumlah data yang tertolak secara benar, FP (*False Positive*) adalah jumlah data yang teridentifikasi secara salah, dan FN (*False Negative*) adalah jumlah data yang tertolak secara salah.

$$Akurasi = \frac{TP+TN}{TP+FP+FN+TN} \times 100\% , \tag{12}$$

$$Sensitivitas = \frac{TP}{TP+FN} \times 100\% , \tag{13}$$


$$\text{Spesifisitas} = \frac{TN}{FP+TN} \times 100\% , \quad (11)$$

IV. HASIL DAN PEMBAHASAN


Data sinyal EEG yang digunakan adalah dari Universitas Bonn [11]. Data sinyal EEG diolah dengan menggunakan metode PSD, Dalam pengolahan fitur dalam penelitian ini akan dilakukan dalam dua tahap. Tahap pertama adalah membagi data sinyal EEG menjadi segmen – segmen dengan ukuran 256 untuk masing data yang ada dalam set A dan set E yang masing – masing memiliki 100 buah data diskrit. Setiap data EEG untuk masing – masing set memiliki panjang 4097 buah data diskrit, sehingga untuk masing – masing dataset akan terbagi menjadi 16 segmen data. Berarti pada set A terdapat 1600 segmen, dan pada set E juga terdapat 1600 segmen. Sehingga, terdapat 3200 segmen data yang digunakan.

Kemudian setiap segmen data yang panjangnya 256 ini ditransformasikan ke dalam bentuk power *spectrum* menjadi 129 nilai diskrit menggunakan metode PSD berbasis *Welch*. Gambar 3 (a) adalah hasil transformasi PSD untuk satu segmen, sedangkan gambar 3 (b) adalah hasil transformasi untuk 3200 segmen data.

Setelah itu, data sinyal EEG yang telah diolah, direduksi dimensinya dengan menggunakan metode PCA, algoritme PCA telah diimplementasikan di Matlab. Berdasarkan pengamatan pada gambar 3(b) didapatkan jumlah fitur yang akan digunakan dalam tahap selanjutnya sebanyak 64 fitur + 1 fitur kelas. Sehingga jumlah fitur setelah diekstrak menggunakan PCA adalah sebanyak 65 fitur sudah termasuk dengan label kelas, seperti yang dilihat pada Tabel 1.



(a)



(b)

Gambar 3. (a) Contoh hasil transformasi PSD Welch untuk satu segmen, dan (b) Pola hasil transformasi PSD Welch untuk 3200 segmen

Pada penelitian ini, data set sinyal EEG dibagi menjadi 2 bagian yaitu 80% data *training* dan 20% data *testing*. Besaran data *training* dan *testing* didapatkan dengan menggunakan metode *trial and error* dimana skenario yang diujikan adalah untuk masing masing *training* dan *testing* adalah 60%-40%, 70%-30%, 80% - 20% , dan 90% - 10%. Dari empat skenario yang dijalankan untuk penentuan *training* dan *testing* didapatkan hasil dari perbandingan 80%-20% adalah yang terbaik. Dalam pengaplikasiannya data

awal sebanyak 3200 akan diajak urutannya menjadi 10 buah data set dengan anggota yang sama tetapi berbeda urutan. Setiap data set akan dibagi menjadi 2 bagian 80 % *training* dan 20 % *testing*. Data yang akan dijadikan acuan dalam pelatihan parameter yang nantinya dihasilkan dari seluruh tahapan adalah data *training*, sedangkan data *testing* hanya akan digunakan untuk melihat akurasi. Kemudian dilakukan proses klasifikasi dengan menggunakan metode MLP.

TABEL I.
HASIL REDUKSI FITUR MENGGUNAKAN PCA

Instance	Atribut					Label class
	1	2	3	4	...	
1	2,5579 e-04	-1,0180 e-04	-1,7323 e-04	6,5522 e-05	...	1
2	2,4810 e-04	-1,8075 e-04	-2,0926 e-04	2,4159 e-06	...	1
3	2,6979 e-04	-2,1564 e-04	-2,5919 e-04	-1,4724 e-04	...	1
4	3,1044 e-04	-2,0837 e-04	-2,6344 e-04	-1,7653 e-04	...	1
5	2,8731 e-04	-1,7757 e-04	-2,4453 e-04	-4,3130e-05	...	1
6	2,7939 e-04	-1,3787 e-04	-1,9548 e-04	-9,2184e-06	...	1
7	2,7073 e-04	-1,8695 e-04	-2,2707 e-04	-7,7275e-05	...	1
...
...
	0,0062	-0,0056	-0,0051	-0,0057	..	0

Backpropagation dengan 10 *fold cross validation*. Parameter input yang diperlukan untuk memperoleh MLP yang paling optimal dilakukan secara *trial error* dan didapatkan parameter terbaik yang di set dalam proses klasifikasi MLP adalah jumlah *input layer* = 64, *hidden layer* = 1, node pada *hidden layer* = 33, *learning rate* = 0,3, jumlah iterasi = 100. Hasil klasifikasi pada MLP dapat dilihat pada matriks *confusion* pada Tabel II. Dimana hanya ada satu data sinyal Set E yang salah diklasifikasikan menjadi sinyal Set A (FP).

