



TESIS - KI142502

**KLASIFIKASI EEG EPILEPSI MENGGUNAKAN  
*SINGULAR SPECTRUM ANALYSIS, POWER  
SPECTRAL DENSITY DAN CONVOLUTION  
NEURAL NETWORK***

NURSENO BAYU AJI  
NRP. 5115201031

DOSEN PEMBIMBING  
Prof.Ir. Handayani Tjandrasa, Msc, Ph.D

PROGRAM MAGISTER  
BIDANG KEAHLIAN KOMPUTASI CERDAS DAN VISUALISASI  
JURUSAN TEKNIK INFORMATIKA  
FAKULTAS TEKNOLOGI INFORMASI  
INSTITUT TEKNOLOGI SEPULUH NOPEMBER  
SURABAYA  
2017



Tesis disusun untuk memenuhi salah satu syarat memperoleh gelar  
Magister Komputer (M.Kom.)  
di  
Institut Teknologi Sepuluh Nopember Surabaya

oleh:  
Nureno Bayu Aji  
Nrp. 5115201031

Dengan judul :  
Klasifikasi EEG Epilepsi Menggunakan Singular Spectrum Analysis, Power  
Spectral Density dan Convolution Neural Network

Tanggal Ujian : 22-6-2017  
Periode Wisuda : 2016 Genap

Disetujui oleh:

Prof.Ir.Handayani Tjandrasa, M.Sc, Ph.D  
NIP. 194908231976032001



(Pembimbing 1)

Dr. Agus Zainal Arifin, S.Kom, M.Kom.  
NIP. 197208091995121001



(Penguji 1)

Anny Yuniarti, S.Kom., M.Comp.Sc  
NIP. 198106222005012002



(Penguji 2)

Dini Adni Navastara, S.Kom, M.Sc  
NIP. 198510172015042001



(Penguji 3)

Dekan Fakultas Teknologi Informasi,  
  
Dr. Agus Zainal Arifin, S.Kom, M.Kom.  
NIP. 197208091995121001



*[Halaman ini sengaja dikosongkan]*

# **KLASIFIKASI EEG EPILEPSI MENGGUNAKAN *SINGULAR SPECTRUM ANALYSIS*, *POWER SPECTRAL DENSITY* DAN *CONVOLUTION NEURAL NETWORK***

Nama Mahasiswa : Nurseno Bayu Aji  
NRP : 51152010131  
Pembimbing : Prof.Ir. Handayani Tjandrasa, Msc, Ph.D

## **ABSTRAK**

Epilepsi merupakan gangguan pada sistem syaraf otak manusia dan menyebabkan berbagai reaksi terhadap tubuh manusia. Epilepsi dapat dideteksi dengan menggunakan *Electroencephalogram* (EEG). Analisis secara visual tidak mungkin dilakukan secara rutin, sehingga sistem komputer diusulkan sebagai sistem deteksi otomatis pada EEG. Langkah yang biasa dikembangkan dalam sistem deteksi EEG secara otomatis adalah ekstraksi fitur dan klasifikasi. *Power Spectral Density* (PSD) adalah metode ekstraksi fitur yang sering dipakai untuk memunculkan karakteristik EEG dengan mengelompokkan energi pada EEG. Pada proses klasifikasi terdapat metode *Convolution Neural Network* (CNN) yang dapat mereduksi fitur dari EEG dan dapat digunakan untuk mengklasifikasikan multiclass dari EEG. Namun, data EEG memiliki kecenderungan bercampur dengan noise berupa sinyal yang lain saat perekaman, oleh karena itu sebelum data EEG digunakan dalam proses selanjutnya, perlu dilakukan pengolahan terlebih dahulu.

Pada penelitian ini diusulkan penggabungan metode *Singular Spectrum Analysis* (SSA) untuk penghilang *noise*, *Power Spectral Density* (PSD) sebagai ekstraksi fitur dan *Convolution Neural Network* (CNN) sebagai klasifier. Diharapkan kombinasi tersebut dapat memperbaiki akurasi dari klasifikasi EEG kelas A, B, C, D, dan E. Penelitian ini dilakukan melalui beberapa fase, fase pertama adalah menghilangkan noise yang bercampur dengan sinyal EEG dengan menggunakan SSA. Selanjutnya ekstraksi fitur menggunakan PSD untuk diambil energi dari sinyalnya, dan terakhir akan diklasifikasi dengan CNN. Pengujian klasifikasi akan dilakukan ke 500 sinyal dengan target 5 kelas dan 3 kelas. Untuk mengetahui performa terhadap metode yang diusulkan, akan dilakukan pengujian secara terpisah antara gabungan PSD dengan CNN yang akan dibandingkan dengan gabungan SSA, PSD dan CNN.

Berdasarkan hasil uji coba, metode yang diusulkan yaitu SSA, PSD dan CNN dapat meningkatkan rata-rata hasil akurasi klasifikasi sinyal EEG untuk epilepsi sebesar 1,2% dari 93,2% menjadi 94,4%, untuk kasus 3 kelas dan meningkatkan 13,4% dari 78,6% menjadi 92%, untuk kasus 5 kelas dibandingkan metode PSD dengan CNN.

**Kata kunci** : *Convolution Neural Network* (CNN), *Electroencephalogram* (EEG), Epilepsi, *Power Spectral Density* (PSD), *Singular Spectrum Analysis* (SSA).

*[Halaman ini sengaja dikosongkan]*

# **EPILEPTIC EEG CLASSIFICATION USING SINGULAR SPECTRUM ANALYSIS, POWER SPECTRAL DENSITY AND CONVOLUTION NEURAL NETWORK**

Name : Nurseno Bayu Aji  
Student Identity Number : 51152010131  
Supervisor : Prof.Ir. Handayani Tjandrasa, Msc, Ph.D

## **ABSTRACT**

Epilepsy is a disorder of the human brain system and causes a variety reactions to the human body. Epilepsy can be detected using Electroencephalogram (EEG). Visual analysis can not be done routinely, so computer system is proposed as an automatic detection system in the EEG. Commonly, steps that developed in automatic EEG detection system are featuring extraction and classification field. Power Spectral Density (PSD) is one of feature extraction methods are often used to bring up the EEG characteristics by featueng energy in the EEG. In the classification process, Convolution Neural Network (CNN) reduces the features of EEG and it can be used to classify multiclassses from EEG. However, the EEG data have a problem with other noise during recording, therefore before the EEG data used in the classification process, preprocessing needs to be done first.

In this study, we proposed the combination of Singular Spectrum Analysis (SSA) for reducing noise, Power Spectral Density (PSD) as a feature extraction and Convolution Neural Network (CNN) as a classifier. It is expected that the combination can improve the accuracy of EEG classification of class A, B, C, D, and E. The study was conducted in several phases, the first phase is to eliminate noise mixed with the EEG signals by using SSA. Furthermore, feature extraction using PSD to take the energy of the signal, and the extracted features will be classified with CNN. The testswere for the classification of 500 signal with a target of 5 classes and 3 classes. The performance of the proposed method will be performed by comparing the previous method of combined PSD, CNN with the proposed method of combined SSA, PSD and CNN.

Based on the results of the experiment, proposed method of combined SSA, PSD and CNN can increases the average accuracy results of EEG signal for epileptic diseases classification by 1.2% from 93.2% to 94.4%, for 3 classes case and increases 13.4% from 78.6% to 92%, for 5 classes case compared to previous method of combined PSD, CNN.

**Kata kunci** : Convolution Neural Network (CNN), Electroencephalogram (EEG), Epilepsy, Power Spectral Density (PSD), Singular Spectrum Analysis (SSA).

*[Halaman ini sengaja dikosongkan]*

## KATA PENGANTAR

Segala puji bagi Allah SWT sehingga buku tesis dengan judul “Klasifikasi EEG Epilepsi Menggunakan Singular Spectrum Analysis, Power Spectral Density dan Convolution Neural Network” dapat diselesaikan dengan baik. Sholawat dan salam semoga selalu tercurahkan kepada junjungan kami nabi besar Muhammad SAW. Dengan selesai dan tersusunnya laporan tesis ini, maka penulis mengucapkan terima kasih atas bantuan dan dukungan dari berbagai pihak baik moril maupun materiil dalam pembuatan tesis ini, antara lain:

1. Kedua orang tua Penulis yang senantiasa memotivasi dan mendo'akan Penulis dalam tiap kesempatan.
2. Ibu Prof. Ir. Handayani Tjandrasa, M.Sc, Ph.D selaku dosen Pembimbing I yang senantiasa memberikan arahan serta nasihat yang membangun kepada Penulis.
3. Bapak Dr. Agus Zainal Arifin, S.Kom, M.Kom, Ibu Anny Yuniarti, S.Kom., M.Comp.Sc, dan Ibu Dini Adni Navastara, S.Kom, M.Sc selaku Tim Penguji yang telah berkenan memberikan kritik serta saran untuk pengembangan tesis ini.
4. Bapak Waskitho Wibisono, S.Kom., M.Eng., Ph.D. selaku Ketua Program Magister Teknik Informatika yang telah memberi dukungan dan arahan dalam menyelesaikan permasalahan akademik.
5. Kepada teman-teman pascasarjana angkatan 2015 yang telah banyak membantu dan berbagi ilmu pengetahuan sehingga berbagai kesulitan yang dihadapi penulis terasa sangat mudah untuk dipecahkan.
6. Teman-teman di lingkungan ITS dan semua pihak yang tidak dapat disebutkan satu per satu yang telah memberikan motivasi dan saran kepada penulis dalam menyelesaikan studi S2 ini.

Penulis menyadari bahwa dalam penelitian dan penulisan tesis ini masih terdapat kekurangan. Namun Penulis tetap berharap hasil dari penelitian pada tesis ini tetap dapat bermanfaat bagi penelitian-penelitian berikutnya. Oleh karena itu,

kritik serta saran yang membangun tetap Penulis harapkan sehingga penelitian-penelitian berikutnya dapat menjadi lebih baik.

Akhir kata, Penulis memohon maaf jika terdapat kesalahan dalam penyusunan dan penulisan tesis ini. Penulis juga memohon maaf kepada semua pihak apabila dalam proses penelitian serta penyusunan tesis ini terdapat kesalahan yang disengaja maupun tidak disengaja oleh Penulis. Sesungguhnya kesempurnaan hanya milik Allah SWT, dan kesalahan murni dari Penulis sebagai manusia biasa.

Surabaya, 17 Juli 2017

Penulis

## DAFTAR ISI

LEMBAR PENGESAHAN .....	<b>Error! Bookmark not defined.</b>
ABSTRAK .....	iii
ABSTRACT .....	v
KATA PENGANTAR.....	vii
DAFTAR ISI.....	ix
DAFTAR GAMBAR .....	xi
DAFTAR TABEL.....	xiii
BAB 1 PENDAHULUAN .....	1
1.1 Latar Belakang.....	1
1.2 Perumusan Masalah .....	4
1.3 Tujuan Penelitian .....	4
1.4 Manfaat penelitian .....	4
1.5 Kontribusi .....	4
1.6 Batasan Penelitian.....	4
BAB 2 DASAR TEORI DAN KAJIAN PUSTAKA.....	5
2.1 Epilepsi .....	5
2.2 <i>Electroencephalogram</i> (EEG) .....	5
2.3 Klasifikasi Gelombang Otak.....	7
2.4 Teknik Perekaman EEG.....	8
2.5 Data Sinyal EEG .....	12
2.6 <i>Singular Spectrum Analysis</i> (SSA) .....	13
2.7 <i>Power Spectral Density</i> (PSD) berbasis metode <i>Welch</i> .....	15
2.8 <i>Artificial Neural Network</i> (ANN) .....	16
2.9 Fungsi Aktivasi .....	18
2.10 <i>Convolution Neural Networks</i> (CNN) .....	18
2.11 <i>Mean Absolute Percentage Error</i> (MAPE) .....	20
2.12 Normalisasi Data.....	21
2.13 <i>Confusion Matrix</i> .....	21
BAB 3 METODA PENELITIAN .....	23
3.1 Studi Literatur .....	23

3.2	Desain Model Sistem.....	24
3.2.1	Data Penelitian.....	24
3.2.2	Pengolahan Awal.....	26
3.2.3	Ekstraksi Fitur.....	29
3.2.4	Fase Klasifikasi.....	31
3.3	Pembuatan Perangkat Lunak.....	34
3.4	Uji coba.....	34
3.5	Analisa Hasil.....	35
BAB 4 HASIL DAN PEMBAHASAN.....		37
4.1	Lingkungan Uji Coba.....	37
4.2	Pengolahan Awal.....	38
4.2.1	<i>Embedding</i> .....	38
4.2.2	<i>Singular Value Decomposition (SVD)</i> .....	40
4.2.3	<i>Grouping</i> .....	41
4.2.4	<i>Diagonal Averaging</i> .....	42
4.3	Ekstraksi Fitur.....	44
4.4	Klasifikasi.....	44
4.5	Evaluasi.....	48
4.5.1	Hubungan Pemilihan <i>Eigenvalue</i> dengan Tingkat Akurasi.....	48
4.5.2	Hubungan Normalisasi dengan Tingkat Akurasi.....	51
4.5.3	Hubungan Filter pada CNN dengan Tingkat Akurasi.....	51
4.5.4	Evaluasi dan Analisis Hasil Akurasi.....	53
BAB 5 KESIMPULAN DAN SARAN.....		59
5.1	Kesimpulan.....	59
5.2	Saran.....	60
DAFTAR PUSTAKA.....		61
BIOGRAFI PENULIS.....		65

## DAFTAR GAMBAR

Gambar 2.1 Elektroda Topi dengan Penempatan Elektroda Sesuai dengan Sistem Penempatan Elektroda 10-20 .....	10
Gambar 2.2 Label untuk Titik-titik Penempatan Elektroda sesuai dengan Sistem 10-20 .....	11
Gambar 2.3 Bentuk Gelombang Sinyal EEG.....	12
Gambar 2.4 <i>Perceptron</i> .....	16
Gambar 2.5 Multilayer Perceptron.....	17
Gambar 2.6 Fungsi Aktivasi <i>Sigmoid Biner</i> .....	18
Gambar 2.7 <i>Convolution Neural Network</i> .....	19
Gambar 2.8 Convolution layer, (a) Convolution Filter dan (b) Pooling Layer.....	20
Gambar 3.1 Alur Metode Penelitian .....	23
Gambar 3.2 <i>Framework</i> Sistem Klasifikasi Sinyal EEG.....	24
Gambar 3.3 Bentuk Gelombang Sinyal EEG untuk Set A (a), set B (b), set C (c), set D (d) dan set E (e).....	25
Gambar 3.4 Diagram Alur SSA .....	27
Gambar 3.5 Contoh Rekonstruksi dengan SSA (a) Sinyal Asli (b) Hasil Rekonstruksi SSA .....	28
Gambar 3.6 Diagram Alur <i>Power Spectral Density</i> .....	29
Gambar 3.7 Contoh Ekstraksi Fitur dengan PSD, (a) Data hasil SSA (b) Hasil Ekstraksi Fitur PSD .....	30
Gambar 3.8 Diagram Alur <i>Convolution Neural Network</i> .....	31
Gambar 3.9 Arsitektur CNN .....	32
Gambar 4.1 Hasil Plot atau Visualisasi Data Kelas A dan Kelas E .....	38
Gambar 4.2 Ilustrasi <i>Trajectory Matrix X</i> .....	39
Gambar 4.3 Ilustrasi <i>Matrix Covariance YY'</i> .....	40
Gambar 4.4 Ilustrasi <i>Eigenvector</i> dari <i>Matrix Y</i> .....	41
Gambar 4.5 Ilustrasi Plot <i>Eigenvalue</i> dari <i>Matrix Y</i> .....	41
Gambar 4.6 Ilustrasi Plot Rekonstruksi Sebagian Sinyal EEG, garis biru Contoh Sebagian Sinyal Inputan EEG plot data A1, garis merah Hasil Rekonstruksi Sinyal A1 dengan <i>Eigenvalue</i> 1, garis hijau Hasil Rekonstruksi Sinyal A1 dengan <i>Eigenvalue</i> 2-4, garis magenta Hasil Rekonstruksi Sinyal A1 dengan <i>Eigenvalue</i> 5-11 .....	42
Gambar 4.7 Plot Rekonstruksi Sinyal EEG (a) Sample sinyal EEG kelas A, dan Sinyal Hasil Rekonstruksi Sinyal dengan (b) <i>Eigenvalue</i> 1, (c) <i>Eigenvalue</i> 1-100, (d) <i>Eigenvalue</i> 100-200, (e) <i>Eigenvalue</i> 200-1000, (f) <i>Eigenvalue</i> 1000-2000, (g) <i>Eigenvalue</i> 1-500, (h) <i>Eigenvalue</i> 500-1000, (i) <i>Eigenvalue</i> 1000-1500, (j) <i>Eigenvalue</i> 1500-2000. ....	43

Gambar 4.8 Plot Hasil Ekstraksi Fitur Sinyal EEG (a) Sample sinyal EEG kelas A, dan Sinyal Hasil Ekstraksi Fitur Menurut Kelompok SSA dengan (b) <i>Eigenvalue</i> 1, (c) <i>Eigenvalue</i> 1-100, (d) <i>Eigenvalue</i> 100-200, (e) <i>Eigenvalue</i> 200-1000, (f) <i>Eigenvalue</i> 1000-2000, (g) <i>Eigenvalue</i> 1-500, (h) <i>Eigenvalue</i> 500-1000, (i) <i>Eigenvalue</i> 1000-1500, (j) <i>Eigenvalue</i> 1500-2000.....	45
Gambar 4.9 <i>Filter Result</i> , (a) Sinyal Hasil Ekstraksi Fitur, (b) Sinyal hasil LPF, (c) Sinyal hasil HPF, (d) Sinyal hasil MF, (e) Full connected dari 3 filter .....	46
Gambar 4.10 Grafik Uji <i>Coba Eigenvalue</i> .....	49

## DAFTAR TABEL

Tabel 2.1 <i>Confusion matrix</i> .....	22
Tabel 4.1 Hasil Uji Coba Kelompok <i>Eigenvalue</i> .....	49
Tabel 4.2 Rata – rata kelompok <i>eigenvalue</i> .....	50
Tabel 4.3 Hasil Skema Normalisasi.....	51
Tabel 4.4 Uji Coba Filter CNN.....	52
Tabel 4.5 Uji Coba Skenario.....	53
Tabel 4.6 Confusion Matrix PSD dan CNN Untuk 3 Kelas.....	53
Tabel 4.7 Confusion Matrix SSA, PSD, dan CNN Untuk 3 Kelas.....	54
Tabel 4.8 <i>Precision dan Recall</i> Klasifikasi 3 Kelas.....	55
Tabel 4.9 Confusion Matrix PSD dan CNN untuk 5 kelas.....	56
Tabel 4.10 Confusion Matrix SSA, PSD, dan CNN Untuk 5 Kelas.....	56
Tabel 4.11 <i>Precision dan Recall</i> Klasifikasi 5 Kelas.....	57

*[Halaman ini sengaja dikosongkan]*

# **BAB 1**

## **PENDAHULUAN**

### **1.1 Latar Belakang**

Otak manusia dapat melakukan berbagai aktivitas baik itu normal maupun abnormal. Kondisi normal terdiri dari kondisi fisik (seperti tidur, terjaga, dan beraktifitas) dan kondisi mental (seperti nyaman, sedih, dan marah). Kondisi abnormal dapat terjadi pada gangguan neurologis dan ketidakseimbangan akibat pengaruh obat-obatan, seperti kejang pada epilepsi dan demensia (Teplan 2002). Aktivitas otak tersebut dapat diteliti dengan media penelitian berupa citra fungsional yang dihasilkan dari pengukuran sinyal otak dengan *electroencephalogram* (EEG), *Magneto-Encephalography* (MEG), dan *functional Magnetic Resonance Imaging* (fMRI).

Pengukuran sinyal EEG merupakan suatu teknik yang paling mudah dan paling murah dibandingkan dengan pengukuran fMRI dan MEG. Resolusi temporal yang tinggi dari EEG dapat memungkinkan tertangkapnya perubahan aktivitas otak lebih cepat dibandingkan dengan MEG dan fMRI, sehingga penelitian dengan menggunakan sinyal EEG lebih diminati. Lebih diminati karena EEG bersifat non-invasif dan merupakan alat yang praktis dalam penelitian berbagai kondisi otak, terutama pada kasus gangguan neurologis (Palaniswami et al. 2008). EEG adalah metode yang digunakan dalam mengukur aktivitas listrik spontan dari otak yang diperoleh dengan menembakkan sinyal listrik ke neuron dalam otak. Proses perekaman sinyal EEG dilakukan dalam waktu singkat, biasanya selama 20-40 menit. Rekaman diperoleh dengan menempatkan elektroda pada berbagai posisi pada kulit kepala (Teplan 2002). EEG mempunyai resolusi temporal yang tinggi dan cepat merespon segala perubahan aktivitas otak dibandingkan dengan MEG dan fMRI .

Sinyal EEG merupakan sinyal yang sangat kompleks dan menjadi sumber informasi untuk penelitian fungsi otak dan gangguan neurologis salah satunya adalah epilepsi. Epilepsi merupakan gangguan neurologis yang mempengaruhi lebih dari 50 juta orang di seluruh dunia. Epilepsi dianggap

sebagai gangguan neurologis kedua yang paling umum setelah stroke. Epilepsi ditandai dengan kelebihan jumlah listrik yang keluar dari sel-sel otak, yang bisa menyebabkan kejang - kejang dan atau gerakan abnormal. Dalam pendeteksian epilepsi, EEG telah dijadikan prosedur untuk pemeriksa rutin (Palaniswami et al. 2008).

Pola dan karakteristik yang dimiliki sinyal EEG pada serangan epilepsi dapat digunakan oleh dokter atau profesional kesehatan untuk membedakan serangan epilepsi dari kondisi normal (*nonseizure*). Tetapi, analisis secara visual tidak mungkin dilakukan secara rutin, karena sinyal EEG yang dihasilkan dari sistem monitoring EEG sangat besar dan cukup memakan waktu (Übeyli 2010). Beberapa teknik deteksi secara otomatis telah diuji coba untuk mempercepat dan meningkatkan akurasi identifikasi EEG patologis pada kasus serangan epilepsi, dan untuk mendeteksi lonjakan amplitudo dalam EEG untuk memprediksi terjadinya epilepsi (Palaniswami et al. 2008).

