



TUGAS AKHIR - TJ 141502

**KLASIFIKASI EPILEPSI KONDISI KEJANG DAN TIDAK KEJANG
BERDASARKAN GELOMBANG OTAK EEG MENGGUNAKAN
EMPIRICAL MODE DECOMPOSITION (EMD) DENGAN EKTRAKSI
FITUR *BANDWIDTH***

Nomala Gema Puji Putri
NRP 07211440000038

Dosen Pembimbing
Prof. Dr. Ir. Yoyon Kusnendar Suprpto, M.Sc.
Dr. Diah Puspito Wulandari, ST., M.Sc.

DEPARTEMEN TEKNIK KOMPUTER
Fakultas Teknologi Elektro
Institut Teknologi Sepuluh Nopember



FINAL PROJECT - TJ 141502

**CLASSIFICATION SEIZURE AND NON SEIZURE BASED ON
EEG SIGNAL USING EMPIRICAL MODE DECOMPOSITION
(EMD) AND BANDWIDTH FEATURE EXTRACTION**

Nomala Gema Puji Putri
NRP 07211440000038

Supervisors

Prof. Dr. Ir. Yoyon Kusnendar Suprpto, M.Sc.
Dr. Diah Puspito Wulandari, ST., M.Sc.

DEPARTEMENT OF COMPUTER ENGINEERING
Faculty of Electrical Engineering
Sepuluh Nopember Institute of Technology
Surabaya 2018

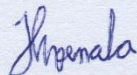
PERNYATAAN KEASLIAN TUGAS AKHIR

Dengan ini saya menyatakan bahwa isi sebagian maupun keseluruhan Tugas Akhir saya dengan judul "**Klasifikasi Epilepsi Kondisi Kejang dan Tidak Kejang berdasarkan Gelombang Otak EEG menggunakan *Empirical Mode Decomposition (EMD)* Dengan Ekstraksi Fitur *Bandwidth***" adalah benar-benar hasil karya intelektual mandiri, diselesaikan tanpa menggunakan bahan-bahan yang tidak diijinkan dan bukan karya pihak lain yang saya akui sebagai karya sendiri.

Semua referensi yang dikutip maupun dirujuk telah ditulis secara lengkap pada daftar pustaka.

Apabila ternyata pernyataan ini tidak benar, saya bersedia menerima sanksi sesuai peraturan yang berlaku.

Surabaya, Juli 2018



Nomala Gema Puji Putri
NRP. 0721144000038

LEMBAR PENGESAHAN

Klasifikasi Epilepsi Kondisi Kejang dan Tidak Kejang berdasarkan Gelombang Otak EEG menggunakan *Empirical Mode Decomposition (EMD)* dengan Ekstraksi Fitur *Bandwidth*

Tugas Akhir ini disusun untuk memenuhi salah satu syarat memperoleh gelar Sarjana Teknik di Institut Teknologi Sepuluh Nopember Surabaya

Oleh : Nomala Gema Puji Putri (NRP: 07211440000038)

Tanggal Ujian : 28 Juni 2018

Periode Wisuda : September 2018

Disetujui oleh:

Prof. Dr. Ir. Yoyon K. Suprpto, M.Sc.
NIP: 195409251978031001

(Pembimbing I)

Dr. Diah Puspito Wulandari, ST., M.Sc.
NIP: 198012192005012001

(Pembimbing II)

Arief Kurniawan, ST., MT.
NIP: 197409072002121001

(Penguji I)

Dr. I Ketut Eddy Purnama, ST., MT.
NIP: 196907301995121001

(Penguji II)

Muhtadin, ST., MT.
NIP: 198106092009121003

(Penguji III)

Mengetahui
Kepala Departemen Teknik Komputer

Dr. I Ketut Eddy Purnama, ST., MT.
NIP: 196907301995121001



Abstrak

Nama Mahasiswa :Nomala Gema Puji Putri
Judul Tugas Akhir :Klasifikasi Epilepsi Kondisi Kejang dan Tidak Kejang berdasarkan Gelombang Otak *EEG* Menggunakan *Empirical Mode Decomposition (EMD)* dengan Ekstraksi Fitur *Bandwidth*
Pembimbing : 1. Prof. Dr. Ir. Yoyon K. Suprpto, M.Sc.
2. Dr. Diah Puspito W, ST., M.Sc.

Penelitian melakukan klasifikasi kondisi kejang penderita epilepsi . Hasil dari pemeriksaan berupa sinyal *electroencephalogram (EEG)* akan digunakan sebagai data untuk melakukan klasifikasi. Data rekaman *EEG* yang digunakan berasal dari “Klinik für Epileptologie, Universität Bonn” dengan total data 500 dan dari Rumah Sakit Universitas Airlangga dengan total data 500. Data *EEG* yang diperoleh kemudian didekomposisi menggunakan metode *Empirical Mode Decomposition (EMD)* menghasilkan *Intrinsic Mode function (IMF)*. *IMF* yang didapatkan dianalisis menggunakan transformasi Hilbert. Hasil analisis *IMF* akan digunakan untuk mendapatkan ekstraksi fitur *bandwidth* yaitu *bandwidth* modulasi amplitudo (*BAM*) dan *bandwidth* modulasi frekuensi (*BFM*) . *BAM* dan *BFM* yang dihasilkan akan menjadi input pada proses klasifikasi menggunakan *Support Vector Machine (SVM)*. Dari hasil penelitian didapatkan rata-rata akurasi terbaik sebesar 96.8% pada data publik dan 96.5% pada data RSUA.

Kata Kunci: Epilepsi ,*EEG*, *Empirical Mode Decomposition*, Pembelajaran Mesin

Halamana ini sengaja dikosongkan

Abstract

Student's Name :Nomala Gema Puji Putri

Title :*Classification Seizure and Nonseizure Based On EEG Signals Using Empirical Mode Decomposition (EMD) and Bandwidth Feature Extraction*

Supervisors : 1. Prof. Dr. Ir. Yoyon K. Suprpto, M.Sc.
2. Dr. Diah Puspito W, ST., M.Sc.

Some research, about clasification of seizure conditions. Epilepsy is one of the brain neurological disorders, caused by functional or structural damage, to determine electroencephalography is used in the evaluation of brain disorders. The result of evaluation electroencephalogram will be used to classify seizure. An EEG dataset, which is publicly in "Clinical für Epileptologie, Universität Bonn" the dataset with 500 EEG dataset and from Airlangga University Hospital Surabaya dataset with 500 EEG dataset obtained by empirical mode decomposition to decompose signals into Intrinsic Mode Functions (IMF's), then processed by Hilbert Transform to produce corresponding analytic signals for each of the inherent modes. The result of IMF analysis by using Hilbert transform will be used to get feature extraction bandwidth namely amplitude modulation bandwidth (B_{AM}) and frequency modulation bandwidth (B_{FM}). The features of B_{AM} and B_{FM} are used as input of the Support Vector Machine (SVM) classifier for seizure and non seizure EEG. From the research, the best accuracy average from public data is 96.8% and best average accuracy on RSUA data is 96.5%.

Keywords: Epilepsy, EEG, Empirical Mode Decomposition, Machine Learning

Halamana ini sengaja dikosongkan

KATA PENGANTAR

Puji syukur kehadirat Allah SWT atas segala limpahan berkah, rahmat, serta hidayah-Nya, penulis dapat menyelesaikan tugas akhir dengan judul **“KLASIFIKASI EPILEPSI KONDISI KEJANG DAN TIDAK KEJANG BERDASARKAN GELOMBANG OTAK EEG MENGGUNAKAN EMPIRICAL MODE DECOMPOSITION (EMD) DENGAN EKTRAKSI FITUR BANDWIDTH”**. Penelitian ini disusun dalam rangka pemenuhan tugas akhir Departemen Teknik Komputer ITS, Bidang Studi Telematika, serta digunakan sebagai persyaratan menyelesaikan pendidikan S1. Bagi penulis, menyelesaikan tugas akhir ini merupakan sebuah pengalaman berharga dalam mengimplementasikan metode yang telah dipelajari. Penelitian ini dapat terselesaikan tidak lepas dari bantuan berbagai pihak. Oleh karena itu, penulis mengucapkan terima kasih kepada:

1. Allah SWT
2. Bapak Kepala Departemen Teknik Komputer Dr. I Ketut Eddy Purnama, ST., MT
3. Bapak Prof. Dr. Ir. Yoyon Kusnendar Suprpto M.Sc. dan Ibu Dr. Diah Puspito Wulandari, ST., M.Sc. selaku dosen pembimbing, atas dukungan dan bimbingan selama mengerjakan tugas akhir ini.
4. dr. Wardah Rahmatul Islamiyah, Sp.S sebagai anggota peneliti yang telah meluangkan waktunya untuk memberikan wawasan seputar epilepsi.
5. Bapak-ibu dosen pengajar serta staff Departemen Teknik Komputer atas pengajaran, bimbingan, serta perhatian yang diberikan kepada penulis selama ini
6. Kedua orangtua, kakak yang sama-sama sedang berjuang menyelesaikan kuliah serta adik yang selalu memberikan dukungan baik doa maupun motivasi dalam mengerjakan tugas akhir ini.
7. Kiki, Thalialia, Desanti, Yayak dan teman-teman angkatan E-54 dan semua pihak yang telah menemani dan menghibur dalam mengerjakan tugas akhir ini.