TABEL II
MARIKS CUNFUSION DATA TESTING PARTISI 80-20%

Aktual	Prediksi	
	Set A	Set E
Set A	319	1
Set E	1	319

TABEL III
AKURASI, SENSITIVITAS DAN SPESIFISITAS MENGGUNAKAN METODE YANG DIUSULKAN

Metrics	80-20% <i>training - testing</i>
Accuracy	99,68
Sensitivitas	99,68
Spesifisitas	99,68

Dapat dilihat pada Tabel III, nilai akurasi yang di dapatkan pada metode ini adalah 99, 68 %, dengan sensitivitas sebesar 99,68% dan spesifisitas 99,68%. Dengan hasil yang didapat, penggabungan metode dapat menghasilkan hasil yang baik. Pengurangan variabel menggunakan PCA dari hasil dari PSD dapat mengurangi beban klasifier yaitu ANN sehingga mampu mengklasifikasikan kasus EEG ini dengan baik. Walaupun hasil dari penggabungan metode ini sudah baik tapi masih terdapat error sebesar 0,32 % atau terdapat 1 data salah dari setiap 320 data, error tersebut dapat terjadi pada proses penentuan treshold pada PCA yaitu berapa banyak variabel yang nantinya akan digunakan atau dibuang hal ini terjadi karena penentuan treshold yang masih manual.

V. KESIMPULAN DAN FUTURE WORK

Paper ini mengusulkan metode klasifikasi sinyal EEG menggunakan *Power Spectral Density* (PSD) berbasis metode *Welch*, *Principle Component Analysis* (PCA), dan *Multi Layer Perceptron Backpropagation*. Penelitian ini mempunyai 3 tahapan utama: 1) pengolahan data sinyal EEG menggunakan *Power Spectral Density* (PSD) berbasis metode *Welch*, 2) *Principle Component Analysis* (PCA) sebagai metode pengurangan dimensi pada data sinyal EEG dan 3) *Multi Layer Perceptron Backpropagation* untuk mengklasifikasikan data sinyal EEG set A dan set E. Dari hasil uji coba, metode diusulkan berhasil meraih nilai akurasi yang tinggi yaitu 99,68 %.

Penelitian terhadap automasi penentuan treshold pada metode PCA dapat menjadi *future work* pada penelitian ini.

DAFTAR PUSTAKA

- [1] Karyawan, Moch. Anang . dkk, , (Juli, 2011). Klasifikasi Sinyal Eeg Menggunakan Koefisien Autoregresif, F-Score, Dan Least Squares Support Vector Machine, jurnal TIF vol. 2, no.1.
- [2] Talwar, D. (2004). Primer of EEG with a Mini-Atlas 31, 378.
- [3] Teplan, M. (2002), Fundamentals of EEG measurements, Measmt. Sci. Rev., Vol. 2.
- [4] Übeyli, E. D. (2010). Least squares support vector machines employing modelbased me-thods coefficients for analysis of EEG signals, Expert Systems with Applications 37, (2010), 233–239.
- [5] Übeyli, E. D. (2009). Combined neural network model employing wavelet coefficients for EEG signals classification. Digital Signal Processing, 19(2), 297–308.
- [6] L. Ma, J. W. Minett, T. Blu, and W. S. Wang, (2015) “Resting State EEG-Based Biometrics for Individual Identification Using Convolutional Neural Networks,” pp. 2848–2851.
- [7] O. Faust, U. R. Acharya, H. Adeli, and A. Adeli, (2015) “Wavelet-based EEG processing for computer-aided seizure detection and epilepsy diagnosis,” Seizure, vol. 26, pp. 56–64.
- [8] Dyah Titisari,dkk. (2013). Reduksi Suara Jantung Dari Instrumentasi Akuisisi Perekaman Suara Paru-Paru Pada Anak-Anak Menggunakan Butterworth Band Pass Filter. Seminar Nasional ke 8: Rekayasa Teknologi Industri dan Informasi.
- [9] Kemalasari, Ardik Wijayanto, Pramitra Joko R, Identifikasi Sinyal Suara Paru Berdasarkan Power Spectra Density Metode Welch Untuk Deteksi Kelainan Parenkim Paru , Jurusan Teknik Elektronika, Politeknik Elektronika Negeri Surabaya Kampus PENS-ITS Sukolilo, Surabaya.
- [10] Eko prasetyo, (2014). Data Mining Mengolah Data Menjadi Informasi Menggunakan Matlab, Yogyakarta, ANDI.
- [11] Andrzejak RG, Lehnertz K, Rieke C, Mormann F, David P, Elger CE (2001) Indications of nonlinear deterministic and finite dimensional structures in time series of brain electrical activity: Dependence on recording region and brain state, Phys. Rev. E, 64, 061907.
- [12] V. Marpaung,(2005) “Depresi Pada Penderita Epilepsi Umum Dengan Kejang Tonik Klonik Dan epilepsi Parsial Sederhana,” pp. 1–25.