Deteksi otomatis epilepsi berbasis EEG telah banyak dikembangkan, dalam perkembangannya terdapat beberapa fokus penelitian yang dilakukan oleh peneliti. Fokus dari peneliti dapat berupa penyempurnaan metode yang digunakan dan banyaknya kelas yang dipakai dalam proses klasifikasi. Berdasarkan banyaknya kelas yang dipakai terbagi menjadi 4 kasus penelitian yaitu untuk 2 kelas, 3 kelas, 4 kelas dan 5 kelas. Dua kelas klasifikasi merupakan penelitian yang paling sering dilakukan oleh peneliti, seperti Güler dkk., 2005 menggunakan *recurrent neural networks* (RNNs) dan ekstraksi fitur Lyapunov yang di-*training* dengan algoritma *Levenberg–Marquardt*. Übeyli, 2006 menggunakan *multilayer perceptron neural network* (MLPNN), Lan Ma dkk, 2015 menggunakan *Convolutional Neural Network* (CNN). Untuk tiga kelas terdapat beberapa penelitian seperti yang dilakukan Tzallas et al. 2009 menggunakan *Time frequency* untuk mengekstraksi fitur yang ada pada sinyal EEG dan mengklasifikasikan EEG ke dalam 3 kelas dengan ANN. Dalam penelitian lain Faust et al. 2015 menggunakan *Wavelet based* untuk mengklasifikasikan 3 kelas EEG epilepsi. Untuk penelitian lima kelas, masih jarang dilakukan karena dianggap memerlukan analisis yang mendalam untuk masing–masing kelas sinyal. Penelitian yang telah dilakukan untuk lima kelas, seperti yang dilakukan

Tjandrasa et al. 2016 dengan menggabungkan *Intrinsic Mode Functions* dan *Power Spectrum* dalam pengklasifikasian sinyal EEG untuk kasus epilepsi.

Dalam tahapan proses klasifikasi atau *machine learning*, seleksi fitur adalah salah satu teknik terpenting dan sering digunakan dalam *pre-processing*. Seleksi fitur adalah proses memilih *subset* dari fitur asli sehingga jumlah fitur berkurang secara optimal sesuai dengan kriteria yang ditentukan. Teknik ini terbukti efektif mengurangi fitur-fitur yang tidak relevan, berlebihan, meningkatkan efisiensi dalam proses *learning*, dan meningkatkan kinerja *learning* seperti akurasi pada proses prediksi. Oleh karena itu, seleksi fitur menjadi sangat diperlukan oleh aplikasi *machine learning* ketika menghadapi data dengan dimensi yang tinggi. (Yu & Liu 2003).

SSA dalam sejarah penggunaannya digunakan untuk memisahkan sinyal *singlechannel* menjadi beberapa sinyal berdasarkan *trend*, komposisi dan juga *noise* (Zhigljavsky et al. 2009). SSA dapat mengurangi *noise* yang mempengaruhi pola utama atau ciri dari suatu sinyal. Lokal SSA digunakan untuk memisahkan sinyal EOG dari sinyal EEG yang akan digunakan pada tahapan selanjutnya dalam pengklasifikasian EEG (Kouchaki & Sanei 2013).

Dalam ekstraksi fitur untuk data berupa sinyal metode PSD juga sering dipakai karena mampu digunakan untuk menganalisa pola dari sinyal berdasarkan kekuatan spektrum yang dimiliki sebuah sinyal. PSD digunakan untuk menganalisa aktivitas *Electrodermal* dalam penilaian fungsi simpatik (Posada-Quintero et al. 2016).

Pada penelitian ini diajukan metode hybrid untuk pengolahan data awal menggunakan penggabungan *Singular Spectrum Analysis* (SSA) untuk menghilangkan *noise* dan memunculkan karakteristik sinyal, dilanjutkan *Power Spectral Density* (PSD) berbasis metode Welch dan *Convolution Neural Network* (CNN) untuk mengklasifikasikan sinyal. Penambahan metode kombinasi ekstraksi fitur tersebut diharapkan mampu meningkatkan hasil akurasi pada klasifikasi data sinyal EEG.

## **1.2 Perumusan Masalah**

Berdasarkan masalah yang di uraikan pada latar belakang maka rumusan masalah yang akan di selesaikan adalah sebagai berikut:

1. Bagaimana memunculkan karakteristik dan menghilangkan noise pada sinyal EEG menggunakan metode SSA?
2. Bagaimana tingkat akurasi proses klasifikasi data EEG untuk set A, B, C, D, dan E pada CNN?

## **1.3 Tujuan Penelitian**

Tujuan dari penelitian ini adalah mengembangkan metode untuk mengklasifikasikan sinyal EEG epilepsi dengan memunculkan karakteristik sinyal menggunakan SSA.

## **1.4 Manfaat penelitian**

Manfaat dari penelitian ini adalah meningkatkan akurasi klasifikasi sinyal EEG set A, set B, set C, set D dan set E sehingga dapat membantu pengamatan sinyal EEG dan memberikan referensi dalam pengolahan sinyal terutama EEG.

## **1.5 Kontribusi**

Kontribusi penelitian ini adalah menggunakan metode SSA untuk menghilangkan noise dan memunculkan karakteristik dari sinyal EEG, sehingga efektif digunakan dalam tahapan ekstraksi fitur menggunakan PSD.

## **1.6 Batasan Penelitian**

Penelitian pada area ini merupakan hal yang kompleks dan luas maka penelitian ini dibatasi sebagai berikut:

1. Data sampel sinyal EEG diperoleh dari Universitas Bonn.
2. Implementasi menggunakan perangkat lunak MATLAB.

## **BAB 2**

### **DASAR TEORI DAN KAJIAN PUSTAKA**

#### **2.1 Epilepsi**

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

Epilepsi merupakan suatu gangguan yang mempunyai problema – problema dasar tertentu (Marpaung 2005) :

- a. Adanya proses disfungsi sistem saraf pusat yang ditandai dengan adanya suatu gangguan yang bervariasi.
- b. Terdapat perbedaan beratnya serangan, dari yang hanya 1 kali serangan sampai beberapa kali serangan dalam sehari.
- c. Epilepsi merupakan suatu gangguan yang memberikan stigma. Stigma tersebut dikaitkan dengan adanya serangan epilepsi yang membawa dampak kurang baik terhadap kehidupan sosial.
- d. Adanya efek yang tidak diinginkan akibat pemakaian obat jangka panjang yang mungkin diremehkan.

#### **2.2 *Electroencephalogram (EEG)***

*Electroencephalogram (EEG)* adalah metode yang digunakan dalam pengukuran aktivitas listrik dari otak yang diperoleh dengan penangkapan sinyal listrik yang dirembakkan dari neuron ke neuron dalam otak. Proses perekaman sinyal EEG dilakukan dalam waktu sekitar 20-40 menit. Rekaman diperoleh dengan menempatkan elektroda pada berbagai posisi pada kulit kepala. EEG mempunyai resolusi temporal yang tinggi dan cepat merespon segala perubahan aktivitas otak dibandingkan dengan MEG dan fMRI (Teplan 2002).

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 secara langsung

dipermukaan korteks pada otak manusia melalui bedah saraf. Keuntungan dari pendekatan ini adalah sinyal EEG yang ditangkap/direkam memiliki kualitas sangat tinggi. Pendekatan lain adalah pendekatan non invasif, yaitu dengan menempelkan elektroda pada permukaan kulit kepala. Hasil perekaman EEG non invasif memiliki kualitas sinyal yang kurang bagus karena tengkorak menjadi penghalang sinyal yang dipancarkan neuron sehingga gelombang elektromagnetik akan terdispersi, dan menjadi kabur. Selain itu juga memiliki resolusi spasial rendah sehingga sulit untuk menentukan wilayah otak yang menghasilkannya atau memancarkan sinyal yang ditembakkan neuron (Karyawan et al. 2011). Rekaman EEG non-invasif dapat diterapkan terus menerus pada pasien, dan bisa diterapkan ke semua kalangan dari anak-anak sampai dengan orang dewasa dengan hampir tidak ada risiko atau pembatasan (Teplan 2002).

Ketika sel-sel otak (neuron) diaktifkan atau menerima perintah, maka arus listrik akan dihasilkan sehingga EEG dapat diukur. Arus yang mengalir saat neuron diaktifkan, akan menimbulkan reaksi antara eksitasi sinaptik dendrit terhadap neuron piramidal di korteks serebral. Perbedaan potensial listrik dihasilkan dari kumpulan nilai potensial *postsynaptic* dari sel piramidal yang menciptakan dipol listrik antara *soma* (bodi *neuron*) dan *apical dendrit* (cabang-cabang saraf). Otak terdiri atas sebagian besar arus listrik ion  $\text{Na}^+$ ,  $\text{K}^+$ ,  $\text{Ca}^{++}$ , dan  $\text{Cl}^-$  yang dikeluarkan melalui saluran dalam membran *neuron* yang arahnya diatur oleh potensial membran. Hanya populasi besar neuron yang aktif dapat menghasilkan rekaman aktivitas listrik pada permukaan kepala. Antara elektroda dan lapisan saraf, aliran listrik dapat menembus melalui kulit, tengkorak dan lapisan lainnya. Sinyal listrik lemah yang terdeteksi oleh elektroda kulit kepala secara masif diperkuat, dan kemudian ditampilkan di atas kertas atau disimpan ke memori komputer. Karena kemampuan menggambarkan aktivitas listrik otak baik normal dan abnormal, EEG telah menjadi alat yang penting dalam bidang neurologi dan neurofisiologi klinis (Teplan 2002).

Aktivitas listrik otak manusia dimulai sekitar minggu 17-23 dari perkembangan janin. Pada saat lahir jumlah sel saraf sudah berkembang dengan jumlah sekitar  $10^{11}$  neuron. Rata-rata kepadatan neuron adalah  $10^4$  per  $\text{mm}^3$ . Neuron saling terhubung ke dalam jaring saraf melalui sinapsis. Orang dewasa

memiliki sekitar 500 triliun ( $5 \times 10^{14}$ ) sinapsis. Jumlah sinapsis per satu neuron sesuai dengan peningkatan usia, namun jumlah neuron menurun terhadap penambahan usia, sehingga jumlah sinapsis berkurang terhadap penambahan usia (Teplan 2002).

Dari sudut pandang anatomi, otak dapat dibagi menjadi tiga bagian: otak besar, otak kecil, dan batang otak. Otak besar terdiri dari belahan otak kiri dan kanan dengan lapisan permukaan yang sangat rumit yang disebut korteks serebral. Korteks adalah bagian yang dominan dari sistem saraf pusat. Otak besar menjadi pusat inisiasi gerakan, kesadaran sensoris, analisis kompleks, dan ekspresi emosi dan perilaku. Otak kecil pusat koordinasi gerakan otot tak sadar dan keseimbangan. Batang otak mengontrol sekresi pernapasan, pengaturan jantung, bioritmik, neurohormon dan sekresi hormon, dan lain-lain. Aktivitas listrik korteks serebral mempunyai pengaruh yang paling tinggi terhadap EEG karena berada pada posisi permukaan (Teplan 2002).

Sinyal EEG dihasilkan karena arus yang ditembakkan antara neuron-neuron pada otak. Ketika neuron diaktifkan, arus mengalir antara dendrit karena eksitasi sinaptik. Arus ini menghasilkan medan magnet dan medan listrik sekunder. Medan magnet diukur dengan mesin *electromyogram* (EMG) dan medan listrik diukur oleh sistem EEG yang berada pada permukaan kepala. Sinyal EEG manusia kali pertama direkam oleh Hans Berger pada tahun 1924, dan terbukti menjadi terobosan signifikan dalam penelitian otak manusia. Dalam penelitian awalnya, dua elektroda dihubungkan pada tengkorak pasien dan mampu mendeteksi arus yang sangat lemah dengan menggunakan galvanometer. Dewasa ini, mesin EEG klinis dapat ditemukan di instansi kesehatan untuk pemantauan rutin aktivitas listrik otak dan membantu dokter dalam mengambil keputusan (Palaniswami et al. 2008)

### **2.3 Klasifikasi Gelombang Otak**

Untuk mendapatkan pola dasar otak seseorang, subyek diinstruksikan untuk menutup mata dan rileks. Pola otak membentuk pola gelombang sinusoidal umum. Biasanya, pola otak diukur dari puncak ke puncak dan dalam amplitudo

berkisar 0,5-100  $\mu\text{V}$ , yaitu sekitar 100 kali lebih rendah daripada sinyal *electrocardiogram* (ECG). Melalui transformasi Fourier *power spectrum* dihasilkan sinyal EEG asli. Dalam *power spectrum*, kontribusi gelombang sinus dengan frekuensi yang berbeda terlihat. Meskipun spektrum kontinyu, mulai dari 0 Hz sampai satu setengah dari frekuensi *sampling*, keadaan otak seseorang dapat menghasilkan frekuensi yang lebih dominan. Gelombang otak dikategorikan ke dalam empat kelompok dasar, yaitu:

- Beta ( $> 13$  Hz),
- Alpha (8-13 Hz),
- Theta (4-8 Hz),
- Delta (0,5-4 Hz) (Teplan 2002).

#### **2.4 Teknik Perekaman EEG**

Untuk membaca sinyal EEG, elektroda akan ditempelkan pada permukaan kepala, *amplifier* meneruskan sinyal dalam satuan mikro volt ( $\mu\text{V}$ ) ke kisaran tertentu sehingga didigitalisasi secara akurat, *converter* mengubah sinyal dari analog ke bentuk digital, dan komputer (atau perangkat lainnya) menyimpan dan menampilkan data yang diperoleh.

Elektroda merekam aktivitas komunikasi antar neuron yang diidentifikasi sebagai EEG di otak, sehingga memungkinkan pengukuran perubahan tegangan listrik selama waktu perekaman dalam bentuk aliran listrik dasar antara sinyal elektroda aktif dan elektroda referensi. Elektroda tambahan ketiga, disebut elektroda *ground*, diperlukan untuk mendapatkan perbedaan tegangan dengan mengurangi tegangan yang ditunjukkan pada titik aktif dan referensi. Konfigurasi minimal untuk *mono-channel* perekaman EEG terdiri atas satu elektroda aktif, satu (atau dua dihubungkan bersama secara khusus) elektroda referensi dan satu elektroda *ground*. Konfigurasi *multi-channel* dapat terdiri hingga 128 atau 256 elektroda aktif.

Elektroda perekam EEG dengan fungsi yang baik sangat berperan dalam memperoleh data kualitas tinggi untuk kebutuhan interpretasi. Berbagai jenis elektroda yang ada dengan karakteristik yang berbeda pula. Pada dasarnya jenis-jenis elektroda adalah:

- Sekali pakai (tanpa gel, dan dengan gel),
- Lempengan elektroda yang dapat digunakan kembali (emas, perak, *stainless steel* atau timah),
- Ikat kepala dan topi elektroda,
- Elektroda berbasis garam,
- Jarum elektroda.

Untuk perekaman *multichannel*, topi elektroda lebih disukai, dengan beberapa elektroda yang terpasang pada permukaan. Elektroda kulit kepala yang umum digunakan terbuat dari lempengan Ag-AgCl (perak-perak klorida), dengan diameter 1 sampai 3 mm, dengan kabel panjang yang dapat dihubungkan ke *amplifier*. Elektroda AgCl digunakan karena dapat merekam perubahan tegangan yang sangat lambat dengan akurat. Elektroda jarum digunakan untuk perekaman yang lama dan invasif yang disisipkan di bawah kulit kepala. Sebelum perekaman dilakukan pembersihan permukaan kulit dari minyak dan menyikat dari bagian-bagian kering. Jika menggunakan elektroda Ag-AgCl, ruang antara elektroda dan kulit harus dilapisi dengan pasta konduktif yang juga berfungsi untuk membantu menempel dengan baik. Topi elektroda dengan jumlah elektroda yang terpasang pada permukaan dapat dilihat pada Gambar 2.1.

Pada tahun 1958, Federasi Internasional Elektroensefalografi dan Neurofisiologi Klinis (*International Federation in Electroencephalography and Clinical Neurophysiology*) mengadopsi standardisasi untuk penempatan elektroda yang disebut sistem penempatan elektroda 10-20. Sistem ini menstandarisasi penempatan fisik dan posisi elektroda pada kulit kepala. Kepala dibagi menjadi area-area dengan jarak yang proporsional, mulai permukaan tengkorak atas (*nasion, preauricular point, inion*) agar diperoleh area yang memadai dari semua daerah otak. Label 10-20 menunjukkan jarak proporsional dalam persen antara telinga dan hidung di mana poin untuk elektroda dipilih. Penempatan elektroda diberi label sesuai daerah otak yang berdekatan: F (*frontal*), C (*central*), T (*temporal*), P (*posterior*), dan O (*occipital*). Huruf disertai dengan angka ganjil di sisi kiri kepala dan nomor genap pada sisi kanan (Teplan, 2002). Gambar 2.1 adalah gambar sistem penempatan elektroda 10-20.

Daerah otak yang berbeda secara tomografi berhubungan dengan fungsi



Gambar 2.1 Elektroda Topi dengan Penempatan Elektroda Sesuai dengan Sistem Penempatan Elektroda 10-20

yang berbeda dari otak. Setiap elektroda kulit kepala terletak dekat pusat-pusat otak tertentu, misalnya F7 terletak di dekat pusat kegiatan rasional, Fz dekat pusat motivasi dan kemauan, F8 dekat dengan sumber impuls emosional. Korteks di sekitar C3, C4, dan lokasi Cz berhubungan dengan fungsi sensorik dan motorik. Lokasi dekat P3, P4, dan Pz berperan untuk kegiatan persepsi dan diferensiasi. Lokasi dekat T3 dan T4 adalah pengolah emosional, sementara di T5, T6 adalah fungsi memori tertentu berada. Daerah visual primer dapat ditemukan titik bawah O1 dan O2. Namun elektroda kulit kepala tidak mencerminkan area tertentu dari korteks, sebagai lokasi yang tepat dari sumber yang aktif dan masih terdapat masalah karena keterbatasan yang disebabkan oleh sifat tengkorak yang non-homogen, orientasi yang berbeda dari sumber korteks, koherensi antara sumber (Teplan, 2002).

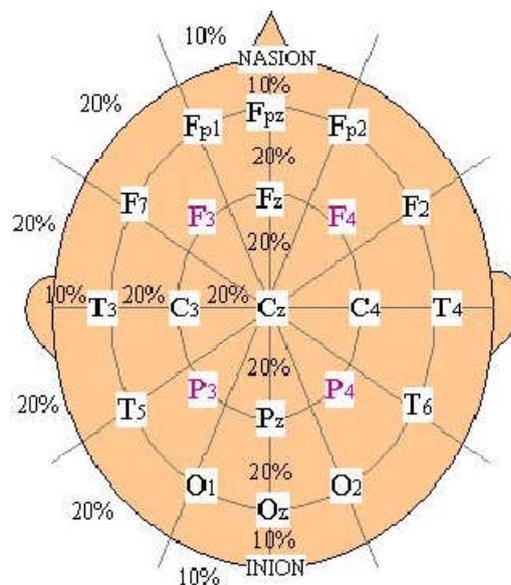
Proses perekaman dengan komputer dilakukan melalui proses *sampling* yang berulang-ulang pada saluran sinyal analog dalam interval waktu yang tetap (*sampling interval*). Tiap sampel dikonversi ke bentuk digital dengan *analog-to-*

*digital (A/D) converter*. *A/D converter* dihubungkan ke sistem komputer sehingga tiap sampel dapat disimpan dalam memori komputer. Resolusi konverter ditentukan oleh amplitudo terkecil dari sampel yang didapat. Caranya dengan membagi rentang tegangan dari *A/D converter* dengan 2 pangkat jumlah *bit A/D converter*. *A/D converter* biasanya menggunakan minimal 12 bit (4.096 tingkat nilai yang berbeda) (Teplan, 2002). *Bandwidth* efektif dari sinyal EEG adalah sekitar 100 Hz. Sehingga minimal terdapat 200 sampel per detik yang diperlukan untuk *sampling* (sesuai kriteria Nyquist). Representasi kuantisasi paling sering digunakan adalah 16 bit.

Sinyal EEG terbukti cukup membantu proses pemantauan dan pendiagnosisan sejumlah kasus klinis, yaitu:

- Epilepsi,
- Penyakit Alzheimer,
- Penyakit Huntington,
- Gangguan tidur.

EEG digunakan ahli saraf untuk mempelajari fungsi otak. EEG akan diolah menggunakan metode dalam *computational intelligence (CI)* dan



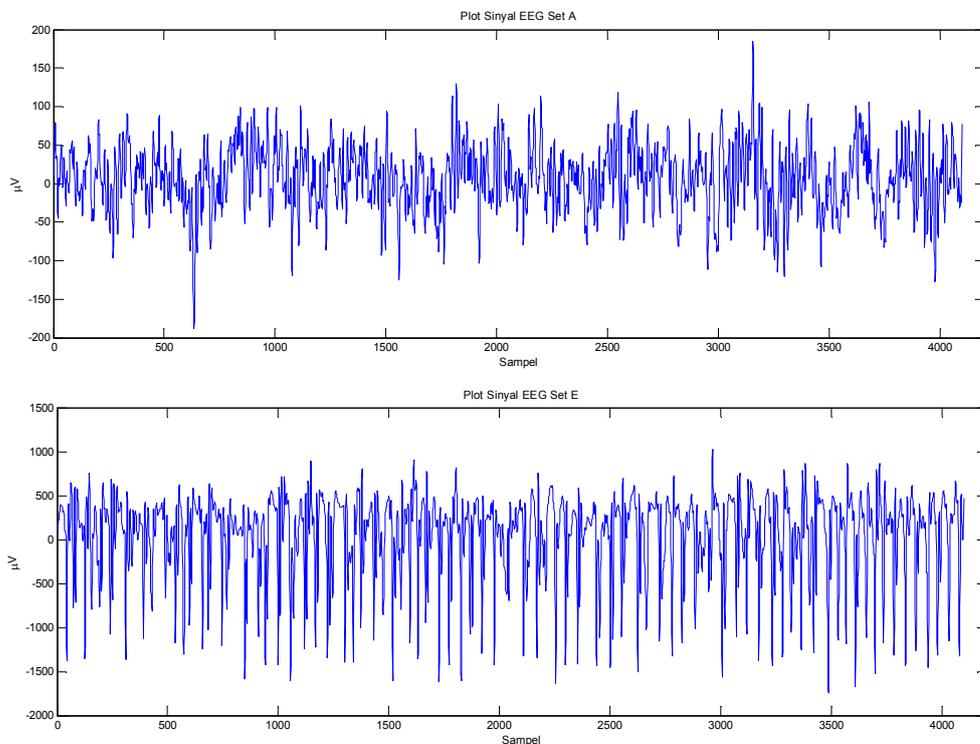
Gambar 2.2 Label untuk Titik-titik Penempatan Elektroda sesuai dengan Sistem 10-20

pemodelan matematika untuk membantu proses analisis EEG. Selain itu EEG juga telah dikembangkan untuk beberapa aplikasi brain computer interface (BCI) sehingga dapat membantu penderita cacat dalam menjalani kegiatan sehari-hari. BCI dapat memfasilitasi komunikasi dari individu yang memiliki cacat fisik dengan bantuan komputer dengan menggunakan karakteristik sinyal EEG. Aplikasi EEG selanjutnya lainnya adalah penelitian respon otak yang muncul terhadap suara, sentuhan, dan cahaya, yang berguna untuk mengevaluasi sejumlah kondisi neurologi (Palaniswami et al. 2008).