Penulis memohon segenap kritik dan saran yang membangun. Harapannya penelitian ini dapat berguna sebagai acuan penelitian-penelitian selanjutnya.

Surabaya, Mei 2018

DAFTAR ISI

Abstrak.....	i
Abstract.....	iii
KATA PENGANTAR	v
DAFTAR ISI.....	vii
DAFTAR GAMBAR	xi
DAFTAR TABEL.....	xiii
DAFTAR ISTILAH	xv
BAB 1 PENDAHULUAN	1
1.1 Latar Belakang.....	1
1.2 Permasalahan	2
1.3 Tujuan.....	2
1.4 Batasan Masalah.....	2
1.5 Sistematika Penulisan.....	3
BAB 2 TINJAUAN PUSTAKA	5
2.1 Epilepsi.....	5
2.2 <i>Electroencephalogram (EEG)</i>	6
2.3 <i>Empirical Mode Decomposition (EMD)</i>	10
2.4 Analisis Sinyal Representasi <i>IMF</i>	11
2.4.1 Sinyal Amplitudo	12
2.4.2 <i>Instantaneous frequency</i>	12
2.5 <i>Bandwidth</i> Modulasi Amplitudo dan Modulasi Frekuensi ..	12
2.6 <i>Support Vector Machine (SVM)</i>	14
2.6.1 Fungsi Kernel.....	17

2.7	Evaluasi Kerja	18
2.7.1	<i>Confusion Matrix</i>	18
2.7.2	<i>K-Fold Cross Validation</i>	20
2.7.3	<i>Receive Operating Characteristics (ROC)</i>	21
BAB 3 DESAIN DAN IMPLEMENTASI SISTEM		23
3.1	Desain Sistem.....	23
3.2	Implementasi Sistem	24
3.2.1	Pengumpulan Data	24
3.2.2	Dekomposisi Sinyal menggunakan <i>EMD</i>	28
3.2.3	Transformasi Hilbert.....	30
3.2.4	Ekstraksi Fitur.....	30
3.2.5	Klasifikasi.....	30
3.2.6	Evaluasi Kerja.....	31
BAB 4 HASIL KERJA DAN PENGUJIAN.....		33
4.1	Pengumpulan Data	33
4.2	Preprocessing Data	35
4.2.1	Proses Dekomposisi Sinyal.....	35
4.2.2	Analisis Sinyal	39
4.2.3	Ekstraksi Fitur.....	43
4.3	Klasifikasi	43
4.3.1	<i>Confusion Matrix</i>	45
4.3.2	<i>K-Fold Cross Validation</i>	45
4.3.2	<i>Receive Operating Characteristics (ROC)</i>	46
4.4	Pengujian Data.....	46
4.4.1	Pengujian dengan beberapa fungsi kernel.....	46
4.4.2	Pengujian dengan <i>ROC</i>	55

BAB 5 PENUTUP	63
5.1 Kesimpulan.....	63
5.2 Saran.....	64
DAFTAR PUSTAKA	65
LAMPIRAN.....	67
BIOGRAFI PENULIS	87

Halamana ini sengaja dikosongkan

DAFTAR GAMBAR

Gambar 2.1 Perekaman sinyal <i>EEG</i> dengan cara <i>ekstrakranial</i>	6
Gambar 2.2 Macam gelombang otak manusia[10]	8
Gambar 2.3 Penempatan elektroda.....	9
Gambar 2.4 Bagan <i>empirical mode decomposition</i>	11
Gambar 2.5 Bagan <i>bandwidth</i> amplitudo modulasi dan frekuensi modulasi.....	13
Gambar 2.6 <i>SVM</i> berusaha menemukan <i>hyperplane</i> terbaik yang memisahkan kedua <i>class</i> 1 dan 2 [15].....	14
Gambar 2.7 Ilustasi <i>hyperplane</i> pada dimensi	17
Gambar 3.1 Blok diagram penelitian	23
Gambar 3.2 Blok diagram data penelitian.....	25
Gambar 3.3 Contoh sinyal <i>EEG</i> dari masing-masing dataset	26
Gambar 3.4 Data sinyal dari hasil perekaman <i>EEG</i>	27
Gambar 3.5 Diagram proses <i>EMD</i>	29
Gambar 3.6 Diagram Klasifikasi <i>SVM</i>	31
Gambar 4.1 Sinyal Awal	35
Gambar 4.2 Mendapatkan nilai <i>extreme sinyal</i>	35
Gambar 4.3 Mendapatkan nilai <i>envelope</i> sinyal	36
Gambar 4.4 Mendapatkan nilai tengah dari sinyal	36
Gambar 4.5 Dekomposisi Sinyal <i>EEG</i> kejang	37
Gambar 4.6 Dekomposisi Sinyal <i>EEG</i> normal.....	38
Gambar 4.7 Amplitudo sesaat pada sinyal kejang	39
Gambar 4.8 Amplitudo sesaat pada sinyal tidak kejang.....	40
Gambar 4.9 Frekuensi sesaat pada sinyal kejang	41
Gambar 4.10 Frekuensi sesaat pada	42
Gambar 4.11 <i>ROC</i> kernel <i>RBF</i> pada data publik	55
Gambar 4.12 <i>ROC</i> kernel <i>polynomial</i> pada data publik.....	56
Gambar 4.13 <i>ROC</i> kernel <i>mexican hat</i>	57
Gambar 4.14 <i>ROC</i> kernel morlet	58
Gambar 4.15 <i>ROC</i> kernel <i>RBF</i> pada data lokal.....	59
Gambar 4.16 <i>ROC</i> kernel <i>polynomial</i> pada data lokal	59
Gambar 4.17 <i>ROC</i> kernel <i>mexican hat</i> pada data lokal.....	60
Gambar 4.18 <i>ROC</i> kernel <i>morlet</i> pada data lokal	61

Halamana ini sengaja dikosongkan

DAFTAR TABEL

Tabel 2.1 Beberapa jenis kernel yang digunakan dalam <i>SVM</i>	18
Tabel 2.2 <i>Confusion Matrix</i> untuk klasifikasi	19
Tabel 2.3 <i>K-fold cross validation</i> untuk klasifikasi	21
Tabel 3.1 Data rekaman <i>EEG</i> yang didapat dari RSUA	28
Tabel 4.1 Keterangan waktu kejadian pada data <i>EEG</i>	34
Tabel 4.2 Contoh hasil ekstraksi fitur pada B_{AM4} dan B_{FM4} serta label kelas	44
Tabel 4.3 Contoh hasil klasifikasi	45
Tabel 4.4 Data publik hasil penelitian dengan menggunakan kernel <i>RBF</i>	47
Tabel 4.5 Data publik hasil penelitian dengan menggunakan kernel <i>Polynomial</i>	48
Tabel 4.6 Data publik hasil penelitian dengan menggunakan kernel <i>mexican hat</i>	49
Tabel 4.7 Data publik hasil penelitian dengan menggunakan kernel <i>morlet</i>	50
Tabel 4.8 Data lokal hasil penelitian dengan menggunakan kernel <i>RBF</i>	51
Tabel 4.9 Data lokal hasil penelitian dengan menggunakan kernel <i>Polynomial</i>	52
Tabel 4.10 Data lokal hasil penelitian dengan menggunakan kernel <i>mexican hat</i>	53
Tabel 4.11 Data lokal hasil penelitian dengan menggunakan kernel <i>morlet</i>	54

Halamana ini sengaja dikosongkan

DAFTAR ISTILAH

$s(t)$:	Sinyal Awal
$em(t)$:	<i>Upper envelope</i>
$el(t)$:	<i>Lower envelope</i>
$a(t)$:	Nilai rata-rata lokal
M	:	Banyaknya nilai ke-
$h_M(t)$:	Hasil <i>IMF</i>
$r_M(t)$:	Residu
$c(t)$:	Hasil Analisa sinyal <i>IMF</i> real
$z(t)$:	Transformasi Hilbert
$A(t)$:	Amplitudo Sesaat
$j c_H(t)$:	Sinyal Imajiner
$\emptyset(t)$:	Fase Sesaat
$\omega(t)$:	Frekuensi Sesaat
$E(t)$:	Energi Sinyal
x_i	:	Banyaknya dataset
y_i	:	Label untuk dataset
\vec{w}	:	Vektor bobot
\vec{x}	:	Nilai atribut
b	:	Bias
L	:	<i>Gradient</i>

K	:	Fungsi kernel
Φ	:	<i>Feature space</i>
l	:	<i>Degree kernel polynomial</i>
σ	:	Parameter kontrol pada kernel <i>RBF</i>
a	:	Dilatasi waktu
w_0	:	Koefisien kernel <i>morlet</i>

BAB 1

PENDAHULUAN

Penelitian ini di latar belakang oleh berbagai kondisi yang menjadi acuan. Selain itu juga terdapat beberapa permasalahan yang akan dijawab sebagai luaran dari penelitian.

1.1 Latar Belakang

Epilepsi merupakan salah satu kelainan fungsi saraf otak yang disebabkan baik karena kerusakan fungsional maupun struktural. Pembacaan hasil *EEG* untuk mendeteksi kejang dengan banyaknya informasi sinyal yang didapat, pengamatan visual sangat menyita waktu dan tidak akurat, sementara hasil *EEG* merupakan bagian penting dari diagnosis epilepsi[1].