## 2.5 Data Sinyal EEG

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 ([http://epileptologie-bonn.de/cms/front\\_content.php?idcat=193&lang=3&changelang=3](http://epileptologie-bonn.de/cms/front_content.php?idcat=193&lang=3&changelang=3)).

Data sinyal EEG dari Universitas Bonn terdiri atas lima kelas *dataset* yaitu



Gambar 2.3 Bentuk Gelombang Sinyal EEG

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) (Andrzejak, 2001). Masing–masing data sinyal EEG digital tersebut terdiri atas 4097 data diskrit.

Plot sinyal EEG dalam bentuk gelombang ditunjukkan Gambar 2.3. Sumbu vertikal menunjukkan nilai tegangan sinyal listrik dalam  $\mu\text{V}$ , sedangkan sumbu horizontal adalah urutan data sampel.

## 2.6 *Singular Spectrum Analisis (SSA)*

SSA adalah sebuah teknik berbasis ruang bagian yang sering digunakan untuk analisis geofisika iklim dan time series (Maddirala & Shaik 2015). Tujuan utama dari SSA adalah untuk menguraikan sinyal yang berupa *singlechannel* sinyal menjadi beberapa sinyal, dengan masing–masing sinyal pecahan tersebut dapat diindikasikan sebagai *trend*, *periodic/quasi-periodic component* dan *noise* (Zhiljvsky et al. 2009). Dengan adanya pemisahan sinyal tersebut sinyal dapat dipilah mana yang paling mewakili *trend* kelas pada saat klasifikasi.

$$X = \begin{pmatrix} y_1 & y_2 & \cdots & y_K \\ y_2 & y_3 & \cdots & y_{K+1} \\ \vdots & \vdots & \ddots & \vdots \\ y_L & y_{L+1} & \cdots & y_T \end{pmatrix} \quad (2.1)$$

Pada dasarnya, SSA terdiri dari dua langkah: *decomposition* dan *reconstruction*. Dalam *decomposition* dibagi lagi menjadi 2 yaitu *embedding* dan *Singular Value Decomposition (SVD)*. *Embedding* merupakan proses pemecahan *singlechannel* ke *multichannel* sinyal dengan memanfaatkan *lagged vector singlechannel*. Apabila *singlechannel*  $Y_T = (y_1, y_2, \dots, y_T)$  akan diubah ke

*multichannel*  $X_1, \dots, X_k$  dengan vektor  $X_i = (y_i, y_{i+1}, \dots, y_{i+L-1})^T \in R^T$ , dimana  $K = T - L + 1$  seperti persamaan 2.1. (Zhigljavsky et al. 2009). Vector  $X_i$  adalah vector  $L$ -lagged dari  $Y$ . Di fase *embedding* ini terdapat 1 parameter, yaitu *Window Length* atau  $L$  yang harus disesuaikan dengan permasalahan yang dihadapi. Parameter  $L$  harus cukup lebar dan sesuai agar dapat memisahkan sinyal dengan baik dan berada pada range  $2 \leq L \leq T$ .

Setelah didapat matrik  $X$  pada langkah 1, Selanjutnya adalah langkah kedua yaitu *Singular Value Decomposition* (SVD). Pertama definisikan *covariance* matrik  $C = XX^T$  yang akan digunakan untuk menghitung *eigenvalues* dan *eigenvectors*. *Eigenvalues* akan dicari sebanyak  $L$  nilai dengan terurut dari yang paling besar ke terkecil ( $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_L \geq 0$ ) dan *eigenvector* ( $U_1, U_2, \dots, U_L$ ). Setelah didapat *eigenvalues* dan *eigenvectors* selanjutnya SVD akan ditulis dengan matriks  $X = E_1 + E_2 + \dots + E_d$ , dimana  $E_i = \sqrt{\lambda_i} U_i V_i^T$ ,  $d$  adalah banyaknya *eigenvalue* yang lebih dari 0, dan  $(V_1, V_2, \dots, V_d)$  adalah *Principal Component* (PC) dengan nilai  $V_i = X^T U_i \sqrt{\lambda_i}$  (enrico, 2013). Dan koleksi dari  $(V_i, U_i, \sqrt{\lambda_i})$  disebut dengan eigentriple dari matriks  $X$  (nina, 2013).

Langkah yang kedua adalah *reconstruction* dan akan dibagi menjadi 2 step yaitu *grouping* dan *diagonal averaging*. Dalam fase *Grouping*, *eigentriple* yang didapat akan digunakan untuk memisahkan sinyal yang dianggap sebagai *trend* dan *noise* (Moskvina & Schmidt 2003). Berdasarkan urutan *eigenvalue* yang dibatasi nilai 0, akan didapatkan  $I$  dimana  $I = (1, 2, \dots, m)$ , dimana  $m$  banyaknya *eigenvalue* yang masuk ke dalam subset. Setelah ditentukan nilai  $I$  maka matriks  $X$  akan dapat dipisah,  $X = X_I + X_{\bar{I}}$ , dimana  $X_I = \sum_{i \in I} X_i$  dan  $X_{\bar{I}} = \sum_{i \notin I} X_i$ . Apabila pemilihan  $I$  sesuai,  $X_I$  akan mencerminkan *trend* dari kelas yang sesuai dengan potongan sinyal tersebut dengan memisahkan  $X_{\bar{I}}$ .

Fase terakhir adalah *Diagonal Averaging*, yang ditujukan untuk mengubah matrik  $X_I$  menjadi Hankel matrik yang kemudian akan diubah menjadi form originalnya. Jika  $z_{ij}$  bagian dari matrik  $Z$ , dan  $k$  adalah optimal result dari merata rata  $z_{ij}$  dari  $i, j$  sehingga  $i + j = k + 2$ . Procedure ini dinamakan *diagonal averaging* atau *Hankelization* dari matriks  $Z$ . Hankel matrik dari  $Z$  adalah  $\mathcal{H}Z$ ,

menurut riset *Hankelization procedure* matrik  $\mathcal{H}Z$  merupakan matrik yang paling mirip dengan  $Z$ . Dengan menggunakan procedure tersebut digunakan untuk matriks yang ada menjadi  $X = \tilde{X}_{I_1} + \dots + \tilde{X}_{I_m}$ , dimana  $\tilde{X}_{I_1} = \mathcal{H}Z$ . Persamaan tersebut sama dengan dekomposisi dari  $Y_T = (y_1, y_2, \dots, y_T)$  ke dalam penjumlahan seri  $d$  menjadi  $y_t = \sum_{k=1}^m \tilde{y}_t^{(k)}$ , dimana  $\tilde{Y}_T^{(k)} = (\tilde{Y}_1^{(k)}, \dots, \tilde{Y}_T^{(k)})$  berhubungan ke matrik  $X_{I_k}$ .

## 2.7 Power Spectral Density (PSD) berbasis metode Welch

Salah satu komponen 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 suara berdasarkan perhitungan estimasi spectrum daya adalah metode Welch (Titisari et al. 2013).

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 (R & Wijayanto n.d.).

Algoritma Power Spektral Density menggunakan metode Welch adalah sebagai berikut (Parhi & Ayinala 2014):

- Sinyal inputan  $x[N]$  yang dibagi menjadi sebanyak  $L$  overlapping segmen menjadi:

$$x_l(n) = x(n + (l - 1)M) \quad , \quad (2.2)$$

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. Setelah didapat *window* dari segmen, selanjutnya akan diolah dengan FFT.

$$A_l(k) = \sum_{n=0}^{N-1} x_l(n)w(n)e^{-j\frac{2\pi}{N}nk} , \quad (2.3)$$

$$\phi_l(k) = \frac{1}{NP} |A_l(k)|^2 , \quad (2.4)$$

dimana  $A_l$  adalah FFT dari segmen yang ada,  $\phi_l$  adalah periodogram, dan  $P$  menunjukkan power window ( $w(n)$ ), dengan

$$P = \frac{1}{N} \sum_{n=0}^{N-1} |w(n)|^2 , \quad (2.5)$$

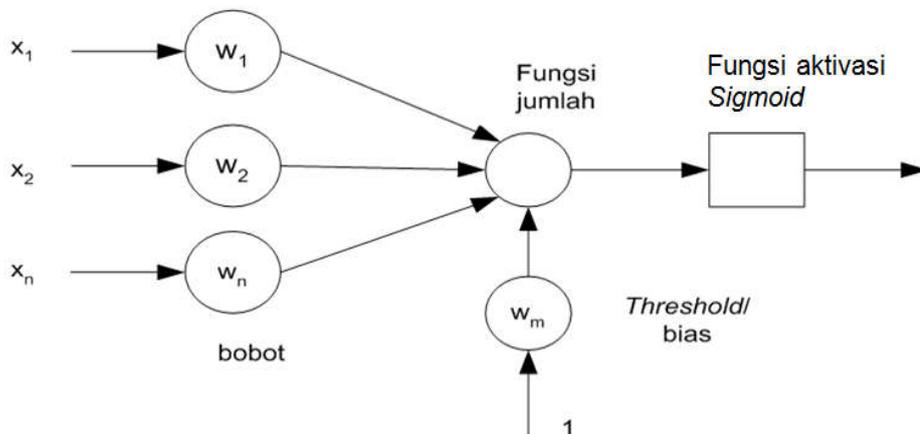
dan akan diestimasi dengan metode Welch dari PSD dengan melihat rata-rata dari periodogram, dengan

$$S(k) = \frac{1}{L} \sum_{l=1}^L \phi_l(k) , \quad (2.6)$$

## 2.8 Artificial Neural Network (ANN)

*Artificial Neural Network* adalah suatu model pemroses data yang memiliki konsep yang sama dengan *Neural Network* pada otak manusia. Di dalam jaringan otak manusia yang berfungsi sebagai pengolah informasi manusia adalah neuron-neuron pada otak, sedangkan pada *Artificial Neural Network* yang berfungsi sebagai pengolah data salah satunya adalah perceptron.

Model jaringan *perceptron* ditemukan oleh Rosenblatt dan Minsky-Papert. Jaringan *perceptron* terdiri dari beberapa unit masukan dan memiliki sebuah unit



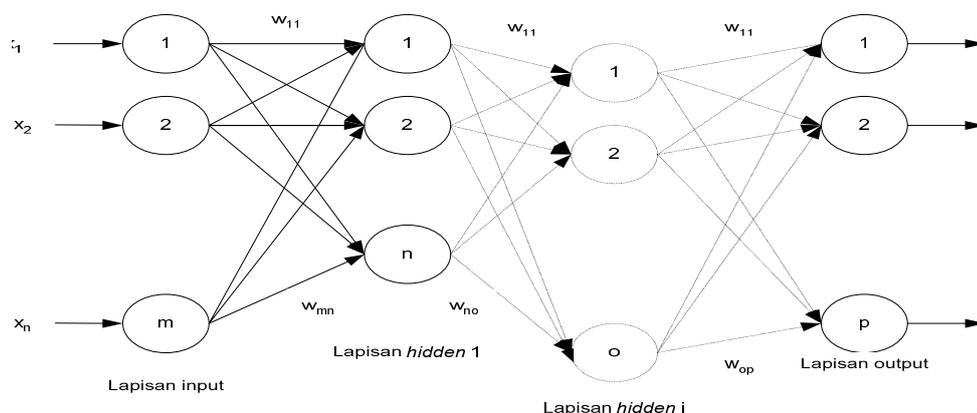
Gambar 2.4 Perceptron

keluaran seperti Gambar 2.4 *Perceptron* sebagai adalah bentuk paling sederhana dari *Artificial Neural Network* bekerja dengan cara menerima sejumlah ( $n$ ) masukan berupa vektor  $(x_1, x_2, x_3, \dots, x_n)$  dan menghasilkan sebuah keluaran dengan nilai 1 atau 0. Bentuk jaringan *perceptron* adalah sesuai Gambar 2.4 .

Seperti pada *neuron*, *perceptron* bekerja dengan menjumlahkan hasil kali masukan dan bobot  $(w_1, w_2, w_3, \dots, w_n)$ . Selanjutnya hasil penjumlahan ini dimasukkan pada suatu fungsi aktivasi untuk menghasilkan keluaran (Alppaydin 2010).

Kemampuan *perceptron* hanya pada fungsi sederhana, maka dikembangkan lagi untuk bisa menyelesaikan masalah yang lebih kompleks dengan cara mengkombinasikan beberapa *perceptron*. Kombinasi *perceptron* ini dikenal dengan *multilayer perceptron*. *Multilayer Perceptron* inilah yang untuk selanjutnya disebut sebagai *Artificial Neural Network*. Gambar 2.5 adalah *Artificial Neural Network* yang merupakan kombinasi dari beberapa *perceptron* yang dihubungkan sehingga menyerupai kinerja otak manusia yang sesungguhnya.

Dalam *Multilayer Perceptron* terdapat 3 bagian penting yaitu input layer, hidden layer dan output layer. Dimana banyaknya komposisi layer dan neuron yang ada pada masing–masing layer tergantung pada kasus yang ada (Alppaydin 2010).



Gambar 2.5 Multilayer Perceptron

## 2.9 Fungsi Aktivasi

Didalam CNN terdapat sebuah fungsi yang akan digunakan untuk mengolah data inputan menjadi suatu nilai outputan yang kita inginkan. Terdapat beberapa macam fungsi aktivasi salah satunya adalah fungsi aktivasi *sigmoid*. Fungsi aktivasi *sigmoid* adalah fungsi aktivasi yang memiliki nilai range 0 sampai 1 (Suartika et al. 2016). Persamaan fungsi aktivasi ini dinyatakan dalam bentuk :

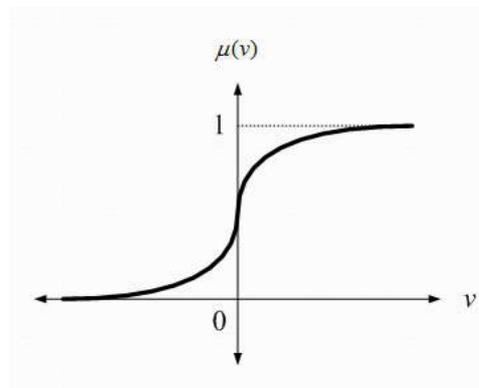
$$y = \mu(v) = \frac{1}{1+e^{-\sigma v}}. \quad (2.7)$$

dan  $x$ , merupakan nilai variabel dari vektor. Apabila digambarkan bentuk dari fungsi aktivasi ini seperti Gambar 2.6.

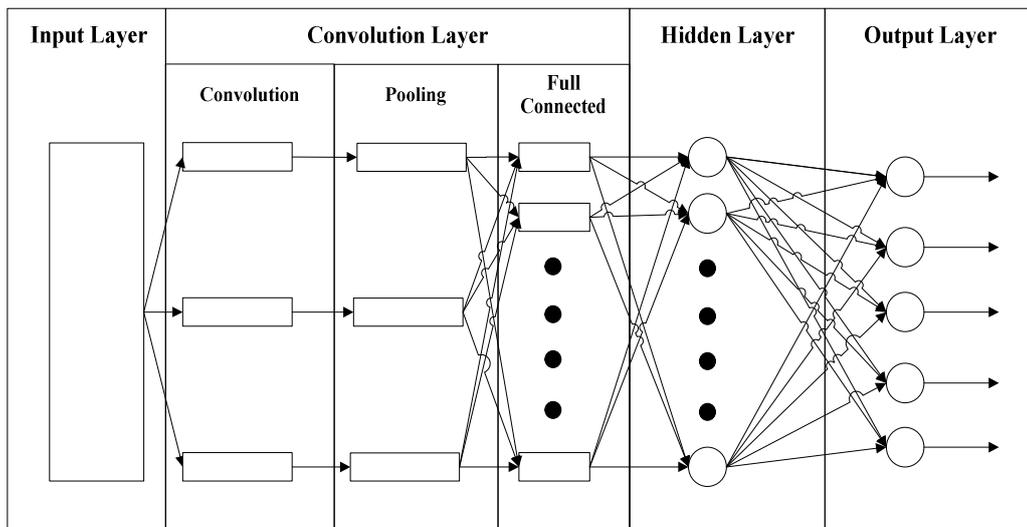
## 2.10 Convolution Neural Networks (CNN)

*Convolutional Neural Network* (CNN) adalah pengembangan dari *Multilayer Perceptron* (MLP) yang didesain untuk mengolah data dua dimensi. CNN termasuk dalam jenis *Deep Neural Network* karena kedalaman jaringan yang tinggi dan banyak diaplikasikan pada data citra dan suara. Perbedaan dari MLP adalah banyaknya layer dan fungsinya. CNN memiliki layer yang digunakan untuk mengekstraksi data awal sehingga lebih efektif digunakan pada layer klasifikasi.

Langkah dari CNN dapat dilihat pada Gambar 2.7 dimana data inputan akan dipecah menjadi beberapa bagian pada *convolution layer* yang masing-masing bagian mewakili fitur yang akan digunakan. *Convolution Layer* melakukan operasi konvolusi dari layer sebelumnya yaitu input layer. Layer



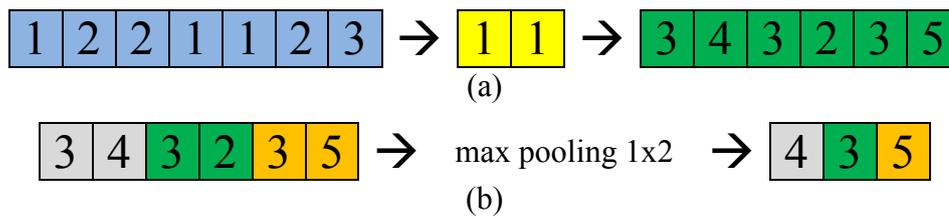
Gambar 2.6 Fungsi Aktivasi *Sigmoid Biner*



Gambar 2.7 Convolution Neural Network

tersebut adalah proses utama yang mendasari sebuah CNN. Tujuan dari *convolution layer* adalah untuk memilih fitur yang akan di gunakan pada proses *Multilayer Perceptron*. Fitur tersebut didapatkan dengan cara memfilter data inputan dengan *convolution layer* yang sesuai dengan fitur yang diinginkan. Konvolusi adalah suatu istilah matematis yang berarti mengaplikasikan sebuah fungsi pada output fungsi lain secara berulang. Dalam pengolahan data, konvolusi berarti mengaplikasikan sebuah filter (kernel) pada data disemua offset yang memungkinkan. Ilustrasi proses konvolusi dapat dilihat pada Gambar 2.8.a, dimana kotak biru secara keseluruhan adalah data yang akan dikonvolusi. Kernel bergerak dari sudut kiri atas ke kanan diwakili kotak kuning. Sehingga hasil konvolusi dari data tersebut dapat dilihat pada kotak hijau disebelah kanan. Untuk mendapatkan fitur yang optimum biasanya filter yang digunakan lebih dari satu. Masing–masing filter tersebut akan diaplikasikan ke data inputan dan setiap filter menghasilkan fitur masing–masing untuk data inputan yang sama. Penggunaan filter yang banyak tersebut bertujuan untuk membatasi variabel bebas yang mengurangi bahkan menutupi karakteristik dari data inputan.

Setiap Convolution layer diikuti dengan subsampling layer, dimana hasil dari convolution di ambil sampling untuk mengecilkan dimensi matrik. Dalam pengolahan data citra pada khususnya, subsampling juga bertujuan untuk meningkatkan invariansi posisi dari fitur. Dalam sebagian besar CNN, metode



Gambar 2.8 Convolution layer, (a) Convolution Filter dan (b) Pooling Layer

subsampling yang digunakan adalah *max pooling* (Palaz et al. 2015). *Max pooling* membagi output dari convolution layer menjadi beberapa grid kecil lalu mengambil nilai maksimal dari setiap grid untuk menyusun matriks citra yang telah direduksi seperti yang ditunjukkan pada Gambar.2.8.b. Grid yang berwarna abu – abu, hijau dan jingga merupakan kelompok grid yang akan dipilih nilai maksimumnya. Sehingga hasil dari proses tersebut dapat dilihat pada kumpulan grid disebelah kanannya. Proses tersebut memastikan fitur yang didapatkan akan sama meskipun objek data mengalami translasi (pergeseran). Gambar.2.8.b. Operasi *Max Pooling* Menurut Springenberg et al. pada tahun 2015, penggunaan *pooling layer* pada CNN hanya bertujuan untuk mereduksi ukuran data sehingga dapat dengan mudah digantikan dengan sebuah *convolution layer* dengan *stride* yang sama dengan *pooling layer* yang bersangkutan. Langkah *convolution layer* dan *subsampling layer* akan diulang sampai didapat matrik yang dirasa cukup kecil untuk dilakukan proses klasifikasi (Levinskis 2013).