Electroencephalography adalah teknik yang digunakan dalam pengukuran sinyal listrik yang diproduksi oleh otak. Sinyal otak dicatat dari elektroda yang ditempatkan pada kepala. Hasil rekaman ini dikenal dengan nama *electroencephalogram (EEG)*. *EEG* merupakan sinyal kompleks yang membawa banyak informasi tentang fungsi otak manusia dan kelainan fungsi saraf[2].

Parameter yang diekstraksi dari *EEG* sangat berguna dalam diagnosis. Parameter spektral berdasarkan transformasi Fourier umumnya digunakan untuk deteksi dan klasifikasi sinyal *EEG* kejang penderita epilepsi[3]. Namun anggapan bahwa sinyal analisis berbasis transformasi Fourier yang dianalisis bersifat stasioner[2]. Penelitian sebelumnya telah menunjukkan sinyal *EEG* berubah seiring waktu, yaitu sinyal *EEG* bersifat nonstasioner[4]. Terdapat beberapa penelitian dengan metode berbasis domain frekuensi waktu telah dikembangkan diantaranya short time fourier transform, dan wavelet transform[2]. Selain itu metode nonlinier telah diusulkan guna mengekstraksi parameter untuk analisis dan klasifikasi sinyal *EEG*.

Pada tugas akhir ini dengan menggunakan sinyal *EEG* baik dari hasil rekaman sinyal *EEG* normal serta sinyal *EEG* penderita epilepsi dalam keadaan kejang dan tidak kejang dapat dilakukan klasifikasi. Dengan analisis sinyal nonstasioner dan nonlinier sinyal didekomposisi menggunakan metode *Empirical Mode Decomposition (EMD)* sehingga akan terurai menjadi *Intrinsic Mode Function (IMF)*. Analisis

representasi *IMF* digunakan sebagai fitur *amplitude modulation bandwidth* (B_{AM}) dan *frequency modulation bandwidth* (B_{FM}). Parameter *bandwidth* amplitudo dan frekuensi digunakan sebagai input *Support Vector Machine* (*SVM*) untuk mengklasifikasikan kondisi kejang penderit epilepsi. Penelitian ini didasarkan pada paper yang pernah dilakukan dengan fitur *bandwidth* pada masing-masing fitur *IMF* [2], serta akan diuji juga klasifikasi dengan menggabungkan fitur *bandwidth* pada empat fitur *IMF*.

1.2 Permasalahan

Permasalahan yang dipaparkan dalam tugas akhir ini adalah:

1. Mengembangkan sistem klasifikasi yang dapat mendampingi diagnosis yang dilakukan ahli medis
2. Diperlukan adanya sistem untuk mempermudah dalam mengklasifikasi kondisi kejang penderit epilepsi karena banyaknya informasi pada sinyal *EEG*
3. Sinyal *EEG* bersifat non stasioner dan non linier sehingga diperlukan dekomposisi sinyal *EEG* menggunakan *EMD* diuraikan menjadi *IMF*, dengan menggunakan fitur *bandwidth* diklasifikasikan dengan *SVM*.

1.3 Tujuan

Tujuan dari penelitian ini adalah untuk melakukan klasifikasi sinyal otak manusia atau *EEG*. Output yang diharapkan yaitu sistem yang dapat mengklasifikasi sinyal *EEG* ke dalam dua kelompok yaitu kondisi normal dan kejang penderit epilepsi. Kedepannya, diharapkan dapat membantu ahli medis untuk memeriksa apakah seseorang terkena epilepsi, serta nantinya pada pasien epilepsi dapat melihat bagaimana perkembangan sebelum dilakukan pengobatan dan setelah dilakukan pengobatan yang dilakukan oleh ahli medis.

1.4 Batasan Masalah

Batasan masalah pada penelitian ini adalah:

1. Data sinyal *EEG* diperoleh dari *EEG Database* [5] dan data *EEG* dari RSUA.
2. Data sinyal *EEG* telah dibersihkan dari *artifacts* dan yang masih mengandung *artifact* fisiologi.

3. Pada tahap *dekomposisi* sinyal menghasilkan *IMF*.
4. Fitur yang diekstrak didapat dari hasil *IMF*.
5. Metode yang digunakan untuk klasifikasi adalah *SVM*.

1.5 Sistematika Penulisan

Laporan penelitian Tugas akhir ini tersusun dalam sistematika dan terstruktur sehingga mudah dipahami dan dipelajari oleh pembaca maupun seseorang yang ingin melanjutkan penelitian ini. Alur sistematika penulisan laporan penelitian ini yaitu :

1. BAB I Pendahuluan
Bab ini berisi uraian tentang latar belakang permasalahan, penegasan dan alasan pemilihan judul, sistematika laporan, tujuan dan metodologi penelitian.
2. BAB II Tinjauan Pustaka
Pada bab ini berisi tentang uraian secara sistematis teori-teori yang berhubungan dengan permasalahan yang dibahas pada penelitian ini. Teori-teori ini digunakan sebagai dasar dalam penelitian, yaitu informasi terkait sinyal *EEG*, penyakit epilepsi, dan teori-teori penunjang lainnya.
3. BAB III Desain dan Implementasi
Bab ini berisi tentang penjelasan-penjelasan terkait eksperimen yang akan dilakukan dan langkah-langkah data diolah hingga menghasilkan data klasifikasi yang diinginkan. Guna mendukung itu digunakan blok diagram atau *work flow* agar sistem yang akan dibuat dapat terlihat dan mudah dibaca untuk implementasi pada pelaksanaan tugas akhir.
4. BAB IV Hasil Kerja dan Pengujian
Bab ini menjelaskan tentang pengujian eksperimen yang dilakukan terhadap data dan analisisnya. Beberapa ekstraksi fitur sinyal akan ditunjukkan hasilnya pada bab ini dan dilakukan analisa terhadap hasil *training* data yang telah didapat dari hasil ekstraksi fitur untuk didapatkan akurasi, spesifikasi, sensitifitas dan *Receive Operating Characteristics (ROC)*.
5. BAB V Penutup
Bab ini merupakan penutup yang berisi kesimpulan yang diambil dari penelitian dan pengujian yang telah dilakukan. Saran dan

kritik yang membangun untuk pengembangan lebih lanjut juga dituliskan pada bab ini.

BAB 2

TINJAUAN PUSTAKA

2.1 Epilepsi

Epilepsi merupakan gangguan kronik otak yang menunjukkan gejala-gejala berupa serangan yang berulang yang terjadi akibat adanya ketidaknormalan kerja sementara sebagian atau seluruh jaringan otak karena jaringan listrik pada neuron peka rangsang yang berlebihan, dapat menimbulkan kelainan motorik, sensorik, otonom atau psikis yang timbul tiba-tiba dan sesaat disebabkan lepasnya muatan listrik abnormal sel-sel otak [6].

Epilepsi merupakan manifestasi gangguan fungsi otak dengan berbagai etiologi, dengan gejala tunggal yang khas, yaitu kejang berulang akibat lepasnya muatan listrik neuron otak secara berlebihan dan *paroksimal*[7]. Terdapat dua kategori dari kejang epilepsi yaitu kejang fokal (parsial) dan kejang umum. Kejang fokal terjadi karena adanya lesi pada satu bagian dari *cerebral cortex*, di mana pada kelainan ini dapat disertai kehilangan kesadaran parsial. Sedangkan pada kejang umum, lesi mencakup area yang luas dari *cerebral cortex* dan biasanya mengenai kedua *hemisfer cerebri*. Kejang mioklonik, tonik, dan klonik termasuk dalam epilepsi umum.[6]

Bangkitan epilepsi adalah manifestasi klinis dari bangkitan serupa (stereotipik) yang berlebihan dan abnormal, berlangsung mendadak dan sementara, dengan atau tanpa perubahan kesadaran. Disebabkan oleh hiperaktifitas listrik sekelompok sel saraf di otak dan bukan disebabkan oleh suatu penyakit otak akut [6].

Kejang epilepsi harus dibedakan dengan sindrom epilepsi. Kejang epilepsi adalah timbulnya kejang akibat berbagai penyebab yang ditandai dengan serangan tunggal atau tersendiri. Sedangkan sindrom epilepsi adalah sekumpulan gejala dan tanda klinis epilepsi yang ditandai dengan kejang epilepsi berulang, meliputi berbagai etiologi, umur, onset, jenis serangan, faktor pencetus, kronisitas[6].

Seorang anak terdiagnosa menderita epilepsi jika terbukti tidak ditemukannya penyebab kejang lain yang bisa dihilangkan atau disembuhkan, misalnya adanya demam tinggi, adanya pendesakan otak oleh tumor, adanya pendesakan otak oleh desakan tulang kranium akibat

trauma, adanya inflamasi atau infeksi di dalam otak, atau adanya kelainan biokimia atau elektrolit dalam darah. Tetapi jika kelainan tersebut tidak ditangani dengan baik maka dapat menyebabkan timbulnya epilepsi di kemudian hari[8].

2.2 *Electroencephalogram (EEG)*

Electroencephalogram (EEG) adalah suatu tes untuk mendeteksi kelainan aktivitas elektrik otak. Sedangkan menurut dr. Darmo Sugondo [9] membedakan antara *electroencephalogram* dan *electroencephalografi* dimana *electroencephalografi* adalah prosedur pencatatan aktifitas listrik otak dengan alat pencatatan yang peka sedangkan grafik yang dihasilkannya disebut *electroencephalogram*.

Jadi aktivitas otak berupa gelombang listrik, yang dapat direkam melalui kulit kepala disebut *electroensefalografi*. Gambar 2.1 merupakan proses perekaman sinyal *EEG* dengan cara *ekstrakranial*.




Gambar 2.1 Perekaman sinyal *EEG* dengan cara *ekstrakranial*

Amplitudo dan frekuensi *EEG* bervariasi, tergantung pada tempat perekaman dan aktivitas otak saat perekaman. Suasana yang sesuai untuk melakukan bacaan *EEG* adalah pada ruangan yang tenang dan sepi supaya pasien dapat mencapai tahap relaksasi (*relaxed wakefulness*). Sewaktu *EEG* dilakukan, pasien dilakukan dengan berbagai macam stimulasi, pasien direkam dengan *EEG* pada saat kondisi mata terbuka, lalu pasien direkam dalam keadaan mata tertutup, kemudian pasien direkam dalam keadaan diberikan rangsangan *strobe light flashes* (lampu ruangan dibuat berkedip-kedip) dengan berbagai intensitas terang cahaya yang telah diatur sedemikian rupa, selanjutnya pasien diintruksikan untuk hiperventilasi selama beberapa saat. Apa yang dilihat adalah jenis gelombang yang dicatat pada *encephalogram*. Pada orang normal, gambaran *EEG* akan menunjukkan beberapa jenis gelombang yang spesifik mengikuti dengan keadaan seseorang itu [9].

Terdapat beberapa jenis gelombang di otak normal yaitu gelombang alfa, gelombang beta, gelombang theta dan gelombang delta dan gelombang gamma. Saat subyek santai, mata tertutup, gambaran *EEG* menunjukkan aktivitas dengan gelombang sinkron 8-14 siklus/detik, disebut gelombang alfa. Gelombang alfa dapat direkam dengan baik pada area visual di daerah oksipital. Gelombang alfa yang sinkron dan teratur akan hilang, kalau subyek membuka matanya yang tertutup. Gelombang yang terjadi adalah gelombang beta (> 14 siklus/detik), gelombang beta direkam dengan baik di regio frontal, merupakan tanda bahwa orang terjaga, waspada dan terjadi aktivitas mental. Gelombang theta mempunyai frekuensi diantara 4-7 siklus per saat dan biasanya datang dari lobus parietalis dan temporalis dalam anak-anak. Pada dewasa gelombang ini biasa terjadi pada orang yang mengalami frustrasi atau kecewa. Gelombang theta juga ada terjadi pada golongan orang yang mempunyai penyakit otak degeneratif. Gelombang delta adalah gelombang pada frekuensi yang kurang daripada 3.5 siklus per saat dan mempunyai tegangan volt 2-4 kali lebih besar daripada gelombang otak lain. Ini sering berlaku pada tidur yang dalam, pada bayi atau penyakit organik yang serius [9]. Gelombang gamma cenderung merupakan yang terendah dalam amplitudo dan gelombang paling cepat. Gelombang gamma adalah gelombang otak (*brainwave*) yang terjadi pada saat seseorang mengalami aktivitas mental yang sangat tinggi, misalnya sedang berada di arena


pertandingan, perebutan kejuaraan, tampil dimuka umum, sangat panik, ketakutan[10].



Gambar 2.2 Macam gelombang otak manusia[10]

Gambar 2.2 merupakan gambar gelombang otak. Adapun untuk mendapatkan gelombang otak *EEG* maka diperlukan pemasangan elektroda. Dimana pemasangan elektroda merupakan faktor yang turut menentukan keberhasilan perekaman sinyal *EEG*. Oleh karena itu International Federation of Societies of Electroencephalography mengeluarkan standar penempatan elektroda *EEG* yang disebut sistem 10-20 [11]. Elektroda referensi biasanya menempel pada telinga (A_1 atau A_2). Penempatan elektroda, dengan melihat kode huruf yang menyatakan lokasi dan angka ganjil menunjukkan sisi kiri serta angka genap

menunjukkan sisi kanan sedangkan terdapat pula huruf z yang menandakan lokasi perpusat pada kepala. sinyal-sinyal dibagian otak sisi kanan dibandingkan dengan sinyal sisi kiri. Saat aktifitas tidak simetris, hal ini sering menandakan adanya indikasi penyakit otak. Untuk mendapatkan hasil perekaman *EEG* yang didapat dengan pemasangan elektroda secara fluktuasi melalui beda potensial atau tegangan yang didapat dari hasil membandingkan dua elektroda, yaitu antara elektroda yang aktif pada kulit kepala dengan satu elektroda acuan yang dipasang pada daerah kulit kepala sehingga muncul selisih beda potensial, tipe perekaman ini disebut *montase* monopolar. Sedangkan hasil dari dua elektroda yang berdekatan disebut *montase* bipolar. Gambar 2.3 menunjukkan tipe EEG untuk beberapa pasang elektroda.



Keterangan *channel* pada elektroda:
 F- lobus Frontal
 T-Lobus Temporal
 C-Lobus Central
 P-Lobus Parietal
 O-Lobus Occipital

Gambar 2.3 Penempatan elektroda sistem standart internasional 10-20[12]

2.3 Empirical Mode Decomposition (EMD)

EMD merupakan metode analisis yang dapat mendekomposisikan sinyal berdasarkan amplitudo dan frekuensi sinyal informasi pada saat tertentu[2].

Tujuan dari metode EMD adalah mendekomposisi sinyal nonlinier dan nonstationer $s(t)$ ke sejumlah *Intrinsic Mode Functions (IMF)*. Setiap IMF memenuhi dua kondisi:

1. Jumlah *extreme* dan jumlah *zero-crossing* harus sama jika terdapat selisih paling banyak berjumlah satu.
2. Pada titik manapun nilai rata-rata dari *envelope* yang didefinisikan oleh *local maxima* dan *envelope* yang didefinisikan oleh *local minima* adalah nol.

Algoritma EMD untuk sinyal asli/awal $s(t)$ dapat dirumuskan sebagai berikut [2]:

1. Mendeteksi *extrema (maxima dan minima)* dari sinyal awal $s(t)$, dimana (t) merupakan waktu.
2. Membangkitkan *upper envelope (em(t))* dan lower envelope ($el(t)$) masing-masing dengan menghubungkan maxima dan minima secara terpisah dengan cubic spline interpolation.
3. Menentukan nilai rata-rata lokal $a(t)$ dimana pada persamaan (2.1)

$$a(t) = \frac{[em(t)+el(t)]}{2} \quad (2.1)$$

4. Ekstrak IMF pertama $h_1(t)$ persamaan (2.2)

$$h_1(t) = s(t) - a(t) \quad (2.2)$$

5. Tentukan apakah $h_1(t)$ adalah IMF atau bukan dengan memeriksa dua kondisi dasar diatas.
6. Ulangi langkah (1) sampai (4) dan berakhir ketika IMF $h_1(t)$ telah diperoleh.

Setelah hasil IMF pertama didapatkan, didefinisikan $c_1(t) = h_1(t)$, merupakan skala waktu terkecil dari sinyal $s(t)$. Untuk menentukan sisa IMF yang disebut sebagai residu $r_1(t) = s(t) - c_1(t)$, ulangi proses

tersebut sampai residu konstan atau turunan pertama dari *IMF* tidak ada lagi. Pada akhir dekomposisi, sinyal asli $s(t)$ persamaan (2.3) direpresentasikan:

$$s(t) = \sum_{m=1}^M (c_m(t) + r_M(t)) \quad (2.3)$$

Dimana $c_m(t)$ adalah jumlah dari *IMF*, dan $r_M(t)$ adalah residu akhir. Gambar 2.4 merupakan bagan dekomposisi sinyal menjadi *IMF* dimana hasil *IMF* pertama akan menjadi inputan untuk mendekomposisi sinyal menjadi *IMF* kedua, hasil *IMF* kedua menjadi inputan untuk mendekomposisi sinyal menjadi *IMF* ketiga dan seterusnya hingga menghasilkan residu yang konstan .