Setelah didapatkan matriks yang cukup kecil dan tidak menghilangkan informasi, hasil dari *convolution layer* akan disatukan ke *Fully Connected Layer*. Layer tersebut adalah layer yang biasanya digunakan sebagai input layer pada *Multilayer Perceptron* dan bertujuan untuk melakukan transformasi pada dimensi data agar data dapat diklasifikasikan secara linear. Setiap neuron pada *convolution layer* perlu ditransformasi menjadi data satu dimensi terlebih dahulu sebelum dapat dimasukkan ke dalam sebuah *fully connected layer*.

### 2.11 Mean Absolute Percentage Error (MAPE)

MAPE merupakan salah satu metode pengecekan error yang membandingkan hasil sebenarnya dengan hasil yang didapat pada proses learning

yang dilakukan. Suatu model mempunyai kinerja sangat bagus jika nilai MAPE berada di bawah 10%, dan mempunyai kinerja bagus jika nilai MAPE berada di antara 10% dan 20% (Zainun et al. 2010). MAPE memiliki persamaan matematika seperti persamaan 2.5.

$$MAPE = \frac{1}{n+k} \sum_{i=1}^n \left| \frac{\hat{Y}_i - Y_i}{\hat{Y}_i} \right| \times 100 \% , \quad (2.8)$$

dimana nilai  $\hat{Y}_i$  merupakan nilai sebenarnya dari kelas pada data ke- $i$ ,  $Y_i$  merupakan nilai ramalan pada data ke- $t$ ,  $n$  merupakan banyaknya data latih, dan  $k$  merupakan banyaknya kelas keluaran dari data (Siswantoro et al. 2016). Nilai MAPE dengan prosentase yang semakin kecil maka semakin baik prediksi yang dilakukan oleh suatu system (Yuliandar et al. 2012).

## 2.12 Normalisasi Data

Sebelum data digunakan dalam proses yang ada dalam CNN, sinyal yang akan digunakan akan diubah menjadi sinyal dengan *range* antara 0,1 sampai 0,9. Hal ini dilakukan agar semua data sinyal yang akan masuk ke CNN memiliki range nilai yang sama.

Normalisasi data yang digunakan adalah persamaan seperti dalam Babovic dan Gopakumar, sebagai berikut :

$$X' = \frac{X - \text{Min}(X)}{\text{Max}(X) - \text{Min}(X)} (\text{Upperbound} - \text{Lowerbound} + \text{Lowerbound}) \quad (2.9),$$

dimana  $X'$  merupakan sinyal dengan range baru,  $X$  merupakan data sinyal yang asli, UpperBound merupakan batas atas nilai data pada sinyal baru, dan LowerBound merupakan batas bawah nilai data pada sinyal baru.

## 2.13 Confusion Matrix

*Confusion matrix* adalah metode yang digunakan untuk mengevaluasi efektivitas metode dan sistem yang telah dibuat. Evaluasi dilakukan terhadap tingkat akurasi klasifikasi dan tingkat kesalahan klasifikasi. Ukuran atau parameter yang digunakan untuk evaluasi antara lain akurasi klasifikasi,

sensitivitas, spesifisitas (Powers 2011). *Confusion matrix* berisi informasi tentang klasifikasi yang sebenarnya dan yang diperkirakan dari hasil sistem klasifikasi.

Tabel 2.1 *Confusion matrix*

Aktual	Prediksi	
	Positif	Negatif
Positif	<i>True Positive</i> (TP)	<i>False Negative</i> (FN)
Negatif	<i>False Positive</i> (FP)	<i>True Negative</i> (TN)

Tabel 2.1 menunjukkan *confusion matrix* untuk dua kelas klasifikasi. Akurasi klasifikasi, sensitivitas, spesifisitas dapat didefinisikan menggunakan elemen-elemen matriks konfusi sebagai berikut:

$$- \text{Klasifikasi akurasi (\%)} = \frac{TP + TN}{TP + FP + FN + TN} \times 100, \quad (2.10)$$

$$- \text{Sensitivitas / Recall (\%)} = \frac{TP}{TP + FN} \times 100, \quad (2.11)$$

$$- \text{Spesifisitas (\%)} = \frac{TN}{FP + TN} \times 100, \quad (2.12)$$

$$- \text{Nilai Prediksi Negatif / Precision (\%)} = \frac{TP}{TP + FP} \times 100, \quad (2.13)$$

$$- \text{Nilai Prediksi Negatif (\%)} = \frac{TN}{FN + TN} \times 100, \quad (2.14)$$

## **BAB 3**

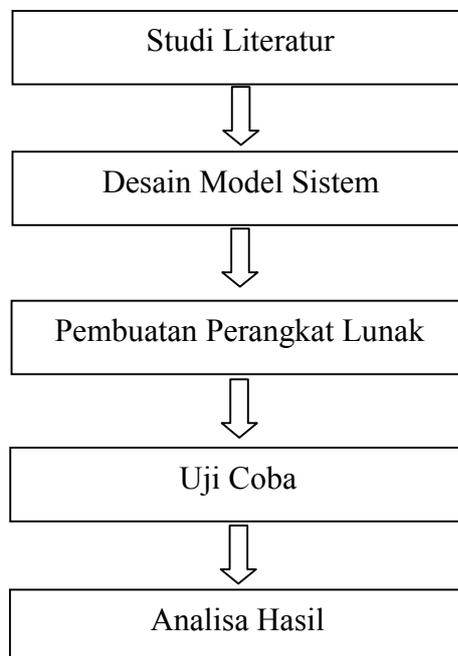
### **METODA PENELITIAN**

Metode penelitian ini melalui beberapa tahap meliputi (1) Studi Literatur, (2) Desain Model Sistem, (3) Pembuatan Perangkat Lunak, (4) Uji Coba, dan (5) Analisa Hasil. Alur tahapan-tahapan tersebut dapat dilihat pada Gambar 3.1.

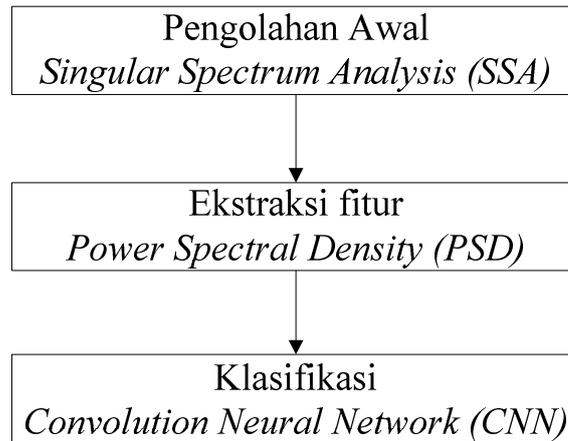
#### **3.1 Studi Literatur**

Studi literatur dilakukan untuk menggali informasi dan menganalisa perkembangan metodologi yang berkaitan dengan penelitian yang dilakukan. Beberapa referensi yang dibutuhkan berkaitan dengan penelitian ini adalah :

1. Preprocessing data untuk sinyal EEG.
2. Ekstraksi fitur menggunakan SSA dan PSD.
3. Sistem klasifikasi yang digunakan untuk penelitian.
4. Untuk evaluasi hasil klasifikasi akan digunakan akurasi.



Gambar 3.1 Alur Metode Penelitian



Gambar 3.2 *Framework* Sistem Klasifikasi Sinyal EEG

### 3.2 Desain Model Sistem

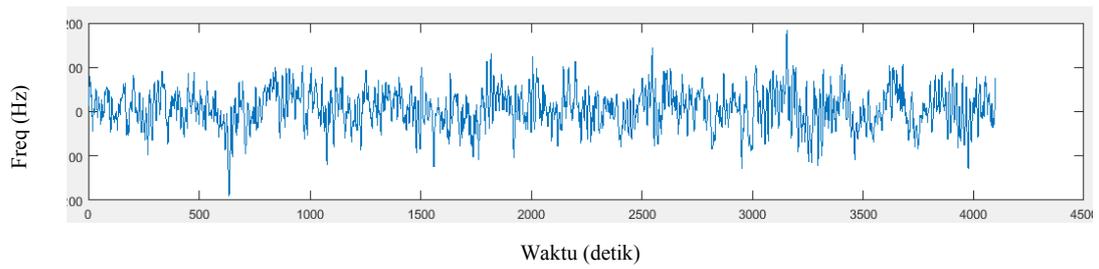
Secara keseluruhan desain model sistem yang akan digunakan pada penelitian ini memiliki 3 tahapan seperti yang ditunjukkan pada Gambar 3.2.

Gambar 3.2 menunjukkan fase-fase yang dilalui yang menunjukkan bagaimana sistem akan berjalan. Fase-fase tersebut adalah pengolahan awal sinyal, Ekstraksi fitur sinyal, dan yang terakhir adalah proses klasifikasi sinyal.

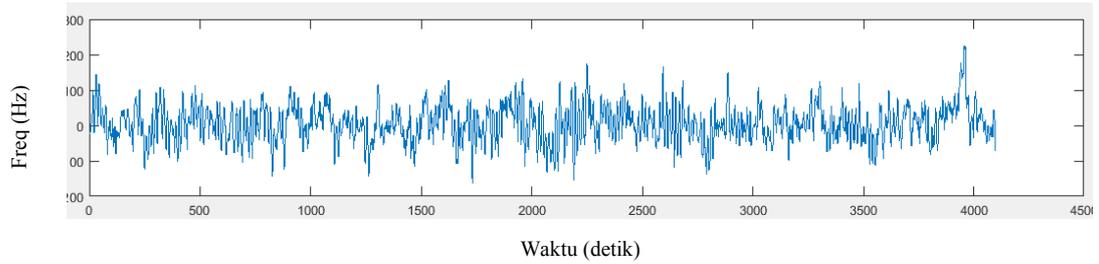
#### 3.2.1 Data Penelitian

Data sinyal EEG yang digunakan dalam penelitian ini 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 ([http://epileptologie-bonn.de/cms/front\\_content.php?idcat=193&lang=3&changelang=3](http://epileptologie-bonn.de/cms/front_content.php?idcat=193&lang=3&changelang=3)) (Andrzejak, 2001). *Dataset* secara lengkap terdiri atas lima kelas yaitu A, B, C, D, dan E. Masing-masing kelas terdiri atas 100 segmen sinyal EEG *single channel* dengan durasi selama 23,6 detik. Data disimpan dalam format teks (\*.txt). Setiap segmen dipilih dan dipotong dari rekaman EEG *multichannel* secara berkelanjutan setelah inspeksi artefak secara visual, misalnya gerakan mata atau aktivitas otot.

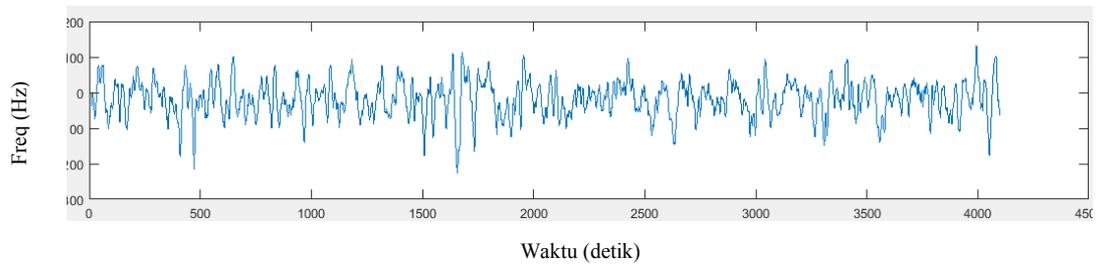
Set A dan set B adalah sinyal yang diambil dari rekaman EEG yang dilakukan pada lima sukarelawan sehat dengan skema penempatan elektroda standar (*International 10-20 system*) dalam kondisi santai, dengan set A diambil



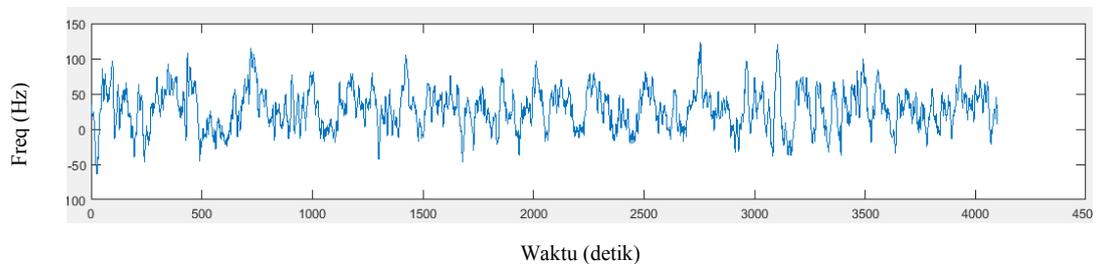
(a)



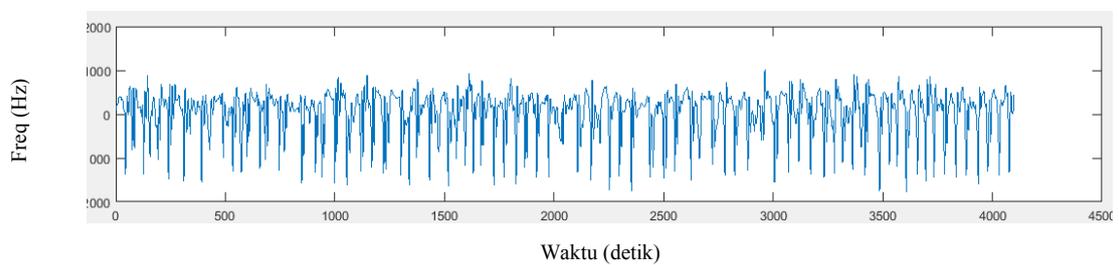
(b)



(c)



(d)



(e)

Gambar 3.3 Bentuk Gelombang Sinyal EEG untuk Set A (a), set B (b), set C (c), set D (d) dan set E (e)

dengan kondisi mata terbuka dan set B diambil saat mata tertutup . Set C-E

berasal dari arsip EEG diagnosis *presurgical* dari lima pasien dipilih, dan semua telah mencapai kontrol kejang yang lengkap, setelah reseksi dari salah satu formasi hippocampal, sehingga didiagnosis dengan benar masuk zona *epileptogenic*.

Sinyal set D direkam saat zona *epileptogenic*, dan berada pada interval tanpa kejang dan set C berasal dari pembentukan *hippocampus* pada belahan yang berlawanan dari otak. Sementara set C dan D berisi aktivitas yang hanya diukur selama interval tanpa kejang, sedangkan set E hanya berisi aktivitas kejang. Data set A - E tersebut yang digunakan dalam penelitian ini seperti Gambar 3.3.

### 3.2.2 Pengolahan Awal

Sebelum masuk kedalam proses ekstraksi fitur suatu sinyal harus terbebas dari noise sehingga karakteristiknya muncul. *Noise* yang dimaksud dapat berupa sinyal yang tidak sengaja terekam pada proses perekaman. Dalam kasus EEG epilepsi ini noise dapat berupa aktivitas pasien yang tidak sesuai dengan objek penelitian, salah satunya adalah *Electrooculography* (EOG) yang merupakan aktivitas mata yang mengeluarkan gelombang listrik yang mempengaruhi EEG. Kemunculan EOG pada EEG ditandai dengan lonjakan frekuensi pada EEG. Untuk menghilangkan EOG dan *noise* yang lain akan digunakan metode *Singular Spectrum Analysis* (SSA).

SSA merupakan sebuah metode yang digunakan untuk menganalisis data *time series*. Analisis yang dilakukan oleh SSA adalah dengan memisahkan sinyal yang dianggap noise dan sinyal yang dianggap sebagai sinyal yang asli. Pemisahan sinyal tersebut dilakukan dengan menerapkan *principal component* pada data *time series*. Dengan memanfaatkan *eigenvalue* pada *principal component* yang diterapkan pada *singlechannel time series*, data *time series* tersebut dapat direkonstruksi.

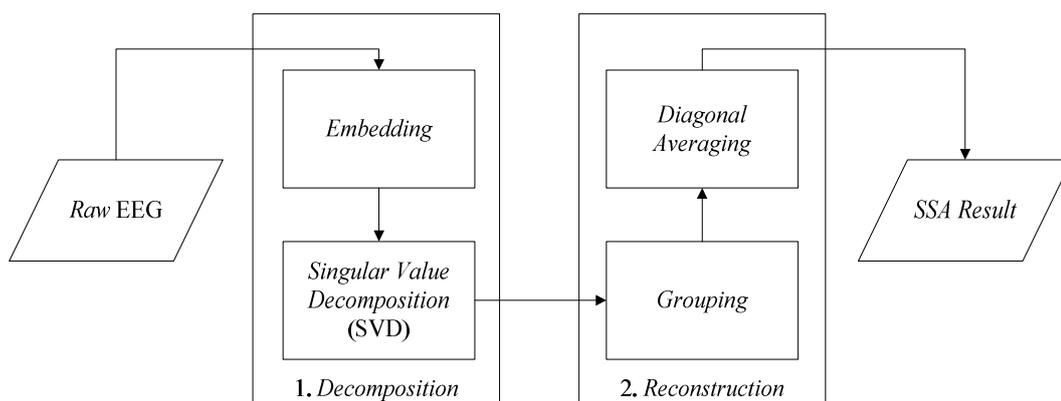
Berdasarkan nilai *eigenvalue* dari data *time series* yang ada, satu data dapat direkonstruksi menjadi beberapa data *time series* baru. Data baru yang dihasilkan nantinya akan berisi data noise dan data yang menjadi karakteristik dari data asli. Kebenaran data hasil rekonstruksi tergantung pada tepat atau tidaknya pemilihan *eigenvalue*. Untuk memilih *eigenvalue* yang sesuai diperlukan

pengamatann terhadap data yang akan kita olah. Seperti pada data *time series* pada penelitian ini yaitu sinyal EEG.

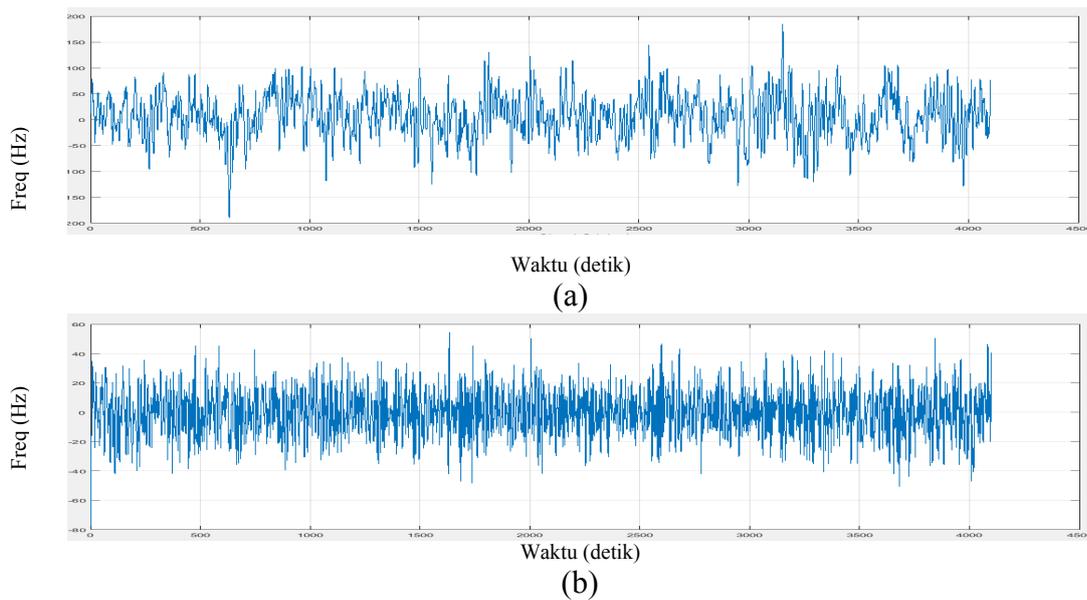
Sinyal EEG pada penelitian ini khususnya untuk kasus 5 kelas memiliki kecenderungan bercampur dengan *noise*, salah satunya EOG. Sebelum dilakukan rekonstruksi sinyal berdasarkan *eigenvalue* akan di bahas hubungan frekuensi sinyal dengan *eigenvalue*. Berdasarkan pengamatan yang dilakukan besaran *eigenvalue* mewakili besaran frekuensi dari sinyal. Dimana setiap *eigenvalue* yang paling besar mewakili fekuensi yang besar pula. Menggunakan dasar hubungan *eigenvalue* dengan nilai fekuensi yang ada dapat dihilangkan frekuensi yang dianggap kurang sesuai.

Dengan adanya indikasi sinyal EEG yang bercampur dengan sinyal EOG akan dilakukan pemilihan *eigenvalue* yang tidak mewakili *noise* tersebut. Karakteristik sinyal EOG adalah lonjakan amplitudo pada sinyal sehingga pada penelitian ini *eigenvalue* yang besar tidak akan dipakai sehingga diharapkan hasil rekonstruksi sinyal EEG setelah dilakukan SSA bebas *noise*.

Untuk menghilangkan noise dalam sinyal EEG digunakan metode SSA, terdapat 2 tahapan yang dilakukan seperti Gambar 3.4, yaitu *decomposition* dan *reconstruction*. Pertama adalah *decomposition*, dalam tahap langkah pertama adalah *embedding* ini data sinyal akan diubah dari *singlechannel* sinyal menjadi *multichannel* sinyal. Dengan memanfaatkan sinyal yang memiliki tipe *time series*



Gambar 3.4 Diagram Alur SSA



Gambar 3.5 Contoh Rekontruksi dengan SSA (a) Sinyal Asli (b) Hasil Rekonstruksi SSA

dimana data berurut berdasarkan waktu sinyal dapat dipisah berdasarkan *lagged time* atau waktu delay dari sinyal tersebut. Ide dasar dari tahap ini, untuk mencari *principal component* dengan mencoba menghitung *covariance* antara nilai  $X(t)$  dan  $X(t + k)$ , dimana  $k$  adalah jumlah delay dari sinyal tersebut. Setiap sinyal  $k$  memiliki panjang  $L$  (*window size*) dan berfungsi sebagai kolom / fitur untuk *lagged* sinyal. Panjang window  $L$  akan mempengaruhi jumlah *eigenvalue* pada tahapan selanjutnya. Menurut Hassani et al. pada 2009 ukuran dari  $L$  sebesar – besarnya dengan range  $2 \leq L \leq T/2$  dimana  $T$  adalah panjang sinyal asli. Setelah didapatkan  $k$  sinyal sinyal tersebut disatukan sehingga seolah-olah didapat *multiclass* data yang disebut *trajextory matrix* sehingga dapat kita lakukan *principal component* pada data tersebut.