Gambar 2.4 Bagan *empirical mode decomposition*

2.4 Analisis Sinyal Representasi *IMF*

Transformasi Hilbert adalah alat untuk analisis data yang dikembangkan pada tahun 1998. Karena algoritma *EMD* awalnya merupakan bagian dari transformasi Hilbert-Huang, sehingga tujuan transformasi Hilbert persamaan (2.4) digunakan untuk menghasilkan analisis sinyal *real IMF* $c(t)$ dan nilai kompleks $jc_H(t)$ sinyal untuk dapat menghasilkan amplitudo sesaat dan fase sesaat dari sinyal. Transformasi Hilbert dapat dirumuskan sebagai[13]:

$$z(t) = c(t) + jc_H(t) \quad (2.4)$$

Keterangan:

$z(t)$: Transformasi Hilbert

$c(t)$: sinyal *real* dari *IMF*

$jc_H(t)$: sinyal imajiner dari *IMF*

dimana transformasi Hilbert $c(t)$ diberikan dari $c_H(t) = c(t) * \frac{1}{\pi t}$

2.4.1 Sinyal Amplitudo

Transformasi Hilbert kemudian diterapkan pada *IMF* untuk menghasilkan analitik sinyal *IMF* berdasarkan transformasi Hilbert. Analitik sinyal amplitudo sesaat $A(t)$ persamaan (2.5) merupakan akar kuadrat dari jumlah sinyal tiap *IMF* itu sendiri dan sinyal imajiner pada waktu sesaat. Sedangkan fase sesaat $\emptyset(t)$ merupakan sudut antara *phasor* yang merupakan komponen *real* dan imajiner yang berputar dari deret waktu dengan sumbu *real* sebagai fungsi waktu persamaan (2.6) dapat didefinisikan sebagai berikut[2]:

$$A(t) = \sqrt{c^2(t) + c^2_H(t)}; \quad (2.5)$$

$$\emptyset(t) = \arctan \frac{cH(t)}{c(t)} \quad (2.6)$$

2.4.2 Instantaneous frequency

Instantaneous frequency/frekuensi sesaat $\omega(t)$ merupakan perubahan fase sesaat sebagai fungsi waktu yang didapatkan dari turunan pertama fase, dirumuskan pada persamaan (2.7) :

$$\omega(t) = \frac{d\emptyset(t)}{dt} \quad (2.7)$$

2.5 Bandwidth Modulasi Amplitudo dan Modulasi Frekuensi

Sinyal EEG yang telah didekomposisi dengan *EMD* kemudian dianalisis menggunakan tranformasi Hilbert. Hasil dari analisis berupa amplitudo sesaat dan frekuensi sesaat akan digunakan untuk mendapatkan fitur dari sinyal yaitu *bandwidth* modulasi amplitudo (B_{AM}) dan *bandwidth* modulasi frekuensi (B_{FM}) Gambar 2.5. Dalam[2] mengembangkan metode untuk mengukur perbedaan kualitas *bandwidth* dengan cara menghitung (B_{AM}) dan (B_{FM}). Untuk menghitung (B_{AM}) dan (B_{FM}) diperlukan E sebagai energi persamaan (2.8) dari sinyal $s(t)$ dengan pusat frekuensi $\langle \omega \rangle$ persamaan (2.9):

$$E = \int_{-\infty}^{\infty} |s(t)|^2 dt \quad (2.8)$$


$$\langle \omega \rangle = \frac{1}{E} \int \frac{d\phi(t)}{dt} A^2(t) dt \quad (2.9)$$

bandwidth sinyal memiliki dua istilah, satu bergantung pada amplitudo dan yang lainnya bergantung pada fase. Oleh karena itu, *bandwidth* modulasi amplitudo (B_{AM}) persamaan (2.10) dan *bandwidth* modulasi frekuensi (B_{FM}) persamaan (2.11)

didefinisikan sebagai [2]:

$$B^2_{AM} = \frac{1}{E} \int \left(\frac{dA(t)}{dt} \right)^2 dt \quad (2.10)$$

$$B^2_{FM} = \frac{1}{E} \int \left(\frac{d\phi(t)}{dt} - \langle \omega \rangle \right)^2 A^2(t) dt \quad (2.11)$$




Gambar 2.5 *Bandwidth* amplitudo modulasi dan frekuensi modulasi

2.6 Support Vector Machine (SVM)

Menurut [14] (*SVM*) pertama kali diperkenalkan oleh Boser, Guyon, Vepnik, yang dipresentasikan untuk pertama kalinya pada tahun 1992 di Annual Workshop on Computational Learning Theory. konsep dari *SVM* merupakan kombinasi harmonis dari konsep komputasi yang sudah ada puluhan tahun sebelumnya, seperti *hyperplane* dan kernel.

Prinsipnya *SVM* bekerja secara linear, dan dikembangkan untuk dapat diterapkan pada masalah non-linear. Dengan menggunakan metode *kernel trick* yang mencari *hyperplane* dengan cara mentransformasi dataset ke ruang vektor yang berdimensi lebih tinggi (*feature space*), kemudian proses klasifikasi dilakukan pada *feature space* tersebut. Penentuan fungsi *kernel* yang digunakan akan sangat berpengaruh terhadap hasil prediksi. *Pattern* yang tergabung Gambar 2.6 (a) pada *class* 1 disimbolkan dengan warna merah (kotak), sedangkan *pattern* pada *class* 2, disimbolkan dengan warna hijau (lingkaran). Problem klasifikasi dapat diterjemahkan dengan usaha menemukan garis (*hyperplane*) yang memisahkan antara kedua kelompok tersebut.



Gambar 2.6 SVM berusaha menemukan *hyperplane* terbaik yang memisahkan kedua *class* 1 dan 2 [15]

Berbagai alternatif garis pemisah (*discrimination boundaries*) ditunjukkan pada Gambar 2.6-a. *Hyperplane* pemisah terbaik antara kedua *class* dapat ditemukan dengan mengukur *margin hyperplane*

tersebut. dan mencari titik maksimalnya. *Margin* adalah jarak antara *hyperplane* tersebut dengan *pattern* terdekat dari masing-masing *class*. *Pattern* yang paling dekat dan berada tepat pada bidang pemisah disebut sebagai *support vector (SV)*. Garis solid pada Gambar 2.6-b menunjukkan *hyperplane* yang terbaik, yaitu yang terletak tepat pada tengah-tengah kedua *class*, sedangkan titik merah dan hijau yang berada dalam bidang pembatas satu dan bidang pembatas dua adalah *support vector*. Usaha untuk mencari lokasi *hyperplane* ini merupakan inti dari proses pembelajaran pada *SVM*.

Data yang tersedia dinotasikan sebagai $\vec{x}_i \in \mathfrak{R}^d$ sedangkan label masing-masing dinotasikan $y_i \in \{-1, +1\}$ untuk $i = 1, 2, \dots, l$ yang mana l adalah banyaknya data. Diasumsikan kedua *class* -1 dan $+1$ dapat terpisah secara sempurna oleh *hyperplane* berdimensi d , yang didefinisikan pada persamaan (2.12).

$$\vec{w} \cdot \vec{x} + b = 0 \quad (2.12)$$

Keterangan:

\vec{w} = Vektor w/vektor bobot (tegak lurus terhadap fungsi pemisah)

\vec{x} = nilai atribut

b = menentukan lokasi fungsi pemisah relatif terhadap titik asal (origin)

Pattern pola \vec{x}_i yang termasuk *class* -1 (sampel negatif) dapat dirumuskan sebagai *pattern* yang memenuhi pertidaksamaan(2.13)

$$\vec{w} \cdot \vec{x}_i + b \leq -1 \quad (2.13)$$

sedangkan *pattern* \vec{x}_i yang termasuk *class* $+1$ (sampel positif) pertidaksamaan(2.14)

$$\vec{w} \cdot \vec{x}_i + b \geq 1 \quad (2.14)$$

Margin terbesar dapat ditemukan dengan memaksimalkan nilai jarak antara *hyperplane* dan titik terdekatnya, yaitu $1/||\vec{w}'||$. Hal ini dapat dirumuskan sebagai *Quadratic Programming (QP) problem*, yaitu

mencari titik minimal persamaan (2.15), dengan memperhatikan nilai *constraint* persamaan (2.16).

$$\min_{\vec{w}} \tau(w) = \frac{1}{2} \|\vec{w}\|^2 \quad (2.15)$$

$$y_i(\vec{x}_i \cdot \vec{w} + b) - 1 \geq 0, \forall i \quad (2.16)$$

Problem ini dapat dipecahkan dengan berbagai teknik komputasi, di antaranya *Lagrange Multiplier* persamaan 2.17

$$L(\vec{w}, b, \alpha) = \frac{1}{2} \|\vec{w}\|^2 - \sum_{i=1}^I \alpha_i (y_i(\vec{x}_i \cdot \vec{w} + b) - 1); \\ (i = 1, 2, \dots, I) \quad (2.17)$$

α_i adalah *Lagrange multiples*, yang bernilai nol atau positif ($\alpha_i \geq 0$). Nilai optimal dari persamaan (2.17) dapat dihitung dengan meminimalkan L terhadap \vec{w} dan b , serta memaksimalkan L terhadap α_i . Dengan memperhatikan sifat bahwa pada titik optimal *gradient* $L = 0$, persamaan (2.17) dapat dimodifikasi sebagai maksimalisasi problem yang hanya mengandung α_i , sebagaimana persamaan (2.18) dan (2.19).

Minimize:

$$\sum_{i=1}^I \alpha_i - \frac{1}{2} \sum_{i,j=1}^I \alpha_i \alpha_j y_i y_j \vec{x}_i \cdot \vec{x}_j \quad (2.18)$$

Subject to:


$$\alpha_i \geq 0 \quad (i = 1, 2, \dots, I) \quad \sum_{i,j=1}^I \alpha_i y_i = 0 \quad (2.19)$$

Dari hasil dari perhitungan ini diperoleh α_i yang kebanyakan bernilai positif. Data yang berkorelasi dengan α_i yang positif inilah yang disebut sebagai *support vector*.