Langkah kedua dari *decomposition* adalah *Singular Value Decomposition* (SVD), setelah didapatkan *trajextory matrix* dari  $X$  atau kita bisa kita labeli dengan matrix  $Y$ , selanjutnya dari matrix  $Y$  akan dicari covariannya dengan persamaan  $cov = YY'$ . Berdasarkan *covariance matrix*  $cov$  akan dihitung *eigenvalue* dan *eigenvector*-nya. *Eigenvalue* atau nilai eigen nantinya akan digunakan untuk grouping sinyal, sehingga sinyal dapat dipisahkan dari noise atau dimunculkan karakteristiknya. *Eigenvalue* akan diurutkan dari nilai yang paling

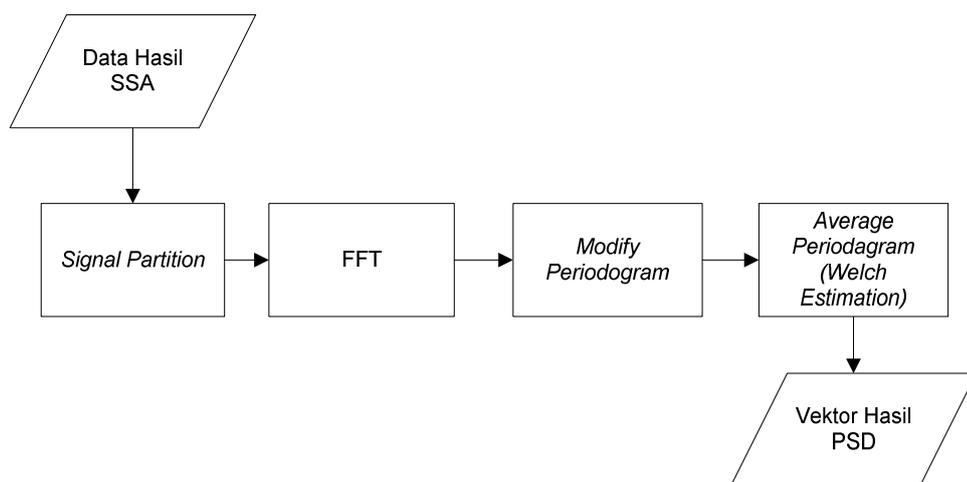
besar ke yang paling kecil ( $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_L \geq 0$ ) untuk mempermudah analisa terhadap *eigenvalue* tersebut.

Tahapan kedua dari SSA adalah *reconstruction*. Langkah pertama dari rekonstruksi adalah *grouping*, pada tahapan ini matrix Y akan ditransformasikan menjadi matrix baru berdasarkan *eigenvalue* yang dinilai mewakili karakteristik dari sinyal yang akan diujicobakan. Pemilihan group atau nilai *eigenvalue* yang dinilai sesuai dalam penelitian ini berdasarkan pengamatan hubungan *eigenvalue* dengan lonjakan sinyal dan percobaan pada tahapan klasifikasi untuk mengetahui karakteristik noise lain selain EOG.

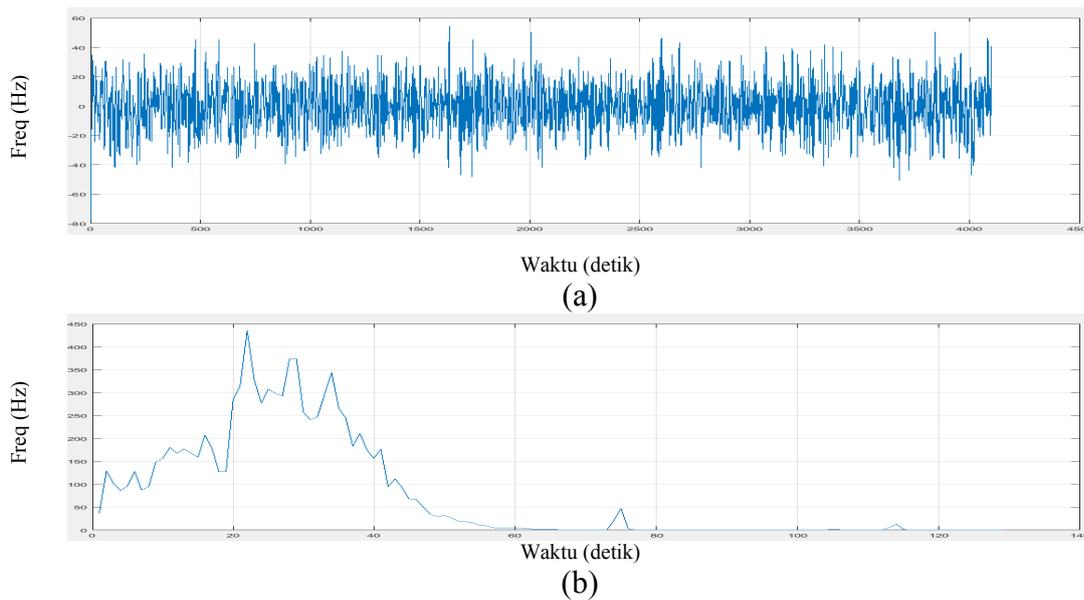
Langkah kedua dari tahapan *reconstruction* adalah *Diagonal Averaging*. *Diagonal Averaging* bertujuan untuk mengubah matrix hasil grouping menjadi single channel pada awalnya. Diharapkan data hasil rekonstruksi terbebas dari noise dan karakteristiknya dapat diklasifikaikan oleh klasifier seperti Gambar 3.5. Penggunaan SSA ini diharapkan dapat memunculkan karakteristik asli dari sinyal EEG dengan menghilangkan noise yang tercampur dalam sinyal.

### 3.2.3 Ekstraksi Fitur

Setelah didapatkan hasil dari proses SSA dilanjutkan ke ekstraksi fitur. Dalam fase ini sinyal yang akan diambil adalah spectrum frekuensi. Dengan



Gambar 3.6 Diagram Alur *Power Spectral Density*



Gambar 3.7 Contoh Ekstraksi Fitur dengan PSD, (a) Data hasil SSA (b) Hasil Ekstraksi Fitur PSD

mentransformasi sinyal dari kawasan waktu ke kawasan frekuensi akan memperoleh informasi tentang frekuensi dari sinyal tersebut. Metode untuk mendapatkan spectrum frekuensi suatu sinyal suara berdasarkan perhitungan estimasi spectrum daya adalah metode Welch (Titisari et al. 2013).

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 (Titisari et al. 2013). Alur secara keseluruhan dari PSD ini dapat dilihat di Gambar 3.5. Prosedur ekstraksi dengan PSD menggunakan fungsi **pwelch** yang telah disediakan oleh **Matlab**.

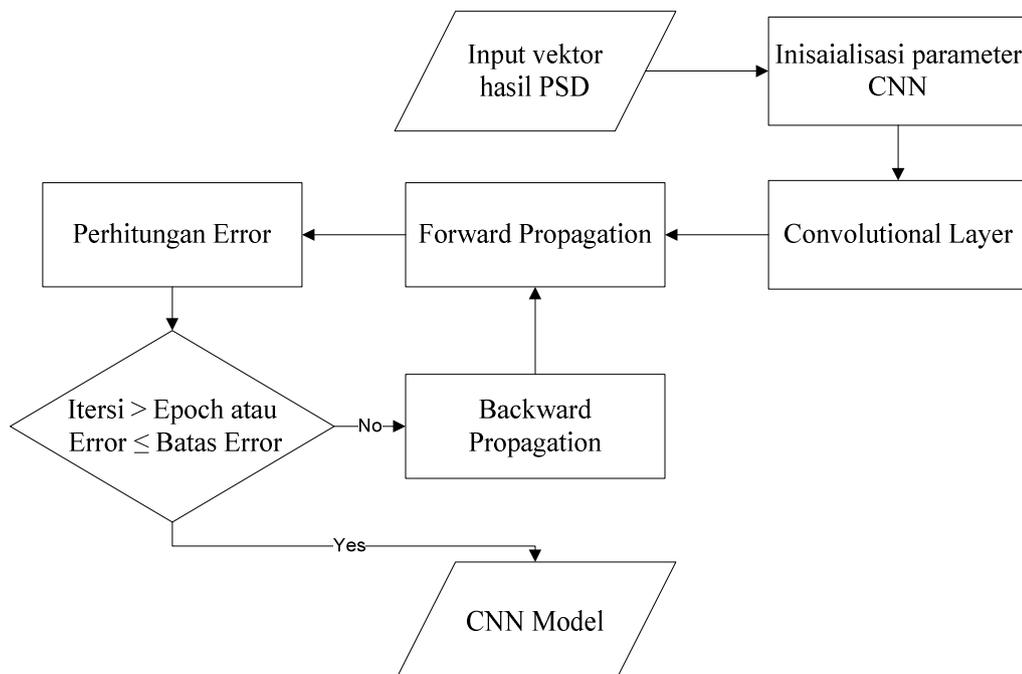
Setelah didapatkan hasil ekstraksi fitur untuk masing-masing kelompok yang akan diujikan, selanjutnya sinyal hasil PSD akan dinormalisasi untuk masing-masing sinyal. Normalisasi untuk masing-masing sinyal ini dilakukan untuk menyamakan range amplitudo sinyal dari semua kelas. Berdasarkan pengamatan hasil ekstraksi fitur antara sinyal set A-set D memiliki range yang sangat jauh

dengan set E sehingga diperlukan normalisasi. Selain perbedaan range yang mencolok normalisasi ini juga bertujuan untuk mempermudah pemfilteran sinyal pada proses klasifikasi menggunakan CNN. Sinyal EEG hasil ekstraksi fitur akan diubah *range*-nya menjadi 0,1 – 0,9. Normalisasi yang akan digunakan menggunakan persamaan 2.9.

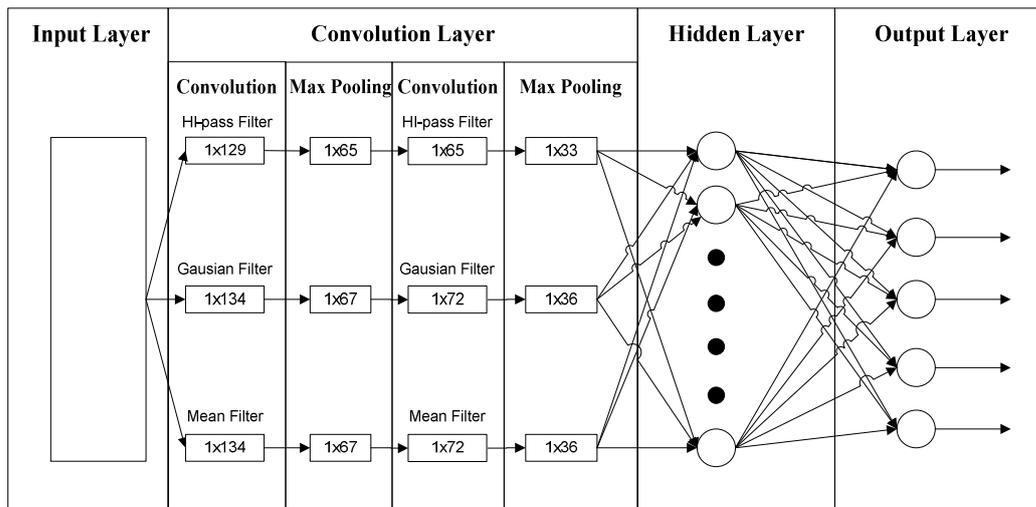
### 3.2.4 Fase Klasifikasi

Tahap ketiga dari metode penelitian adalah melakukan klasifikasi dengan menggunakan CNN. Dalam tahapannya terdapat dua tahapan utama dalam proses uji cobanya yang pertama adalah tahapan *convolution* dan yang kedua adalah *neural network*.

Pada tahapan *convolution* sinyal hasil normalisasi dari ekstraksi fitur akan di filter menggunakan dua filter, yang pertama adalah *low-pass filter* dan *high-pass filter*. *Low-pass filter* sendiri akan digunakan 2 buah filter yaitu *Gaussian filter* dan *mean filter*. Pada penelitian yang sudah dilakukan khususnya pada klasifikasi EEG epilepsi, fitur low spectrum atau fitur dengan spectrum rendah memiliki pengaruh besar dalam pengklasifikasian EEG pada kasus epilepsi.



Gambar 3.8 Diagram Alur *Convolution Neural Network*



Gambar 3.9 Arsitektur CNN

Penggunaan 2 buah *low-pass* filter bertujuan untuk menambahkan invarian parameter. Penggunaan *high-pass* ditujukan untuk menangani set E pada pengklasifikasi sinyal EEG epilepsi. Set E untuk data EEG epilepsi memiliki karakter high spectrum, dimana sinyal set E memiliki banyak lonjakan frekuensi sehingga fitur dengan spectrum yang tinggi dianggap mewakili karakter dari sinyal tersebut. Kombinasi 2 *low-pass* filter dan 1 *high-pass* filter diharapkan dapat saling melengkapi parameter EEG untuk klasifikasi CNN. Data yang diolah dalam bentuk sinyal, maka untuk masing – masing filter yang digunakan akan diaplikasikan menggunakan 1-D filter untuk convolution. Sehingga untuk setiap filter yang digunakan akan memiliki dimensi 1 x 5 untuk setiap proses pemfilteran akan menghasilkan jumlah filter yang berbeda sesuai dengan filter yang digunakan.

Filter pertama yang digunakan adalah *Low-Pass Filter* (LPF). Untuk filter ini, sinyal hasil normalisasi akan di filter menggunakan LPF untuk diambil sinyal yang memiliki spectrum yang rendah.. *Low-pass filter* yang digunakan adalah *Gaussian filter* dan *Mean filter*. *Gaussian Filter* (GF) ini digunakan untuk memfilter sinyal dari adanya perubahan nilai yang signifikan dengan meminimalisasi peningkatan dan penurunan nilai secara dratis. Filter ini ditujukan untuk menjaga bentuk dari sinyal yang akan digunakan. Filter yang kedua untuk

*low-pass filter* adalah *Mean Filter* (MF). Filter ini memfilter sinyal dengan rata – rata window filter 1x5. Filter ini digunakan untuk mengurangi lonjakan nilai dari sinyal sehingga sinyal akan lebih *smooth*.

Dimana dalam training CNN akan dilakukan 5 tahapan seperti pada Gambar 3.6. Tahapan pertama adalah inisialisasi parameter CNN yang dalam hal ini adalah bobot dan filter yang digunakan, untuk bobot pada ANN, pada awalnya akan didapat dengan cara random sedangkan untuk filter sudah ditentukan. Langkah kedua adalah *convolution layer* dimana data akan di filter dan direduksi fiturnya dengan di *pooling*. Ketiga *Forward Propagation* dimana data inputan akan diolah dengan mencari convolution layer dan pool layer dan dihitung dengan fungsi aktivasi yang digunakan.

Filter yang kedua merupakan kebalikan filter yang pertama yaitu *High-Pass Filter* (HPF) yang menahan sinyal dengan power yang rendah dan melewatkan sinyal dengan power yang tinggi. Penggunaan filter ini ditujukan untuk mempertahankan pola sinyal set-E yang memiliki lonjakan sinyal yang banyak. Setelah mendapatkan hasil dari masing–masing filter selanjutnya setiap data hasil filter tersebut akan di *pooling* dengan menggunakan *max pooling*. Dimana *max pooling* merupakan merupakan filter yang mereduksi dimensi fitur dengan cara mengambil salah satu nilai fitur dengan memilih nilai yang paling tinggi antar grid yang sudah ditentukan, dan banyaknya tetangga yang dibandingkan akan sesuai dengan window yang ditentukan di awal. Dalam penelitian ini window dari *max pooling* adalah 1x2, sehingga fitur dapat tereduksi.

Dalam penelitian ini akan dilakukan 2 kali seperti Gambar 3.7 konvolusi yang bertujuan untuk mengurangi fitur yang akan digunakan dalam proses klasifikasi dengan *neural network*. Untuk tahapan konvolusi yang kedua ini setiap hasil *pooling* dari setiap filter akan di filter ulang sesuai filter yang digunakan pertama dan akan di *pooling* lagi dengan *max pooling*. Ketiga hasil tersebut pooling layer yang kedua akan digabungkan yang nantinya akan diolah pada tahapan *neural networknya*.

Proses yang kedua adalah *neural network*, fitur hasil dari *max pooling* yang disatukan. Seperti biasa langkah dari neural network adalah *Forward Propagation* dimana data inputan adalah hasil penggabungan 3 filter yang di

pooling dan dihitung dengan fungsi aktivasi yang digunakan. Telah itu penghitungan error dengan menggunakan MAPE. Kelima apabila MAPE masih berada diatas batas atau lebih besar dari nilai yang ditentukan maka akan dilakukan proses *backpropagation* untuk mengupdate parameter yang digunakan dengan cara *gradient descent* dengan tujuan supaya *error* berkurang, apabila error lebih kecil dari batas maka iterasi akan dihentikan. Model CNN dengan nilai error terkecil yang diperoleh pada proses training akan diuji dalam proses testing untuk melihat kecakapan model terhadap data lain.

### 3.3 Pembuatan Perangkat Lunak

Pada tahap ini, dilakukan implementasi terhadap desain yang telah dirancang sebelumnya. Implementasi dilakukan menggunakan perangkat lunak Matlab R2016a dengan memanfaatkan library yang sudah tersedia. Seperti **pwelch** yang merupakan library matlab untuk mengolah data sinyal yang akan dicari power spectrum nya dengan PSD berbasis metode welch untuk ekstraksi fitur, **FIR** sebagai pembangkit sinyal yang akan digunakan sebagai filter convolusi dan **conv** merupakan library matlab yang digunakan untuk proses filter convolusi sinyal hasil ekstraksi fitur yang akan difilter dengan sinyal hasil pembangkitan **FIR**.

### 3.4 Uji coba

Pengujian performa dari pengklasifikasi dilakukan dengan menerapkan perbandingan nilai akurasi. Pada penelitian ini, pengujian klasifikasi EEG dilakukan dengan menggunakan akurasi. Data inputan kan dibagi menjadi data training dan data testing dengan perbandingan 90% *training* dan 10% *testing*. Setiap pengujian akan dianalisis dan dibandingkan apakah performa metode yang diusulkan sesuai tujuan atau tidak. Selain pengujian dan perbandingan metode akan dibahas juga pengaruh parameter yang ada pada metode yang digunakan terhadap hasil akurasi dari penelitian ini.

Untuk setiap proses *training-testing*nya akan melalui skema metode yang diujikan yaitu pengolahan awal menggunakan SSA, ekstraksi fitur menggunakan PSD dan yang terakhir klasifikasi menggunakan CNN.

### 3.5 Analisa Hasil

Pada tahap ini akan dilakukan analisis dari hasil uji coba untuk metode yang akan digunakan. Untuk mengetahui performa dari metode yang digunakan pada penelitian ini akan dilakukan dua skenario percobaan, yang pertama adalah penggabungan SSA, PSD dengan CNN dan yang kedua adalah penggabungan PSD dengan CNN. Dengan kedua skenario penelitian tersebut akan diuji coba, sehingga diharapkan dari analisis uji coba ini akan diperoleh hasil yang sesuai dengan tujuan penelitian.

Selain dua skenario utama yang akan diujikan, akan dibahas dan dianalisis pengaruh parameter-parameter yang mempengaruhi uji coba yang dilakukan. Parameter tersebut adalah pengaruh pemilihan *eigenvalue* pada SSA, penggunaan normalisasi untuk menyamakan range dari hasil dai ekstraksi fitur, dan penggunaan filter apa saja yang efektif untuk kasus EEG epilepsi ini.

*[Halaman ini sengaja dikosongkan]*

## **BAB 4**

### **HASIL DAN PEMBAHASAN**

Pada bab ini menjelaskan lingkungan uji coba, uji coba, dan evaluasi. Uji coba dibagi menjadi tiga sub bab, yaitu pengolahan awal berupa *noise filtering* pada sinyal EEG menggunakan SSA, proses ekstraksi fitur menggunakan PSD, dan klasifikasi menggunakan CNN. Hasil uji coba metode yang diusulkan juga disajikan sesuai dengan skenario pengujian yaitu uji coba pada sinyal dengan SSA dan uji coba sinyal tanpa SSA. Evaluasi dan pembahasan metode yang diusulkan berdasarkan hasil uji coba akan dipaparkan pada akhir bab ini.

#### **4.1 Lingkungan Uji Coba**

Tahap uji coba pada penelitian ini dilakukan pada perangkat keras yang menggunakan prosesor Intel® i5 2,5 GHz dan RAM dengan kapasitas sebesar 4 GB. Sedangkan perangkat lunak yang digunakan untuk mengimplementasikan metode yang diusulkan serta proses pengujian ialah Matlab R2016a.

Data yang digunakan pada tahap pengujian terdiri dari 500 data sinyal EEG yang dipilih secara acak dari Universitas Bonn. Data – data sinyal tersebut dibagi ke dalam 5 kelas data. Masing–masing kelas memiliki 100 data sinyal EEG. Data tersebut akan diolah sesuai dengan metode yang telah diusulkan, untuk masing–masing data akan di olah menggunakan SSA yang bertujuan untuk memunculkan karakteristik dan meghilangkan noise sinyal sesuai dengan kelas dari sinyal tersebut. Pemunculan karakteristik dan penghilangan noise tersebut dilakukan dengan analisis manual terhadap *eigenvalue* yang dimiliki oleh masing–masing sinyal.

Setelah proses pemunculan karakteristik dan penghilangan noise selanjutnya akan dilakukan ekstraksi fitur yaitu PSD dimana sinyal yang sudah terbebas dari noise akan dimunculkan power dari sinyal tersebut yang akan digunakan untuk fitur pada tahapan klasifikasi. Untuk tahapan klasifikasi sendiri akan digunakan CNN dengan menggunakan 2 filter, yaitu *low-pass filter*, *hi-pass filter*.

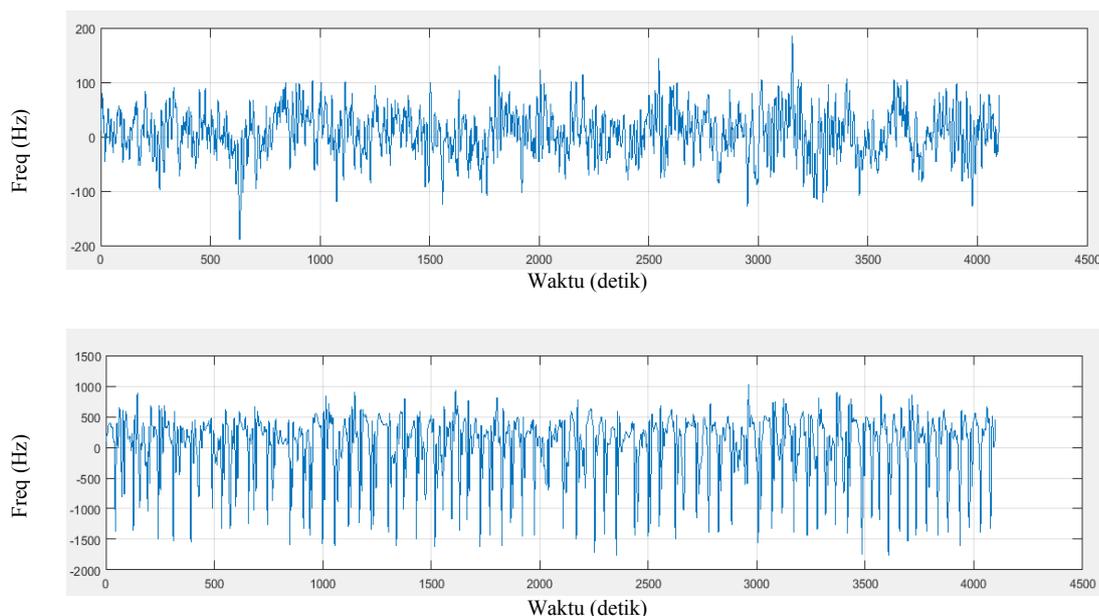
## 4.2 Pengolahan Awal

Sebelum masuk kedalam proses ekstraksi fitur tahapan paling awal dari penelitian ini adalah pengolahan awal. Pada tahap pengolahan awal ini data sinyal EEG akan diproses menggunakan *Singular Spectrum Analysis* (SSA) yang bertujuan memunculkan karakteristik dan menghilangkan noise pada sinyal EEG yang akan diolah pada penelitian ini.

Pada proses ini data inputan yang digunakan adalah data signal diskrit sebanyak 4097 data diskrit dengan file inputan berbentuk “.txt” atau text. Dan apabila ditampilkan secara visual atau di plot-kan data yang akan digunakan dalam penelitian ini akan terlihat seperti Gambar 4.1. Sinyal tersebut akan diolah menggunakan SSA, pada prinsip dasarnya SSA ini adalah merupakan metode analisis yang memanfaatkan *principal component* yang digunakan pada *singlechannel* data. Sehingga sebelum masuk ke dalam proses *principal component* diperlukan beberapa tahapan untuk *single channel* sinyal. Di dalam SSA terdapat 4 tahapan yang harus dilalui.

### 4.2.1 Embedding

Dalam tahap *embedding* ini data sinyal akan diubah dari *singlechannel* sinyal menjadi *multichannel* sinyal. Dengan memanfaatkan sinyal yang memiliki tipe *time series* dimana data berurut berdasarkan waktu sinyal dapat dipisah



Gambar 4.1 Hasil Plot atau Visualisasi Data Kelas A dan Kelas E.

berdasarkan *lagged time* atau waktu delay dari sinyal tersebut. Ide dasar dari tahap ini, untuk mencari *principal component* dengan mencoba menghitung *covariance* antara nilai  $X(t)$  dan  $X(t + k)$ , dimana  $k$  adalah jumlah delay dari sinyal tersebut. Setiap sinyal  $k$  memiliki panjang  $L$  (*window size*) dan berfungsi sebagai kolom / fitur untuk *lagged* sinyal. Panjang window  $L$  akan mempengaruhi jumlah *eigenvalue* pada tahapan selanjutnya. Menurut Hassani et al. pada 2009 ukuran dari  $L$  sebesar – besarnya dengan range  $2 \leq L \leq T/2$  dimana  $T$  adalah panjang sinyal asli. Sebagai ilustrasi ditunjukkan pada text  $X$ ,  $x_1$ ,  $x_2$  dan  $x_3$  seperti berikut :

(X) 12 22 35 45 69 74 79 78 66 43 33 36 34 38 36 28 6 -19 -38 -45 35 19  
 (x1) 12 22 35 45 69 74 79 78 66 43 33,  
 (x2) 22 35 45 69 74 79 78 66 43 33 36,  
 (x3) 35 45 69 74 79 78 66 43 33 36 34.

Dimana nilai  $x_1$ ,  $x_2$ ,  $x_3$  merupakan lagged time dari  $X$  dengan panjang  $L$  adalah 11. Dari kumpulan *lagged* sinyal tersebut akan didapatkan *trajectory matrix* dengan dimensi matrix 11 x 12 seperti Gambar 4.2. yang bisa digunakan dalam perhitungan principal component pada langkah selanjutnya.

Pada penelitian yang dilakukan untuk masing–masing data sinyal memiliki panjang 4097. Pada tahapan ini akan dibentuk matrix baru dengan panjang  $L$  atau window size sebesar 2000, sehingga akan tercipta *lagged matrix* baru sebesar 2000 x 2098.

12	22	35	45	69	74	79	78	66	43	33	36
22	35	45	69	74	79	78	66	43	33	36	34
35	45	69	74	79	78	66	43	33	36	34	38
45	69	74	79	78	66	43	33	36	34	38	36
69	74	79	78	66	43	33	36	34	38	36	28
74	79	78	66	43	33	36	34	38	36	28	6
79	78	66	43	33	36	34	38	36	28	6	-19
78	66	43	33	36	34	38	36	28	6	-19	-38
66	43	33	36	34	38	36	28	6	-19	-38	-45
43	33	36	34	38	36	28	6	-19	-38	-45	35
33	36	34	38	36	28	6	-19	-38	-45	35	19

Gambar 4.2 Ilustrasi *Trajectory Matrix X*

#### 4.2.2 Singular Value Decomposition (SVD)

Setelah didapatkan *trajectory matrix* dari X atau kita bisa kita labeli dengan matrix Y, selanjutnya dari matrix Y akan dicari covariannya dengan persamaan  $cov = YY'$  dengan hasil ilustrasi seperti Gambar 4.3. Berdasarkan *covariance matrix cov* akan dihitung *eigenvalue* dan *eigenvector*-nya. *Eigenvalue* atau nilai eigen nantinya akan digunakan untuk grouping sinyal, sehingga sinyal dapat dipisahkan dari noise atau dimunculkan karakteristiknya. *Eigenvalue* akan diurutkan dari nilai yang paling besar ke yang paling kecil ( $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_L \geq 0$ ) untuk mempermudah analisa terhadap *eigenvalue* tersebut, karena *eigenvalue* yang memiliki kedekatan nilai dianggap memiliki kemiripan karakteristik. Sebagai ilustrasi ditunjukkan pada text e1 seperti berikut :

(e1) 246861 27974 14174 10233 2409 636 252 237 83 37 29

Untuk *eigenvector* akan digunakan sebagai matrix transformasi yang digunakan untuk mentransformasikan matrix *cov* berdasarkan *eigenvalue* yang dipilih karena setiap nilai di dalam *eigenvector* berkaitan erat dengan nilai di dalam *eigenvalue* atau dapat dikatakan *eigenvector* mewakili setiap nilai *eigenvalue*. Sebagai ilustrasi nilai eigen vector dapat dilihat pada Gambar 4.4. yang merupakan nilai *eigenvector* hasil *eigenvalue* e1.

35030	34645	33162	30828	27956	24427	20594	16299	11404	8885	5032
34645	36042	35673	33966	31240	27332	22893	18354	13833	11802	9015
33162	35673	37002	36271	34040	29950	24982	19711	14928	13711	11578
30828	33966	36271	37073	35704	31841	26676	20849	15361	13878	12890
27956	31240	34040	35704	35832	32767	27979	22057	16079	13371	12475
24427	27332	29950	31841	32767	31107	27547	22300	16405	11735	10518
20594	22893	24982	26676	27979	27547	25992	22423	17383	10856	8192
16299	18354	19711	20849	22057	22300	22423	21195	17971	10839	6737
11404	13833	14928	15361	16079	16405	17383	17971	17136	11248	6630
8885	11802	13711	13878	13371	11735	10856	10839	11248	14005	9075
5032	9015	11578	12890	12475	10518	8192	6737	6630	9075	12517

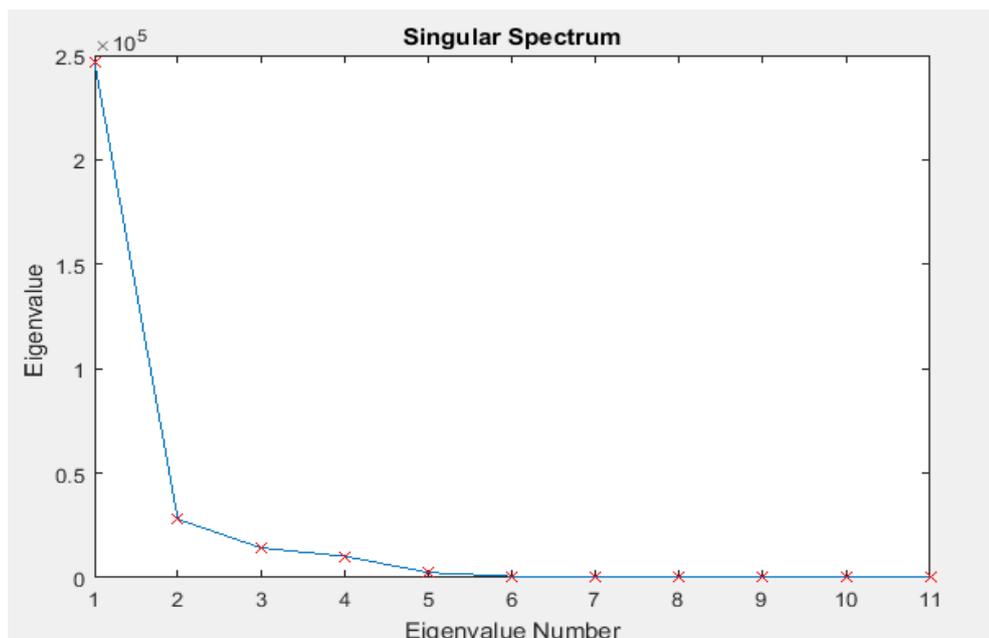
Gambar 4.3 Ilustrasi Matrix Covariance  $YY'$

0,3285	0,485	0,224	0,300	0,052	0,463	-0,185	-0,174	-0,285	-0,392	-0,024
0,3581	0,356	-0,001	0,255	0,213	0,022	0,396	-0,019	0,535	0,428	-0,088
0,3762	0,228	-0,158	0,067	0,001	-0,432	0,002	0,571	-0,463	0,119	0,190
0,3801	0,096	-0,194	-0,195	-0,084	-0,380	-0,594	-0,214	0,420	-0,211	-0,019
0,3711	-0,050	-0,090	-0,374	-0,214	-0,052	0,274	-0,556	-0,409	0,251	-0,222
0,3396	-0,166	0,103	-0,393	-0,129	0,183	0,423	0,193	0,230	-0,441	0,423
0,2978	-0,292	0,294	-0,193	-0,017	0,275	-0,217	0,446	0,050	0,136	-0,600
0,2465	-0,389	0,338	0,147	0,156	0,116	-0,311	-0,166	-0,062	0,419	0,558
0,1909	-0,437	0,185	0,442	0,280	-0,419	0,238	-0,154	-0,052	-0,388	-0,237
0,1533	-0,275	-0,418	0,500	-0,649	0,215	0,005	0,048	0,070	0,024	0,006
0,1242	-0,210	-0,677	-0,070	0,598	0,327	-0,051	0,013	-0,084	-0,051	-0,003

Gambar 4.4 Ilustrasi *Eigenvector* dari *Matrix Y*

### 4.2.3 Grouping

Pada tahapan ini matrix *Y* akan ditransformasikan menjadi matrix baru berdasarkan *eigenvalue* yang dinilai mewakili karakteristik dari sinyal yang akan diujicobakan. Pemilihan group atau nilai *eigenvalue* yang dinilai sesuai dalam penelitian ini berdasarkan pengamatan *eigenvalue* dan percobaan pada tahapan klasifikasi. Berdasarkan pengamatan pada nilai *eigen* terdapat beberapa kelompok nilai *eigen* seperti pada Gambar 4.5. Dimana pada Gambar 4.5 terdapat 3 kelompok nilai *eigen*, yaitu kelompok yang pertama nilai *eigen* pertama yang memiliki nilai paling tinggi, yang kedua nilai *eigen* kedua sampai ke empat yang



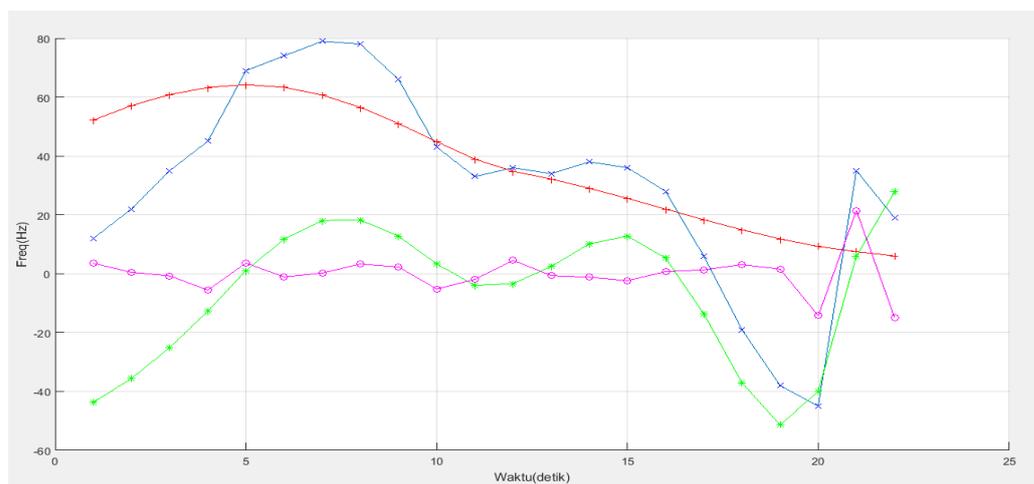
Gambar 4.5 Ilustrasi Plot *Eigenvalue* dari *Matrix Y*

memiliki nilai berdekatan cenderung ditengah, dan yang terakhir adalah kelompok nilai *eigen* yang terendah. Dari ketiga kelompok tersebut masing–masing dapat digunakan untuk mentransformasikan *matrix* Y sesuai dengan karakteristik kelas sinyal tersebut. Dengan berdasarkan kelompok *eigenvalue* dapat digunakan *eigenvector* yang berkaitan dengan kelompok *eigenvalue*.

Pada penelitian yang dilakukan beberapa uji coba dalam pengelompokan *eigenvalue*. Dengan nilai L atau *window size* sebesar 2000 dilakukan uji coba untuk *eigenvalue* ke =1, 1-100, 100-200, 200-1000, 1000-2000, 1-500, 500-1000, 1000-1500, 1500-2000. Berdasarkan 9 kelompok tersebut akan dilihat hasilnya dalam tahapan klasifikasi.

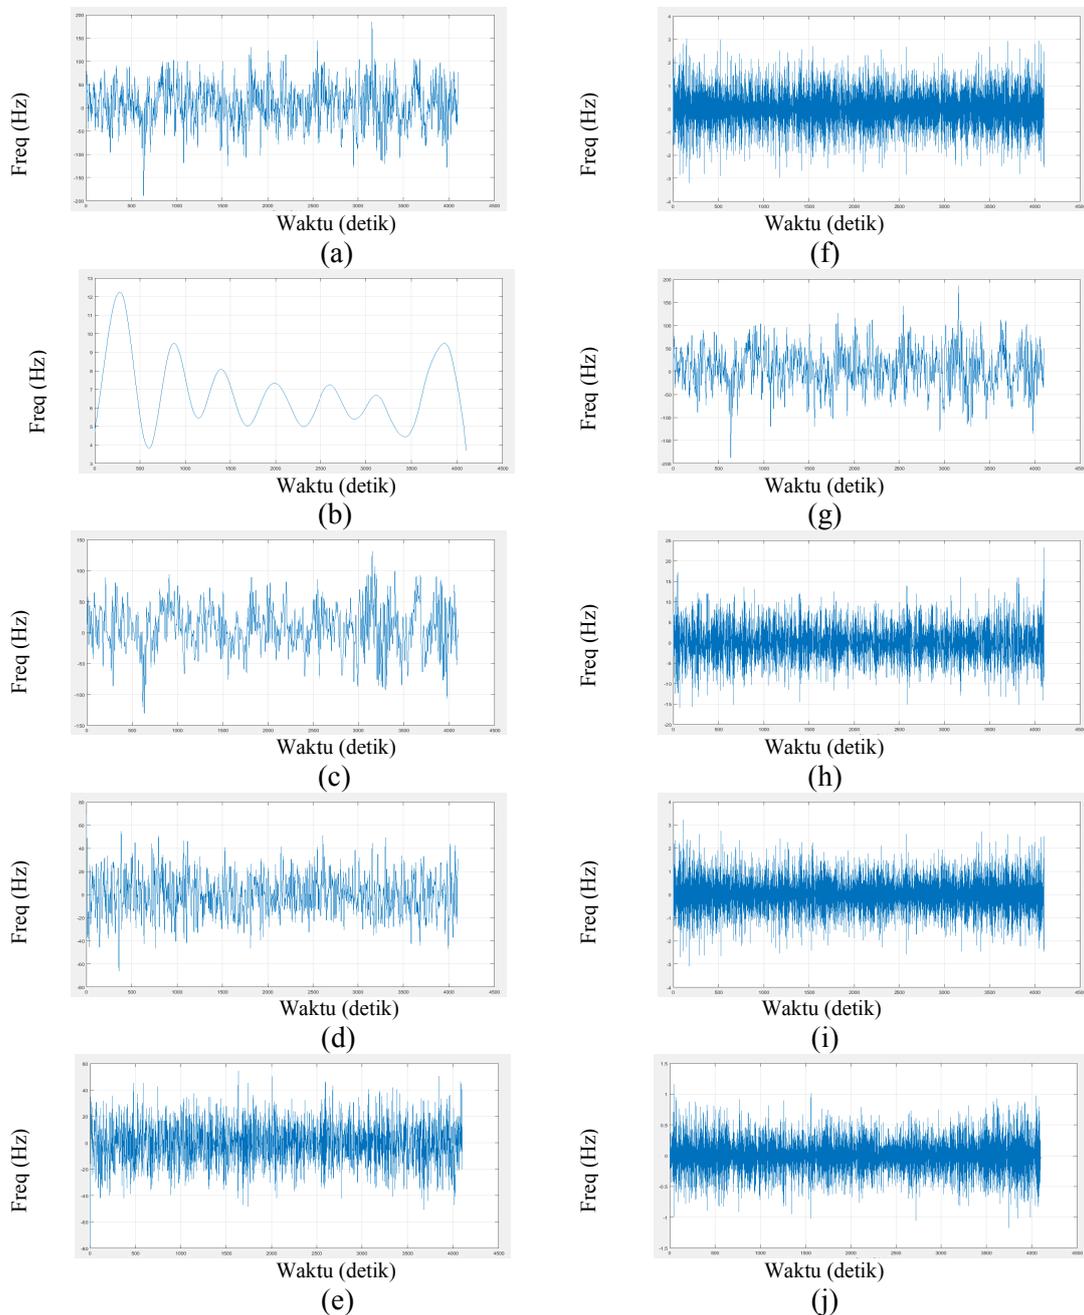
#### 4.2.4 *Diagonal Averaging*

*Matrix* hasil dari transformasi *matrix* Y dengan *eigenvector* berdasarkan kelompok *eigenvalue* akan dikembalikan ke form dasarnya seperti sinyal inputan Seperti Gambar 4.6.a merupakan hasil plot untuk contoh data inputan A1 yang di rekonstruksi ulang berdasarkan kelompok *eigenvalue* berdasarkan Gambar 4.5. yang telah dikelompokkan menjadi 3 kelompok. Gambar 4.6.b merupakan hasil



Gambar 4.6 Ilustrasi Plot Rekonstruksi Sebagian Sinyal EEG, garis biru Contoh Sebagian Sinyal Inputan EEG plot data A1, garis merah Hasil Rekonstruksi Sinyal A1 dengan *Eigenvalue* 1, garis hijau Hasil Rekonstruksi Sinyal A1 dengan *Eigenvalue* 2-4, garis magenta Hasil Rekonstruksi Sinyal A1 dengan *Eigenvalue* 5-11

rekonstruksi sinyal dengan kelompok *eigenvalue* 1, Gambar 4.6.c kelompok *eigenvalue* 2-4, dan Gambar 4.6.d kelompok *eigenvalue* 5-11. Hasil rekonstruksi sinyal EEG pada penelitian ini dapat dilihat pada Gambar 4.7 dengan 9 kelompok



Gambar 4.7 Plot Rekonstruksi Sinyal EEG (a) Sample sinyal EEG kelas A, dan Sinyal Hasil Rekonstruksi Sinyal dengan (b) *Eigenvalue* 1, (c) *Eigenvalue* 1-100, (d) *Eigenvalue* 100-200, (e) *Eigenvalue* 200-1000, (f) *Eigenvalue* 1000-2000, (g) *Eigenvalue* 1-500, (h) *Eigenvalue* 500-1000, (i) *Eigenvalue* 1000-1500, (j) *Eigenvalue* 1500-2000.

*eigenvalue* yang akan diujikan.