2.6.1 Fungsi Kernel

Tidak semua data dapat dipisahkan secara linier, sedangkan *SVM* pada dasarnya hanya mampu memisahkan data secara linier saja, sehingga diperlukan sebuah pengembangan untuk dapat membuat *SVM* mampu memisahkan data non-linier, salah satunya dengan menambahkan fungsi kernel. Dengan menambahkan fungsi kernel pada *SVM* nantinya data akan dipetakan ke ruang vektor yang lebih tinggi hingga *hyperplane* dapat dikonstruksikan [14].

Pemetaan tersebut bertujuan untuk tetap menjaga topologi data, artinya dua data yang semula dekat pada input *space* akan tetap dekat pada *feature space*, begitu pula sebaliknya data yang pada awalnya jauh akan tetap jauh. Kemudian dari data yang sudah ditransformasikan pada ruang yang lebih tinggi tersebut dilakukan perhitungan *dot product* untuk mendapatkan titik-titik *support vector*. Karena sulitnya menemukan fungsi dari transformasi atau fungsi Φ tersebut, maka perhitungan *dot product* dapat digantikan dengan fungsi kernel $K(x, x_i)$ yang mendefinisikan fungsi transformasi sebelumnya secara implisit inilah yang disebut dengan “kernel *trick*” [14]



Gambar 2.7 Ilustrasi *hyperplane* pada dimensi yang lebih tinggi [14]

Fungsi kernel yang digunakan untuk memetakan dimensi awal (dimensi yang lebih rendah) himpunan data ke dimensi baru (dimensi yang relatif lebih tinggi).

Nama Kernel	Fungsi Kernel
<i>Polynomial</i>	$K(x, x_i) = (x^T x_i + 1)^l$
<i>RBF</i>	$K(x, x_i) = e^{\frac{-\ x-x_i\ ^2}{2\sigma^2}}$
<i>Mexican hat</i>	$K(x, x_i) = \prod_{k=1}^d \left[1 - \frac{(x^k - x_i^k)^2}{a^2} \right] e^{\frac{-\ x-x_i\ ^2}{2\sigma^2}}$
<i>Morlet</i>	$K(x, x_i) = \prod_{k=1}^d \cos \left[w_0 \frac{(x^k - x_i^k)^2}{a^2} \right] e^{\frac{-\ x-x_i\ ^2}{2\sigma^2}}$

Tabel 2.1 Beberapa jenis kernel yang digunakan dalam SVM

Pada Tabel 2.1 dimana fungsi K untuk semua vektor input x, x_i , l adalah degree dari kernel *polynomial*, σ adalah besarnya control untuk fungsi *RBF*, a merupakan dilatasi pada fungsi kernel *mexican hat* dan *morlet*. Beberapa macam kernel yang digunakan dalam SVM [2].

2.7 Evaluasi Kerja

2.7.1 Confusion Matrix

Confusion matrix adalah sebuah tabel yang menyatakan jumlah data uji yang benar diklasifikasikan dan jumlah data uji yang salah diklasifikasikan. *Confusion matrix* untuk klasifikasi ditunjukkan pada tabel 2.2.

	Prediksi Positif(1)	Prediksi Negatif(0)
Keadaan Positif(1)	Benar Positif (<i>TP</i>)	Salah Negatif (<i>FN</i>)
Keadaan Negatif(0)	Salah Positif (<i>FP</i>)	Benar Negatif (<i>TN</i>)

Tabel 2.2 Confusion Matrix untuk klasifikasi

Keterangan untuk tabel 2.2 dinyatakan sebagai berikut:

- *True Positive (TP)*, yaitu jumlah data dari kelas 1 yang benar dan diklasifikasikan sebagai kelas 1.
- *True Negative (TN)*, yaitu jumlah data dari kelas 0 yang benar diklasifikasikan sebagai kelas 0.
- *False Positive (FP)*, yaitu jumlah data dari kelas 0 yang salah diklasifikasikan sebagai kelas 1.
- *False Negative (FN)*, yaitu jumlah data dari kelas 1 yang salah diklasifikasikan sebagai kelas 0.

Untuk mengevaluasi hasil klasifikasi maka diperlukan pengujian dengan melakukan perhitungan akurasi (*Acc*), sensitifitas (*SEN*), spesififikasi(*SPE*).

Dimana Akurasi merupakan suatu kondisi dalam keadaan benar dan diprediksi kedalam keadaan benar untuk menghitung akurasi dapat dilihat pada persamaan 2.20.

$$Acc = \frac{TP+TN}{TP+TN+FP+FN} \times 100 \quad (2.20)$$

Spesifitas merupakan suatu kondisi dalam keadaan negatif dan diprediksi kedalam keadaan benar negatif persamaan 2.21.

$$SPE = \frac{TN}{TN+FP} \times 100 \quad (2.21)$$

Sensitifitas merupakan suatu kondisi dalam keadaan positif dan diprediksi kedalam keadaan benar persamaan 2.22.

$$SEN = \frac{TP}{TP+FN} \times 100 \quad (2.22)$$

2.7.2 *K-Fold Cross Validation*

Pada suatu sistem evaluasi merupakan bagian penting , Salah satunya diantara bagian penting tersebut adalah *K-Fold Cross Validation*. *K-fold cross validation* adalah teknik yang dapat digunakan apabila memiliki jumlah data yang terbatas (jumlah *instance* tidak banyak) [16].

Secara umum *10-fold cross-validation* dianjurkan untuk memperkirakan akurasi karena bias dan variansi yang relatif rendah. *K-fold cross validation* merupakan salah satu metode yang digunakan untuk mengetahui rata-rata keberhasilan dari suatu sistem dengan cara melakukan perulangan dengan mengacak atribut masukan sehingga sistem tersebut teruji untuk beberapa atribut input yang acak. Dengan metode ini data dikelompokkan menjadi *k* kelompok.

K-fold cross validation diawali dengan membagi data sejumlah *n-fold* yang diinginkan. Dalam proses *cross validation* data akan dibagi dalam *n* buah partisi dengan ukuran yang sama $D_1, D_2, D_3, \dots, D_n$ selanjutnya proses *testing* dan *training* dilakukan sebanyak *n* kali. Dalam iterasi ke-*i* partisi D_i akan menjadi data *testing* dan sisanya akan menjadi data *training*. Untuk penggunaan jumlah fold terbaik untuk uji validitas, dianjurkan menggunakan *10-fold cross validation* dalam model[16]. Skenario pengujian merupakan tahap penentuan pengujian yang dilakukan. Pengujian dilakukan menggunakan metode *k-cross validation* dengan nilai *k* sebanyak *10 fold*, *10-fold cross validation* akan mengulang pengujian sebanyak 10 kali dan hasil pengukuran adalah nilai rata-rata dari 10 kali pengujian pengujian ini bertujuan untuk mengetahui akurasi metode *Support Vector Machine* diterapkan pada analisis sentimen jika diuji dengan data *training* dan data *testing* yang berbeda . Penggunaan 10

fold ini dianjurkan karena merupakan jumlah *fold* terbaik untuk uji validitas[16].

Tahap pengujian dengan menggunakan metode *10-fold cross validation* membagi dataset yang awalnya berjumlah 500 data akan dibagi menjadi 10 *subset*(bagian) masing-masing terbagi dengan data training random dan satu subset dengan nilai random digunakan sebagai data *testing*, dimana data yang masuk dalam training tidak boleh menjadi data testing.Selanjutnya proses *training* dan *testing* dilakukan sampai *fold* kesepuluh. Tabel 2.3 merupakan gambaran *K-fold validasion*

Fold-1	1	2	3	4	5	6	7	8	9	10
Fold-2	1	2	3	4	5	6	7	8	9	10
Fold-3	1	2	3	4	5	6	7	8	9	10
Fold-4	1	2	3	4	5	6	7	8	9	10
Fold-5	1	2	3	4	5	6	7	8	9	10
Fold-6	1	2	3	4	5	6	7	8	9	10
Fold-7	1	2	3	4	5	6	7	8	9	10
Fold-8	1	2	3	4	5	6	7	8	9	10
Fold-9	1	2	3	4	5	6	7	8	9	10
Fold-10	1	2	3	4	5	6	7	8	9	10

Tabel 2.3 *K-fold cross validation* untuk klasifikasi

2.7.3 *Receive Operating Characteristics (ROC)*

Validasi pada klasifikasi selain dilakukan dengan penghitung, tingkat akurasi (*Acc*), sensitifitas (*SEN*), spesifikasi(*SPE*) juga dilakukan penghitungan menggunakan nilai *AUC (Area Under the ROC Curve)*[2]. Dengan menggunakan nilai *FPR* dan *TPR* dimana kurva *ROC* dibuat berdasarkan nilai telah didapatkan pada perhitungan dengan *confusion matrix*, yaitu antara *False Positive Rate (FPR)* dengan *True Positive Rate (TPR)* dimana:

FPR merupakan suatu keadaan negatif tetapi diprediksi dalam keadaan positif persamaan 2.23

$$FPR = \frac{FP}{TN+FP} \times 100 \quad (2.23)$$

TPR merupakan suatu keadaan negatif dan diprediksi dalam keadaan negatif persamaan 2.24

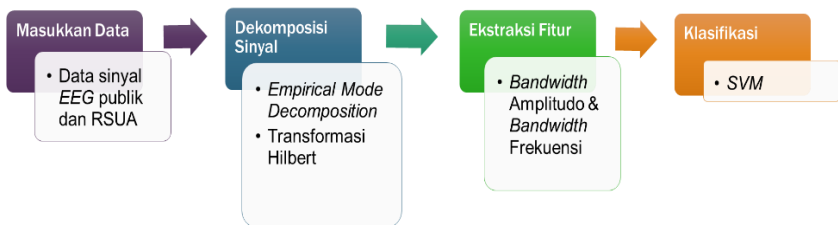
$$TPR = \frac{TP}{TP+FN} \times 100 \quad (2.24)$$

BAB 3

DESAIN DAN IMPLEMENTASI SISTEM

Penelitian ini dilaksanakan sesuai dengan desain sistem dan implementasinya. Desain sistem merupakan konsep dari pembuatan dan perancangan infrastruktur dan kemudian diwujudkan dalam bentuk blok-blok alur yang harus dikerjakan. Pada bagian implementasi merupakan pelaksanaan teknis untuk setiap blok pada desain sistem.