### 4.3 Ekstraksi Fitur

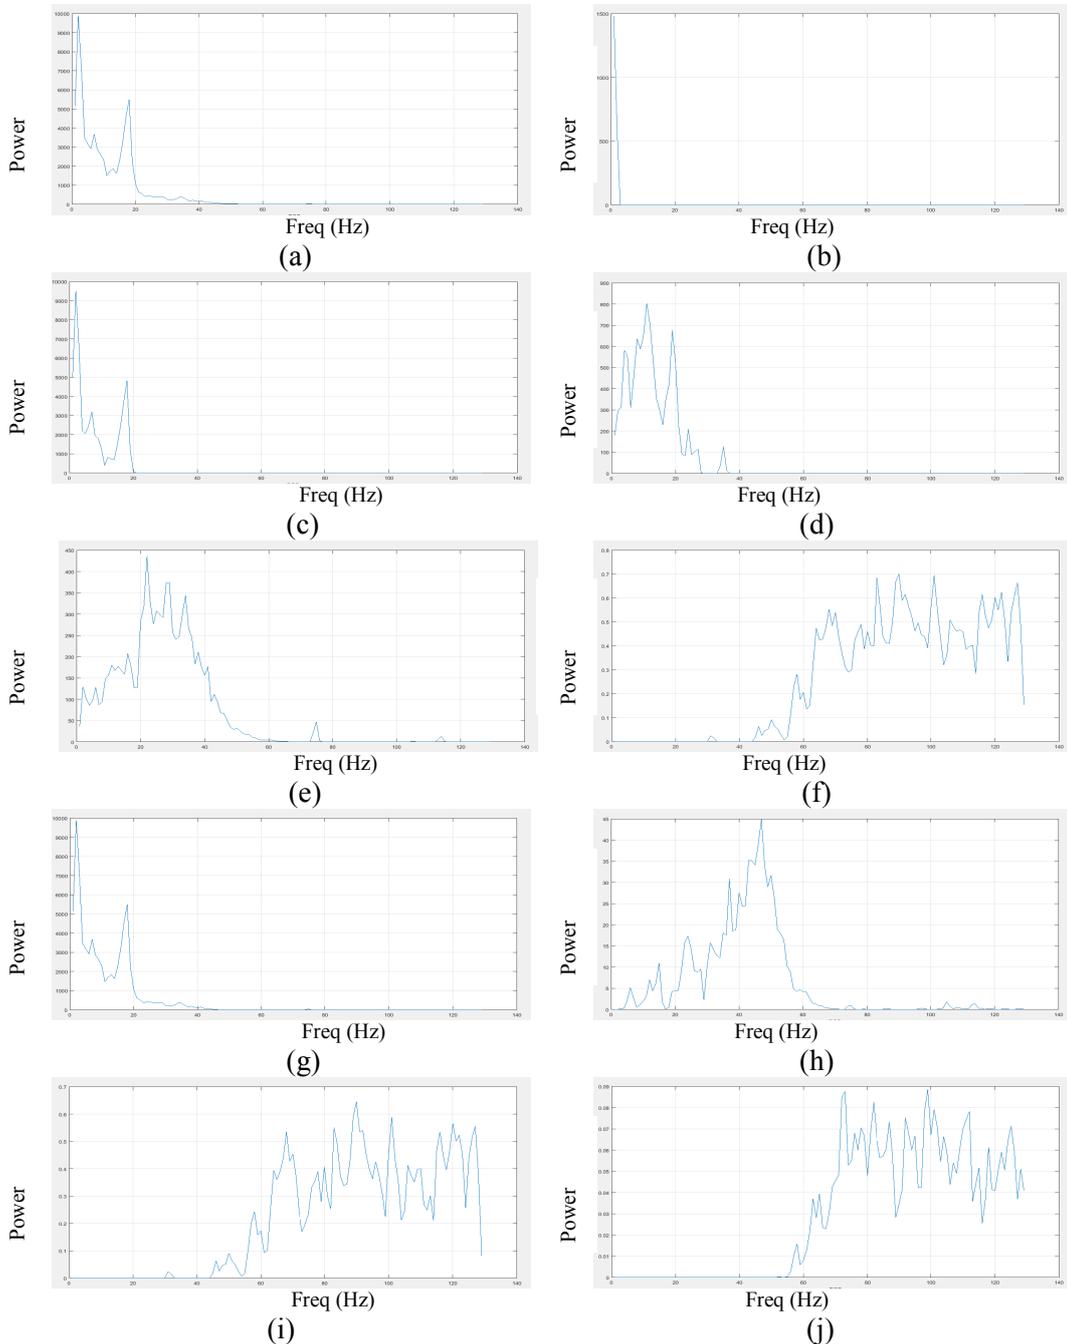
Proses ekstraksi fitur dilakukan terhadap data sinyal EEG yang telah diolah menggunakan SSA. Proses ekstraksi fitur pada data tersebut menggunakan *Power Spectral Density* (PSD) dengan *window size* 256 dengan overlapping 50%. Prosedur ekstraksi dengan PSD menggunakan fungsi **pwelch** yang telah disediakan oleh **Matlab**. PSD yang digunakan adalah PSD yang berbasis metode *welch*. Hasil ekstraksi fitur dengan menggunakan PSD akan menghasilkan 129 fitur power dari sinyal hasil pengolahan awal SSA. Contoh hasil ekstraksi fitur untuk sinyal yang diolah menggunakan SSA berdasarkan *eigenvalue*-nya dapat dilihat pada Gambar 4.8.

Setelah didapatkan hasil ekstraksi fitur untuk masing–masing kelompok yang akan diujikan, selanjutnya sinyal hasil PSD akan dinormalisasi untuk masing–masing sinyal. Normalisasi untuk masing–masing sinyal ini dilakukan untuk menyamakan range sinyal dari semua kelas. Berdasarkan pengamatan hasil ekstraksi fitur antara sinyal set A – set D memiliki range yang sangat jauh dengan set E sehingga diperlukan normalisasi. Selain perbedaan range yang mencolok normalisasi ini juga bertujuan untuk mempermudah pemfilteran sinyal pada proses klasifikasi menggunakan CNN. Sinyal EEG hasil ekstraksi fitur akan diubah *range*-nya menjadi 0,1 – 0,9. Normalisasi yang akan digunakan menggunakan persamaan 2.9.

### 4.4 Klasifikasi

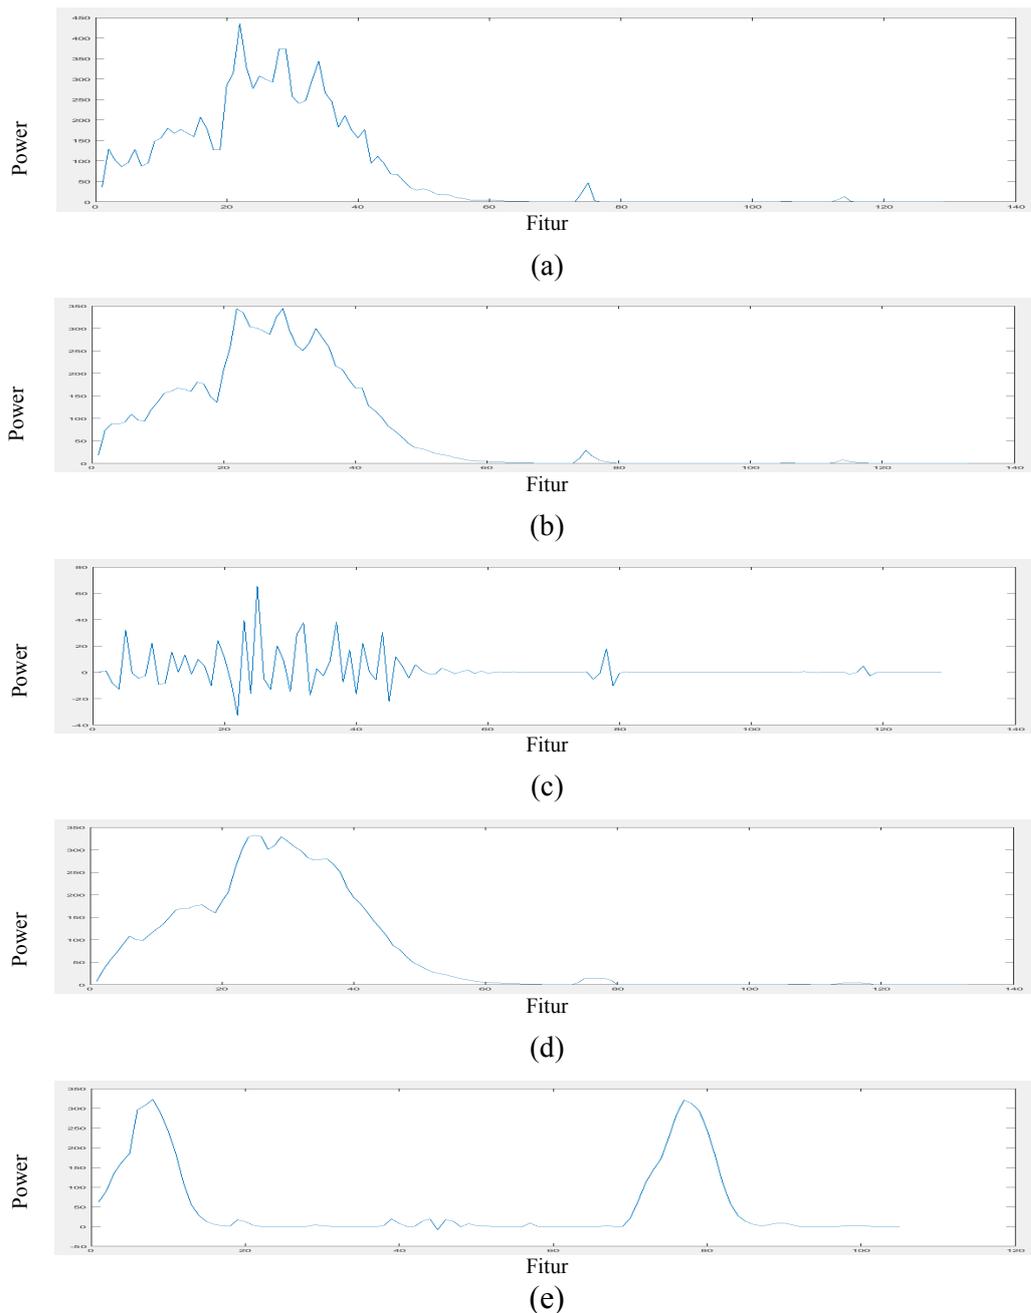
Klasifikasi pada penelitian ini akan menggunakan *Convolution Nerural Network* (CNN). Dalam tahapannya terdapat dua tahapan utama dalam proses uji cobanya yang pertama adalah tahapan *convolution* dan yang kedua adalah *neural network*. Pada tahapan *convlution* sinyal hasil ekstraksi fitur akan di filter menggunakan dua filter, yang pertama adalah *low-pass* filter dan *hi-pass* filter. *Low – pass* filter sendiri akan digunakan 2 buah filter yaitu *Gaussian* filter dan *mean* filter. Pada penelitian yang sudah dilakukan khususnya pada klasifikasi EEG epilepsi, fitur *low spectrum* atau fitur dengan *spectrum* rendah memiliki

pengaruh besar dalam pengklasifikasian EEG pada kasus epilepsi. Penggunaan 2 buah *low-pass* filter bertujuan untuk menambahkan invarian parameter.



Gambar 4.8 Plot Hasil Ekstraksi Fitur Sinyal EEG (a) Sample sinyal EEG kelas A, dan Sinyal Hasil Ekstraksi Fitur Menurut Kelompok SSA dengan (b) *Eigenvalue* 1, (c) *Eigenvalue* 1-100, (d) *Eigenvalue* 100-200, (e) *Eigenvalue* 200-1000, (f) *Eigenvalue* 1000-2000, (g) *Eigenvalue* 1-500, (h) *Eigenvalue* 500-1000, (i) *Eigenvalue* 1000-1500, (j) *Eigenvalue* 1500-2000.

Penggunaan high-pass ditujukan untuk menangani set E pada pengklasifikasi sinyal EEG epilepsi. Set E untuk data EEG epilepsi memiliki karakter *high spectrum*, dimana fitur *spectrum* yang tinggi dianggap mewakili karakter dari sinyal. Kombinasi 2 *low-pass* filter dan 1 *high-pass* filter diharapkan dapat saling melengkapi parameter EEG untuk klasifikasi CNN. Data



Gambar 4.9 *Filter Result*, (a) Sinyal Hasil Ekstraksi Fitur, (b) Sinyal hasil LPF, (c) Sinyal hasil HPF, (d) Sinyal hasil MF, (e) Full connected dari 3 filter

yang diolah dalam bentuk sinyal, maka untuk masing-masing filter yang digunakan akan diaplikasikan menggunakan 1-D filter untuk *convolution*. Sehingga untuk setiap filter yang digunakan akan memiliki dimensi 1 x 5 untuk setiap proses pemfilteran akan menghasilkan jumlah filter yang berbeda sesuai dengan filter yang digunakan.

Filter pertama yang digunakan adalah *Low-Pass Filter* (LPF). Untuk filter ini, sinyal hasil normalisasi akan di filter menggunakan LPF untuk diambil sinyal yang memiliki power yang rendah. Untuk kasus EEG yang diujikan setelah sinyal di ekstraksi fiturnya dengan banyak fitur 129 akan di filter dengan LPF menjadi 134 fitur. *Low-pass* filter yang digunakan adalah *Gaussian* filter dan *Mean* filter. *Gaussian Filter* (GF) ini digunakan untuk memfilter sinyal dari adanya perubahan nilai yang signifikan dengan meminimalisasi peningkatan dan penurunan nilai secara dratis. Filter ini ditujukan untuk menjaga bentuk dari sinyal yang akan digunakan. Contoh *Gaussian Filter* (GF) dapat dilihat pada Gambar 4.9.(b). Filter yang kedua untuk low-pass filter adalah *Mean Filter* (MF). Filter ini memfilter sinyal dengan rata-rata window filter 1x5. Filter ini digunakan untuk mengurangi lonjakan nilai dari sinyal sehingga sinyal akan lebih *smooth*. Dengan menggunakan filter ini sinyal hasil convolusi akan menjadi 134 fitur, untuk contoh dapat dilihat pada Gambar 4.9.(d). Filter yang kedua merupakan kebalikan filter yang pertama yaitu *High-Pass Filter* (HPF) yang menahan sinyal dengan power yang rendah dan melewatkan sinyal dengan power yang tinggi. Penggunaan filter ini ditujukan untuk mempertahankan pola sinyal set – E yang memiliki lonjakan sinyal yang banyak. Dengan menggunakan filter ini sinyal hasil convolusi akan tetap pada 129 fitur, untuk contoh dapat dilihat pada Gambar 4.9.(c).

Setelah mendapatkan hasil dari masing-masing filter selanjutnya setiap data hasil filter tersebut akan di *pooling* dengan menggunakan *max pooling*. Dimana *max pooling* merupakan merupakan filter yang mereduksi dimensi fitur dengan cara mengambil salah satu nilai fitur dengan memilih nilai yang paling tinggi antar tetangganya, dan banyaknya tetangga yang dibandingkan akan sesuai dengan window yang ditentukan di awal. Dalam penelitian ini window dari max pooling adalah 1x2, sehingga setelah di filter hasil dari masing-masing filter yang

dipakai fiturnya akan berkurang setengah. GF dari 134 menjadi 67, HPF dari 129 menjadi 65, dan MF dari 134 menjadi 67.

Dalam penelitian ini akan dilakukan 2 kali convolusi yang bertujuan untuk mengurangi fitur yang akan digunakan dalam proses klasifikasi dengan *neural network*. Untuk tahapan convolusi yang kedua ini setiap hasil pooling dari setiap filter akan di filter ulang sesuai filter yang digunakan pertama dan akan di *pooling* lagi dengan *max pooling*. Untuk masing-masing filter akan tereduksi filternya untuk GF menjadi 36, HPF menjadi 33, dan MF menjadi 36. Ketiga hasil tersebut akan digabungkan menjadi 105 fitur seperti Gambar 4.9.(e) yang nantinya akan diolah pada tahapan *neural network*nya.

Pada tahapan *neural network* prinsip kerjanya akan sama dengan *Multi Layer Perceptron* (MLP) pada umumnya. Untuk penggunaan neural network pada penelitian ini akan menggunakan aplikasi yang telah tersedia. Dengan 105 data hasil konvolusi akan diolah dengan *epoch* sebanyak 500 dengan *learning rate* 0,3 dengan struktur MLP note pada *input layer* adalah 105 dengan 1 *hidden layer* dengan 60 note dan *output layer* nya terdapat 5 note.

## 4.5 Evaluasi

Sesuai dengan tujuan penelitian ini yaitu menghasilkan sistem klasifikasi sinyal EEG menggunakan *Singular Spectrum Analysis* (SSA), *Power Spectral Density* (PSD), dan *Convolution Neural Network* (CNN) dengan mengevaluasi tingkat akurasi dari usulan metode tersebut . Evaluasi dilakukan dengan membandingkan hasil uji coba dengan metode yang sudah ada yaitu *Power Spectral Density* (PSD), dan *Convolution Neural Network* (CNN).

### 4.5.1 Hubungan Pemilihan *Eigenvalue* dengan Tingkat Akurasi

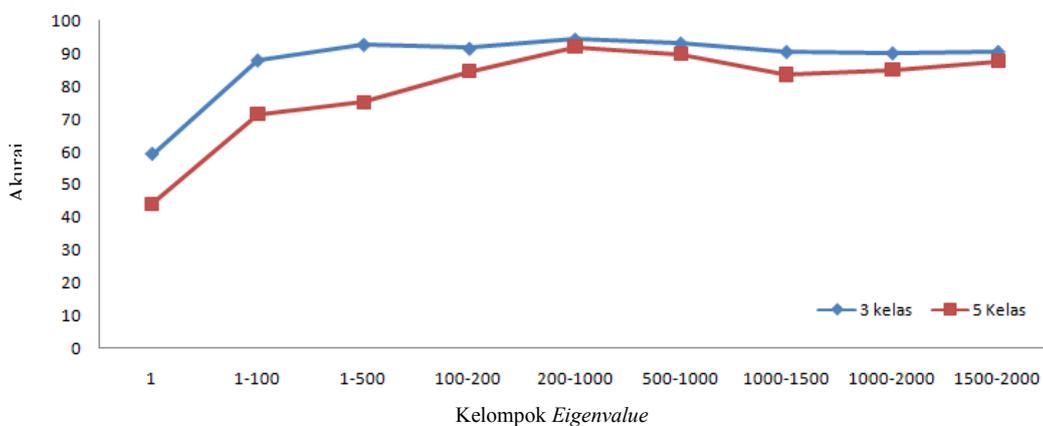
Dalam penerapan *Singular Spectrum Analysis* (SSA), pemilihan *eigenvalue* merupakan hal yang penting karena sangat mempengaruhi hasil akurasi pada proses klasifikasi. Dalam penelitian ini dalam penentuan *eigenvalue* akan dilakukan 9 uji coba berdasarkan pengamatan dan *trial error*. Sembilan uji coba tersebut akan dilakukan pada kelompok *eigenvalue* ke - 1, 1-100, 100-200, 200-1000, 1000-2000, 1-500, 500-1000, 1000-1500, 1500-2000. Penentuan

kelompok *eigenvalue* ditentukan berdasarkan besarnya *eigenvalue*, dimana untuk masing–masing sinyal inputan memiliki 2000 *eigenvalue* dan dikelompokkan berdasarkan besaran nilai tersebut.

Hasil pengujian data terhadap kelompok *eigenvalue* ditunjukkan pada Tabel 4.1. dengan grafik pada Gambar 4.11. Pada Tabel 4.1 dan Gambar 4.11 dapat terlihat hasil untuk setiap kelompok *eigenvalue* dengan 2 kelas uji Coba dan

Tabel 4.1 Hasil Uji Coba Kelompok *Eigenvalue*

Kelompok <i>Eigenvalue</i>	Akurasi (Kelas)	
	3(%)	5(%)
1	59,2	44,2
1-100	88	71,6
1-500	92,8	75,2
100-200	91,6	84,6
200-1000	94,4	92
500-1000	93,2	89,8
1000-1500	90,6	83,5
1000-2000	90,2	85
1500-2000	90,6	87,6



Gambar 4.10 Grafik Uji Coba *Eigenvalue*

5 kelas uji coba. Dari percobaan yang dilakukan dalam kasus sinyal *processing* pada EEG ini nilai *eigenvalue* yang paling besar tidak menghasilkan nilai akurasi yang baik, hal ini terjadi karena nilai *eigenvalue* pada sinyal EEG mewakili amplitudo yang terdapat pada sinyal, sedangkan pada kasus EEG lonjakan amplitudo pada saat perekaman. Sehingga pada percobaan dapat dilihat bahwa sinyal yang masih menggunakan *eigenvalue* pertama atau terbesar seperti *eigenvalue* ke – 1, 1-100, 1-500 memiliki tingkat akurasi yang kurang baik untuk 5 kelas.

Tabel 4.2 Rata – rata kelompok *eigenvalue*

Kelompok <i>Eigenvalue</i>	Akurasi ( kelas )	
	3(%)	5(%)
K1	79,6	66,8
K2	93,8	90,9
K3	90,46	85,3

Pada kasus EEG untuk dataset Universitas Bonn yang digunakan pada penelitian ini kelompok *eigenvalue* yang paling bagus berdasarkan percobaan yang dilakukan adalah pada *eigenvalue* ke 200 – 1000. Berdasarkan percobaan yang dilakukan untuk dataset EEG epilepsi, nilai *eigenvalue* yang tepat digunakan atau yang paling sesuai adalah *eigenvalue* dari 200 – 1000. Penentuan *eigenvalue* yang digunakan untuk kasus ini dapat dipilih nilai yang berada pada range tengah seperti misal pada hasil terbaik yaitu 200 – 1000. Menurut percobaan dan pengamatan yang dilakukan *eigenvalue* pada range awal menyimpan informasi lonjakan amplitudo yang disebabkan oleh lonjakan amplitudo dan range akhir memiliki keenderungan menyimpan informasi *noise* dari sinyal yang telah didapat. Seperti pada percobaan yang dilakukan misalkan kita bagi menjadi 3 kelompok hasil yaitu K1, K2, dan K3 yang merupakan hasil rata – rata akurasi kelompok *eigenvalue* seperti Tabel 4.2. Kelompok K 1 berisi kelompok *eigenvalue* 1, 1 – 100, dan 100 – 200; K2 berisi kelompok *eigenvalue* 200 – 1000

dan 500 – 1000; dan yang terakhir K3 merupakan kelompok *eigenvalue* 1000 – 1500, 1500 – 2000, dan 1000 – 2000.