3.1 Desain Sistem



Gambar 3.1 Blok diagram penelitian

Penelitian ini bertujuan untuk melakukan klasifikasi kondisi kejang penderita epilepsi. Adapun tahapan proses yang dilakukan dapat dilihat pada Gambar 3.1. Diawali dengan memproses sinyal yang terdapat pada suatu file untuk dilakukan dekomposisi sinyal menggunakan metode *EMD* dengan proses yang dinamakan *shifting* untuk mendapatkan sinyal dengan frekuensi yang lebih konstan. Dari proses *shifting* dihasilkan fungsi mode intrinsik (*IMF*) kemudian dengan menggunakan transformasi Hilbert, *IMF* akan di analisis. Hasil dari analisis menggunakan transformasi Hilbert dapat digunakan untuk mendapatkan amplitudo serta frekuensi sesaat kemudian akan digunakan untuk mendapatkan fitur (B_{AM}) dan (B_{FM}). Fitur (B_{AM}) dan (B_{FM}) yang didapatkan akan dimanfaatkan sebagai input bagi *SVM*.

3.2 Implementasi Sistem

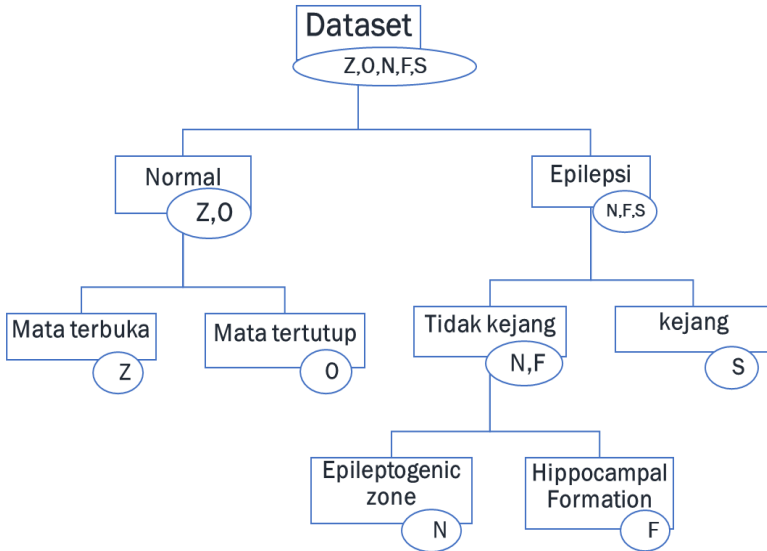
Secara garis besar, ada empat proses pada bagian implementasi tugas akhir ini yaitu:

1. Pengumpulan Data
Data sinyal *EEG* yang didapatkan dari data publik yaitu *EEG* dataset yang dapat diambil dari “Klinik für Epileptologie, Universität Bonn” dan data dari “Rumah Sakit Umum Airlangga”.
2. Dekomposisi Sinyal.
Data yang telah didapatkan kemudian didekomposisi sinyal menggunakan metode *EMD* sehingga menghasilkan *IMF*.
3. Transformasi Hilbert
IMF yang telah diperoleh, dengan menggunakan transformasi Hilbert akan didapatkan amplitudo sesaat dan frekuensi sesaat yang dapat digunakan untuk mencari fitur pada sinyal.
4. Ekstraksi Fitur
Dari hasil perhitungan amplitudo sesaat dan frekuensi sesaat yang telah didapat akan diproses untuk mendapatkan fitur, yaitu (B_{AM}) dan (B_{FM}).
5. Klasifikasi
Dari hasil fitur yaitu (B_{AM}) dan (B_{FM}) akan digunakan sebagai inputan dalam proses klasifikasi menggunakan *SVM*.

3.2.1 Pengumpulan Data

3.2.1.1 Data Publik


Data yang digunakan sebagai input untuk diolah dan dilakukan pengujian untuk mendapatkan hasil klasifikasi dengan dekomposisi sinyal menggunakan *EMD* menghasilkan (B_{AM}) serta (B_{FM}) untuk mendapatkan fitur sebagai inputan klasifikasi. Data publik diperoleh dari “Klinik für Epileptologie, Universität Bonn” yang dapat diakses secara online[5].



Gambar 3.2 Blok diagram data penelitian

Dataset yang digunakan terdapat lima folder yaitu (Z,O,N,F dan S) Gambar 3.2 dengan kondisi Z,,O,N,F(tidak kejang) dan S (kejang). Dimana setiap folder berisi 100 file data sinyal *EEG single-channel* yang telah dibersihkan dari derau dengan durasi setiap file 23,6 detik serta frekuensi sampling 173,61 Hz sehingga didapatkan 4097 nilai.


Hasil perekaman yang terdapat pada folder Z dengan kondisi mata terbuka dan folder O kondisi mata tertutup yang diambil dari lima sukarelawan sehat direkam dengan cara ekstrakanial. Sedangkan pada folder N,F,S direkam pada pasien epilepsi secara *intrakranial* dimana folder N dan F pada keadaan tidak kejang dengan folder N pada daerah *hippocampal formation* dan folder F pada *epileptogenic zone* sedangkan folder S diambil pada saat kejang[2]. Pada Gambar 3.3 merupakan contoh file sinyal yang diambil pada masing-masing folder.



Gambar 3.3 Contoh sinyal *EEG* dari masing-masing dataset

3.2.1.2 Data RSUA

Data yang didapat dari RSUA/data lokal merupakan data hasil perekaman *EEG* dengan cara *ekstrakranial* menggunakan sistem standart internasional 10-20. Data yang didapat dari banyak elektroda kemudian direferensikan ke salah satu channel sehingga hasil rekaman *EEG* disebut montase monopolar. Channel referensi yang digunakan adalah Cz dimana channel Cz merupakan channel yang letaknya di tengah/di pusat otak. Rekamana *EEG* yang dilakukan kurang lebih dilakukan selama 30 menit kemudian sinyal akan diseleksi sehingga menjadi data sinyal tunggal dari sebuah elektroda dengan durasi selama 10 detik, dengan sampling interval 2mildetetik sehinga didapatkan nilai sebanyak 5000. Sinyal telah di filter dengan *high pass filter* sebesar 35-70 Hz. Data yang didapat masih mengandung *artifact* fisiologi dan akan dikelompokkan menjadi lima folder dengan kriteria sama seperti pada data publik. Adapun contoh data hasil perekaman *EEG* Gambar 3.4



Gambar 3.4 Data sinyal dari hasil perekaman *EEG*

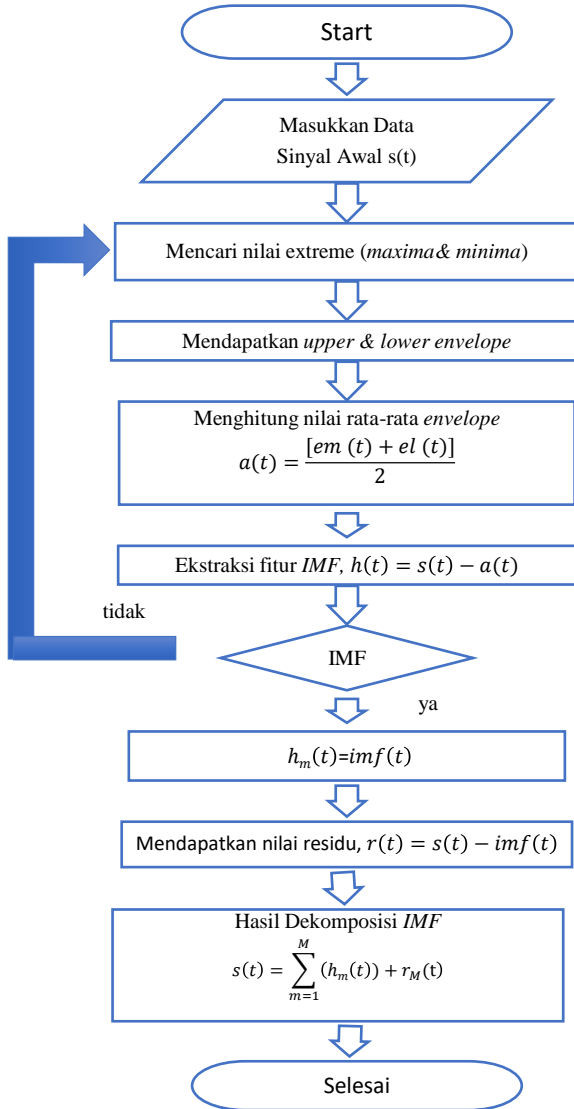
Adapun selama melakukan rekamana sinyal *EEG* pasien diberikan beberapa stimulasi yaitu pasien diinstruksikan untuk membuka mata, menutup mata, hiperventilasi dan *strobe light flashes* Data yang didapat dari lokal Tabel 3.1 dengan total sebanyak enam pasien. Pada pasien pertama dan kedua didapatkan data untuk folder A dengan kondisi perekaman mata terbuka, folder B dengan kondisi mata tertutup, kemudian pasien ketiga sampai ke enam merupakan pasien epilepsi dengan dipengaruhi ketika perekaman tidak terjadi kejang sehingga didapatkan untuk data folder C dengan pusat gelombang kejang (*epiloptogenic zone*) dan folder D dengan kondisi titik terjauh dari pusat gelombang kejang (*hippocampal formation of the opposite hemisphere of the barin*) dan juga pada saat perekaman pasien mengalami kejang sehingga data dapat dimasukkan pada folder folder E.