#### 4.5.2 Hubungan Normalisasi dengan Tingkat Akurasi

Setelah melakukan pengamatan pada penelitian ini, hasil sinyal dari ekstraksi fitur memiliki tingkat range power berbeda-beda. Perbedaan range tersebut sangat mempengaruhi hasil dari klasifikasi yang dilakukan. Untuk mengatasi perbedaan range tersebut dilakukan normalisasi. Normalisasi yang dilakukan dengan cara mengubah range setiap sinyal yang akan diuji. Sehingga setiap sinyal yang akan diolah memiliki nilai minimal dan nilai maksimal yang sama.

Tabel 4.3 Hasil Skema Normalisasi

No	Skema	Akurasi(%)
1.	Tanpa Normalisasi	85,4
2.	Normalisasi	92

Dengan range yang sama tersebut karakteristik sinyal dari masing–masing kelas akan lebih terlihat dari pola masing–masing sinyal dan tidak terpengaruh oleh perbedaan nilai yang besar untuk masing–masing sinyal. Seperti pada Tabel 4.2 yang merupakan perbedaan pengolahan sinyal antara yang menggunakan sinyal dan tidak pada kelompok *eigenvalue* terbaik untuk 5 kelas.

#### 4.5.3 Hubungan Filter pada CNN dengan Tingkat Akurasi

Dalam proses klasifikasi menggunakan *Convolution Neural Network* (CNN) terdapat tahapan convolusi. Pada tahapan convolusi ini akan digunakan filter untuk mengolah data sinyal hasil ekstraksi fitur. Pada penelitian ini akan digunakan 3 filter, yaitu *Gaussian Filter*, *High-Pass Filter*, dan *Mean Filter*.

Tabel 4.4 Uji Coba Filter CNN

No	Filter	Akurasi
1.	<i>Gaussian Filter</i> (GF)	90
2.	<i>High – Pass Filter</i> (HPF)	80,4
3.	<i>Mean Filter</i> (MF)	88
4.	GF + HPF	90,8
5.	GF + MF	88,8
6.	HPF + MF	90
7.	GF + HPF +MF	92

Dengan ketiga filter tersebut akan diuji coba untuk hasil dari masing–masing filter kombinasi dua filter dan kombinasi ketiganya dengan membandingkan hasil dari klasifikasi. Hasil akurasi dari uji coba filter diambil dari kelompok *eigenvalue* terbaik yaitu ke 200 – 1000 untuk 5 kelas.

Berdasarkan uji coba filter untuk CNN dengan hasil seperti Tabel 4.3, untuk masing–masing filter *Gaussian Filter* memiliki tingkat akurasi yang paling tinggi. berdasarkan tujuan digunakan filter ini, bentuk dari sinyal hasil ekstraksi fitur merupakan parameter paling mempengaruhi hasil dari klasifikasi, dengan ini bisa dikatakan bentuk sinyal dapat digunakan untuk membedakan karakteristik sinyal untuk sinyal EEG epilepsi dibandingkan 2 filter lainnya.

Untuk uji coba gabungan 2 filter hasil paling bagus adalah gabungan antara *Gaussian Filter* dan *High-Pass Filter* dengan 90,8 %. Penggabungan 2 filter tersebut menjadi paling bagus dikarenakan parameter hasil *High-Pass Filter* dapat menutupi kekurangan dari parameter *Gaussian Filter* untuk lonjakan power pada inyal hasil ekstraksi fitur, karena parameter hasil *High-Pass Filter* dapat digunakan untuk mengklasifikasikan inyal EEG set – E dengan kelas yang lainnya.

Pada Tabel 4.4 hasil akurasi terbaik adalah hasil dari semua kombinasi ketiga filter yang digunakan. Kombinasi ketiganya saling menutupi kekurangan filter yang lain sesuai dengan tujuan digunakan filter tersebut . Berdasarkan hasil dari percobaan filter convolusi dalam penelitian ini akan digunakan tiga filter

dalam convolution layer yaitu *Gaussian Filter* , *High-Pass Filter*, dan *Mean Filter*.

Tabel 4.5 Uji Coba Skenario

No.	Skenario	Akurasi (Kelas)	
		3(%)	5(%)
1.	SSA, PSD, CNN	94,4	92
2.	PSD, CNN	93,2	78,6

#### 4.5.4 Evaluasi dan Analisis Hasil Akurasi

Dalam penelitian ini akan dilakukan 2 skenario percobaan untuk mengetahui hasil dari gabungan metode yang dihasilkan yaitu SSA, PSD, dan CNN dibandingkan dengan PSD dan CNN. Dari hasil percobaan kedua skenario tersebut membuktikan bahwa SSA, PSD dan CNN memiliki akurasi yang lebih baik untuk 2 kelas percobaan yaitu untuk 5 kelas dan 3 kelas seperti Tabel 4.5.

Tabel 4.6 Confusion Matrix PSD dan CNN Untuk 3 Kelas

Aktual	Prediksi		
	Set AB	Set CD	Set E
Set AB	188	10	2
Set CD	11	186	3
Set E	3	5	92

Pada Tabel 4.5 terdapat nilai akurasi hasil percobaan metode yang diusulkan dengan metode yang dikembangkan. Kedua skenario yang diujikan dengan menggunakan parameter yang sama untuk parameter pada PSD dan CNN, sesuai dengan pembahasan sebelumnya. Sehingga dapat dibuktikan bahwa penambahan SSA untuk memunculkan karakteristik dari sinyal EEG epilepsi akan menghasilkan akurasi yang lebih baik.

Untuk kasus 3 kelas EEG metode yang diusulkan berhasil melakukan klasifikasi dengan akurasi 94,4 % lebih baik sebesar 1,2 % daripada metode sebelumnya 93,2 %. Sedangkan untuk kasus 5 kelas metode usulan memiliki nilai akurasi 92 % meningkat sebesar 13,4 % dari metode sebelumnya 78,6 %.

Tabel 4.7 Confusion Matrix SSA, PSD, dan CNN Untuk 3 Kelas

Aktual	Prediksi		
	Set AB	Set CD	Set E
Set AB	197	3	0
Set CD	3	187	10
Set E	0	12	88

Untuk 5 kelas EEG metode usulan memiliki selisih akurasi yang cukup signifikan dibandingkan dengan sebelumnya berbeda dengan hasil pengklasifikasian 3 kelas yang memiliki perubahan yang tidak signifikan. Hal ini dapat terjadi karena terjadi perbedaan karakteristik dalam pengklasifikasian 3 kelas dan 5 kelas.

Pada 3 kelas antara set AB, set CD dan E memiliki perbedaan karakteristik yang cukup mencolok sehingga tanpa SSA, klassifier dapat mengklasifikasikannya dengan baik. Pada Tabel 4.6 merupakan confusion matrix dari metode yang diprbaiki yaitu gabungan PSD dengan CNN dan Tabel 4.7 merupakan confussion matrix dari metode yang diusulkan yaitu penggabungan SSA, PSD dengan CNN, kedua tabel tersebut merupakan hasil klasifikasi untuk 3 kelas. Dari kedua tabel tersebut dapat dibandingkan kelebihan dan kekurangan dari masing-masing metode. Berdasarkan 2 tabel tersebut akan dicari presisi dan *recall* untuk setiap kelas atau set yang diujikan seperti Tabel 4.8.

Tabel 4.8 *Precision dan Recall* Klasifikasi 3 Kelas

Kelas	<i>Precision (%)</i>		<i>Recall (%)</i>	
	PSD, CNN	SSA, PSD, dan CNN	PSD, CNN	SSA, PSD, dan CNN
Set AB	94	98,5	93,07	98,5
Set CD	93	93,5	92,53	92,57
Set E	92	88	94,8	89,8

Berdasarkan Tabel 4.8 terdapat beberapa nilai presisi dari setiap kelas untuk masing-masing metode yang diujikan. Pada set AB dan set CD metode usulan memiliki nilai presisi dan *recall* yang lebih baik dibandingkan metode sebelumnya. Penambahan SSA mampu meningkatkan presisi untuk kedua kelas tersebut. Pada set E metode sebelumnya memiliki nilai presisi dan *recall* yang lebih baik dibandingkan metode usulan. Pada metode SSA terdapat langkah yang mengharuskan untuk memilih kelompok *eigenvalue* yang bertujuan untuk mengelompokkan sinyal sesuai karakteristiknya. Berdasarkan pengamatan pada penelitian sebelumnya untuk memunculkan karakteristik sinyal EEG, perlu memisahkan sinyal dengan noise yang ikut terekam. Salah satu noise yang ada adalah lonjakan amplitudo pada sinyal EEG. Dari pengamatan yang dilakukan untuk set A, set B, set C dan set D sangat terpengaruh oleh adanya lonjakan amplitudo. Dengan adanya lonjakan amplitudo karakteristik kelas tersebut menjadi kurang dominan sehingga susah diklasifikasikan apabila tidak dipisahkan. Berbeda dengan kelas yang lain untuk data set E memiliki karakteristik utama dengan banyaknya lonjakan amplitudo sehingga dengan pemilihan *eigenvalue* yang terfokus pada pemisahan EEG dari lonjakan amplitudo maka karakteristik utama set E berkurang.

Pada kasus 5 kelas terdapat tingkat akurasi untuk metode yang diusulkan adalah 92 % meningkat sebesar 13,4 % dari metode sebelumnya 78,6 %. Penambahan SSA mampu memberi peningkatan akurasi yang signifikan pada kasus 5 kelas. Berbeda dengan kasus 3 kelas yang memiliki perbedaan yang cukup

mencolok, kasus 5 kelas tidak memilikinya. Kelas dalam kasus 5 kelas merupakan pecahan dari kelas – kelas yang ada pada 3 kelas. Set A dan set B pada kasus 5 kelas merupakan pecahan set AB pada 3 kelas begitu pula dengan set C dan set D merupakan pecahan dari set CD. Kelas hasil pecahan tersebut memiliki kemiripan dengan kelas pecahan dari asal yang sama, misal set A mirip dengan set B dan set C mirip dengan set D. Kemiripan tersebut dapat dilihat dari hasil *precision* dan *recall* seperti pada Tabel 4.11 dan confusion matrix pada Tabel 4.9, dimana pada metode sebelumnya terdapat banyak salah klasifikasi terutama pada set C dan set D. Hasil recall dari metode sebelumnya untuk semua kelas masih kurang memuaskan itu menandakan adanya banyak salah klasifikasi.

Tabel 4.9 Confusion Matrix PSD dan CNN untuk 5 kelas

Aktual	Prediksi				
	Set A	Set B	Set C	Set D	Set E
Set A	86	9	3	1	1
Set B	5	93	0	0	2
Set C	2	0	68	27	3
Set D	6	2	34	52	6
Set E	2	1	0	3	94

Tabel 4.10 Confusion Matrix SSA, PSD, dan CNN Untuk 5 Kelas

Aktual	Prediksi				
	Set A	Set B	Set C	Set D	Set E
Set A	90	8	2	0	0
Set B	5	94	1	0	0
Set C	3	1	96	0	0
Set D	0	0	0	93	7
Set E	0	0	0	13	87

Pada metode yang diusulkan semua nilai *recall* untuk semua kelas lebih baik daripada metode sebelumnya, walaupun untuk nilai *precision* pada set E

lebih kecil dibandingkan metode sebelumnya. Menurunnya nilai *precision* pada set E dipengaruhi oleh pemilihan eigenvalue seperti yang dijelaskan sebelumnya. Dengan demikian metode SSA mampu memunculkan karakteristik sinyal EEG dengan memisahkannya dari noise, terutama untuk set A, set B, set C, dan set D.

Tabel 4.11 *Precision dan Recall* Klasifikasi 5 Kelas

Kelas	<i>Precision (%)</i>		<i>Recall (%)</i>	
	PSD, CNN	SSA, PSD, dan CNN	PSD, CNN	SSA, PSD, dan CNN
Set A	86	90	85,14	91,83
Set B	93	94	88,57	91,26
Set C	68	96	64,76	96,96
Set D	52	93	62,65	87,77
Set E	94	87	88,67	92,55

*[Halaman ini sengaja dikosongkan]*

## **BAB 5**

### **KESIMPULAN DAN SARAN**

Bab ini menguraikan kesimpulan yang dapat diambil dari penelitian ini dan saran-saran yang dapat digunakan untuk pengembangan selanjutnya.

#### **5.1 Kesimpulan**

1. Penambahan Metode SSA dalam kombinasi metode SSA, PSD dan CNN mampu meningkatkan akurasi klasifikasi sinyal EEG untuk set A, set B, set C, set D dan set E sebesar 1,2 % untuk 3 kelas dan 13,4 % untuk 5 kelas.
2. Tingkat akurasi gabungan SSA, PSD dan CNN lebih baik dibandingkan kombinasi PSD dan CNN untuk dua jumlah kelas yang diuji yaitu 92 % berbanding 78,6 % untuk 5 kelas dan 94,4 % berbanding 93,2 % untuk 3 kelas.
3. Pemilihan kelompok *eigenvalue* yang tepat pada metode SSA dapat digunakan untuk memunculkan karakteritik dari sinyal EEG epilepsi yang ditunjukkan dengan peningkatan akurasi dibandingkan dengan tidak menggunakan SSA, yaitu 78,6 % menjadi 92 % dengan kelompok *eigenvalue* terbaik adalah 200-1000.
4. Penyamaan besaran *range power spectrum* dengan menggunakan normalisasi dapat meningkatkan akurasi sebesar 6,6 %.
5. Penggabungan 3 buah filter yaitu *Gaussian Filter*, *High – Pass Filter*, dan *Mean Filter* dapat meningkatkan akurasi rata – rata klasifikasi sebesar 5,87 % dibandingkan dengan menggunakan 1 buah filter

## 5.2 Saran

Pengembangan yang bisa dilakukan untuk pada penelitian selanjutnya adalah :

1. Mengembangkan atau mengoptimasi pemilihan kelompok *eigenvalue* pada SSA sehingga pemilihan *eigenvalue* tidak perlu manual.
2. Melakukan lebih banyak percobaan pada CNN sehingga filter dapat ditambah dan dapat memperbaiki hasil akurasi.

## DAFTAR PUSTAKA

- Alpaydin, 2010. *Introduction to Machine Learning Second Edition*,
- Faust, O. et al., 2015. Wavelet-based EEG processing for computer-aided seizure detection and epilepsy diagnosis. *Seizure: European Journal of Epilepsy*, 26, pp.56–64. Available at: <http://dx.doi.org/10.1016/j.seizure.2015.01.012>.
- Hassani, H., Heravi, S. & Zhigljavsky, A., 2009. Forecasting European industrial production with singular spectrum analysis. *International Journal of Forecasting*, 25(1), pp.103–118. Available at: <http://dx.doi.org/10.1016/j.ijforecast.2008.09.007>.
- Karyawan, M.A., Zainal, A. & Saikhu, A., 2011. Klasifikasi Sinyal Eeg Menggunakan Koefisien Autoregresif ., *Jurnal TIF*, 2(1), pp.1–13.
- Kouchaki, S. & Sanei, S., 2013. Supervised Single Channel Source Separation Of EEG Signals. *IEEE INTERNATIONALWORKSHOP ON MACHINE LEARNING FOR SIGNAL PROCESSING*.
- Levinskis, A., 2013. Convolutional neural network feature reduction using wavelet transform. *Elektronika ir Elektrotechnika*, 19(3), pp.61–64.
- Maddirala, A.K. & Shaik, R.A., 2015. Removal of EMG Artifacts from Single Channel EEG Signal using Singular Spectrum Analysis. *IEEE SENSORS JOURNAL*, 16(23), pp.111–115.
- Marpaung, V., 2005. Depresi Pada Penderita Epilepsi Umum Dengan Kejang Tonik Klonik Dan epilepsi Parsial Sederhana. , pp.1–25.
- Moskvina, V. & Schmidt, K.M., 2003. Approximate projectors in singular spectrum analysis. *Siam J. Matrix Anal. Appl*, 24(4), pp.932–942.
- Palaniswami, M., Lai, D.T.. H. & Begg, R., 2008. *Computational intelligence in biomedical engineering*,
- Palaz, D., Magimai.-Doss, M. & Collobert, R., 2015. Convolutional Neural Networks-Based Continuous Speech Recognition Using Raw Speech Signal. *Icassp*, pp.4295–4299.
- Parhi, K.K. & Ayinala, M., 2014. Low-complexity welch power spectral density

- computation. *IEEE Transactions on Circuits and Systems I: Regular Papers*, 61(1), pp.172–182.
- Posada-Quintero, H.F. et al., 2016. Power Spectral Density Analysis of Electrodermal Activity for Sympathetic Function Assessment. *Annals of Biomedical Engineering*, 44(10), pp.3124–3135.
- Powers, D.M.W., 2011. Evaluation: From Precision, Recall and F-Measure To Roc, Informedness, Markedness & Correlation. *Journal of Machine Learning Technologies*, 2(1), pp.37–63. Available at: [http://www.bioinfopublication.org/files/articles/2\\_1\\_1\\_JMLT.pdf](http://www.bioinfopublication.org/files/articles/2_1_1_JMLT.pdf).
- R, P.J. & Wijayanto, A., Identifikasi Sinyal Suara Paru Berdasarkan Power Spectra Density Metode Welch Untuk Deteksi Kelainan Parenkim Paru.
- Siswantoro, J. et al., 2016. A linear model based on Kalman filter for improving neural network classification performance. *Expert Systems with Applications*, 49, pp.112–122.
- Springenberg, J.T. et al., 2015. STRIVING FOR SIMPLICITY: THE ALL CONVOLUTIONAL NET. In *ICLR*. pp. 1–14.
- Suartika, I.W., Wijaya, A.Y. & Soelaiman, R., 2016. Klasifikasi Citra Menggunakan Convolutional Neural Network ( Cnn ) pada Caltech 101. , 5(1).
- Teplan, M., 2002. Fundamentals of EEG measurement. *Measurement Science Review*, 2(2), pp.1–11.
- Titisari, D., Soesanti, I. & Winduratna, B., 2013. Reduksi Suara Jantung Dari Instrumentasi Akuisisi Perekaman Suara Paru-Paru Pada Anak-Anak Menggunakan Butterworth Band Pass Filter. In *SEMINAR NASIONAL ke 8 Tahun 2013 : Rekayasa Teknologi Industri dan Informasi REDUKSI*. pp. 129–134.
- Tjandrasa, H., Djanali, S. & Arunanto, F.X., 2016. Feature Extraction Using Combination of Intrinsic Mode Functions and Power Spectrum for EEG Signal Classification. *International Congress on Image and Signal Processing, BioMedical Engineering and Informatics*, 9, pp.1498–1502.
- Tzallas, A.T. et al., 2009. Epileptic Seizure Detection in EEGs Using Time – Frequency Analysis. *IEEE Transactions on Information Technology in*

- Biomedicine*, 13(5), pp.703–710.
- Übeyli, E.D., 2010. Least squares support vector machine employing model-based methods coefficients for analysis of EEG signals. *Expert Systems with Applications*, 37(1), pp.233–239.
- Yu, L. & Liu, H., 2003. Feature Selection for High-Dimensional Data: A Fast Correlation-Based Filter Solution. *International Conference on Machine Learning (ICML)*, pp.1–8. Available at: <http://www.aaai.org/Papers/ICML/2003/ICML03-111.pdf>.
- Yuliandar, D., Warsito, B. & Yasin, H., 2012. Pelatihan Feed Forward Neural Network Menggunakan Algoritma Genetika Dengan Metode Seleksi Turnamen Untuk Data Time Series. *JURNAL GAUSSIAN*, 1, pp.65–72.
- Zainun, N.Y., Rahman, I.A. & Eftekhari, M., 2010. Forecasting low-cost housing demand in an urban area in Malaysia using artificial neural networks: Batu Pahat, Johor. *WIT Transactions on Ecology and the Environment*, 142(1), pp.51–58.
- Zhigljavsky, A., Hassani, H. & Heravi, S., 2009. Forecasting European Industrial Production with Multivariate Singular Spectrum Analysis. *Business*, pp.1–39.

*[Halaman ini sengaja dikosongkan]*

## BIOGRAFI PENULIS



Penulis merupakan anak kedua dari pasangan Bambang Dwi Haryanto, S.Pd dan Suharti, S.Pd. yang dilahirkan di Wonogiri, Jawa Tengah pada tanggal 30 Juli 1991. Penulis menempuh pendidikan dasar di SDN 1 Sanan, Girimarto, Wonogiri, Jawa Tengah sejak tahun 1997 hingga lulus pada tahun 2003. Pendidikan tingkat menengah pertama Penulis ditempuh pada tahun 2003 – 2006 di SMPN 1 Sidoharjo, Wonogiri, Jawa Tengah. Sedangkan pendidikan menengah tingkat atas ditempuh penulis di SMAN 1 Wonogiri, Jawa Tengah pada tahun 2006 – 2009. Penulis kemudian melanjutkan pendidikan ke Program Studi S1 Ilmu Komputasi, Fakultas Sains, Universitas Telkom, Bandung, Jawa Barat selama 8 semester sejak September 2009 hingga lulus pada September 2013. Setelah lulus S1, Penulis sempat bekerja selama 1 tahun di perusahaan penyedia jasa IT di Jakarta. Karena keinginan pribadi Penulis melanjutkan studi ke program studi S2 Teknik Informatika di Jurusan Teknik Informatika, Fakultas Teknologi Informasi, Institut Teknologi Sepuluh Nopember Surabaya sejak September 2015. Penulis mengambil bidang minat Komputasi Cerdas dan Visual. Penulis dapat dihubungi melalui email di [bayu.nurseno@gmail.com](mailto:bayu.nurseno@gmail.com) atau Facebook di [www.facebook.com/nursenobayu](http://www.facebook.com/nursenobayu).