<i>Pasien</i>	<i>Keterangan</i>
1	Normal
2	Normal
3	Gelombang kejang(Temporal)
4	Gelombang kejang (Temporal)
5	Epilepsi(Prefrontal)
6	Epilepsi(Prefrontal)

Tabel 3.1 Data rekaman *EEG* yang didapat dari RSUA

3.2.2 Dekomposisi Sinyal menggunakan *EMD*

Dari data sinyal yang telah didapatkan yaitu data publik dan data lokal maka sinyal akan didekomposisi dengan metode *EMD*. Proses yang dilakukan dalam yaitu *shifting* proses. Konsep dari dekomposisi sinyal dengan *EMD* adalah untuk mengidentifikasi skala waktu yang tepat guna menunjukkan karakteristik fisik sinyal, untuk dapat mengubah sinyal ke mode intrinsik dengan fungsi, yang disebut sebagai fungsi mode intrinsik (*IMF*)[2] dan residu. Sehingga untuk mendapatkan sinyal awal dengan cara menjumlahkan *IMF* dan residu.



Gambar 3.5 Diagram proses EMD

Adapun proses dekomposisi sinyal dengan EMD dapat dilihat pada Gambar 3.5 dari gambar diagram diketahui bahwa IMF yang dihasilkan akan memiliki amplitudo yang berbeda-beda. Besarnya nilai amplitudo

akan berbanding terbalik dengan besarnya *IMF*, semakin besar nilai *IMF* maka semakin kecil nilai amplitudo.

3.2.3 Transformasi Hilbert

Setelah dilakukan dekomposisi sinyal *EEG* menggunakan *EMD* dan menghasilkan *IMF*, dimana setiap *IMF* yang dihasilkan akan dilakukan analisa sinyal pada domain waktu frekuensi menggunakan transformasi hilbert persamaan (2.4) ini bertujuan untuk menghasilkan sinyal imajiner dari sinyal nyata yang akan digunakan untuk mendapatkan amplitudo & frekuensi sesaat dari *IMF* yang telah didapatkan.


3.2.4 Ekstraksi Fitur

Fitur yang akan digunakan pada tugas akhir ini adalah dari *bandwidth* sinyal, dimana *bandwidth* sinyal didapatkan dari *IMF* yang telah didapatkan pada proses dekomposisi sinyal. Pada *IMF* yang telah didapatkan akan dilakukan analisis sinyal terlebih dahulu untuk mendapatkan *bandwidth* dengan nama (B_{AM}) dan (B_{FM}). Dimana berdasarkan referensi [2] *IMF* yang akan digunakan sebagai masing-masing fitur (B_{AM}) dan (B_{FM}) yaitu empat *IMF* pertama sebagai inputan *SVM* karena setelah *IMF* ke-empat perbedaan *IMF* tidak begitu signifikan. Adapun untuk mendapatkan fitur (B_{AM}) persamaan (2.10) dan (B_{FM}) persamaan (2.11) dimana E persamaan (2.9) merupakan energi dari sinyal $s(t)$.

3.2.5 Klasifikasi

Untuk klasifikasi digunakan *SVM*. *SVM* merupakan teknik *supervised learning* yang banyak digunakan untuk klasifikasi dengan meminimalkan eror dan memaksimalkan margin serta menentukan *hyperplane* sebagai pemisah yang digunakan untuk identifikasi kelas data yang berbeda dengan formulasi *quadratic programming*. Pada tugas akhir ini klasifikasi dengan menggunakan *SVM*, dimana formulasi *training* data untuk klasifikasi kondisi kejang dan dan tidak kejang digunakan formulasi batasan kesetaraan. Untuk memaksimalkan batasan-batasan margin maka digunakan berbagai macam fungsi kernel yaitu kernel *RBF*, *polynomial*, *mexican hat* dan *morlet* untuk memetakan data training ke dalam ruang kernel. Data yang digunakan untuk klasifikasi dengan *SVM* adalah data yang telah didapatkan dari masing-masing empat fitur pertama (B_{AM}) dan (B_{FM}) dari setiap folder yaitu Z,O,N,F dan S. Sehingga didapatkan delapan fitur dengan masing-masing

100 data setiap folder yang akan digunakan sebagai inputan SVM, dimana data dengan kondisi kejang akan bernilai “1” sedangkan data tidak kejang akan bernilai “0” dengan data yang akan digunakan sebagai data *training* masing-masing sebanyak 80% dan data *testing* sebanyak 20% dari jumlah data yang ada. Fitur-fitur yang akan digunakan sebagai *training* dimasukkan pada variabel X sedangkan nilai Y akan diberikan nilai “1” atau “0” bergantung pada kondisi ketika kejang atau tidak kejang. Kedua variabel X dan Y bersama dengan variabel *X_testing* dan *Y_testing* akan menjadi inputan untuk melakukan klasifikasi dengan SVM. Diagram klasifikasi Gambar 3.6



Gambar 3.6 Diagram Klasifikasi SVM

3.2.6 Evaluasi Kerja

Pengujian yang dilakukan menggunakan *confussion matriks* dapat menghasilkan nilai akurasi dinyatakan dalam persamaan(2.20), spesifikasi dinyatakan dalam persamaan(2.21), sensitifitas dinyatakan

dalam persamaan(2.22) FPR persamaan(2.23) dan TPR persamaan(2.24) selain itu juga dilakukan evaluasi dengan menggunakan ROC untuk mendapatkan daerah AUC (*Area Under the ROC Curve*). Area ini menunjukkan luasan kurva untuk membandingkan suatu hasil dengan hasil yang lain dengan nilai yang didapat dari FPR dan TPR . Untuk menguji akurasi, sensitifitas, spesififikasi, FPR dan TPR maka dengan menggunakan metode K -fold validation dilakukan suatu penempatan untuk melakukan *training* dan *testing* menjadi beberapa *fold*. *Fold* yang digunakan dalam penelitian ini berdasarkan studi literatur yang telah dilakukan berjumlah 10 [2]. Data akan dibagi menjadi 10 bagian. Satu data *fold* akan berfungsi sebagai data *testing* dan sembilan *fold* yang lain akan menjadi data *training* pengujian dilakukan sebanyak K yaitu 10 kali. Setiap percobaan nilai akurasi akan disimpan dan kemudian akan dicari nilai rata-rata akurasinya. Hal ini berguna untuk mengetahui tingkat prediksi yang diklasifikasikan benar dengan banyaknya dataset yang digunakan.

BAB 4

HASIL KERJA DAN PENGUJIAN

Bab ini membahas mengenai hasil kerja dari metodologi penelitian yang telah dipaparkan, dapat dilihat pada bab sebelumnya dan evaluasi dari penelitian yang telah dikerjakan. Adapun hasil kerja yang dilakukan dari beberapa tahapan yang telah dirancang berupa pengumpulan data sinyal *EEG*, dekomposisi sinyal dan analisa hasil dekomposisi sinyal, ekstraksi fitur serta hasil proses klasifikasi. Adapun evaluasi yang digunakan untuk mengukur kinerja sehingga didapatkan keputusan untuk menjawab permasalahan yang telah dirumuskan di awal.

4.1 Pengumpulan Data

Pada penelitian ini digunakan dua dataset yang didapatkan dari data publik dan data dari lokal untuk mengetahui hasil dari masing-masing dataset. Pengumpulan data publik yang dilakukan seperti yang telah dipaparkan pada bab sebelumnya, data yang digunakan didapatkan dari data publik yang dapat diakses secara online pada situs milik “Klinik für Epileptologie, Universität Bonn”[5]. Data yang didapatkan untuk penelitian tugas akhir ini yaitu lima folder Z,O,N,F dan S dimana setiap folder berisi masing-masing file berjumlah 100, dengan durasi 23,6 detik dan frekuensi sampling sebesar 173,61 Hz sehingga didapatkan data dengan panjang 4097 nilai. Sehingga lima folder yang didapat dengan masing-masing folder berisi 100 data berformat *.txt* dengan masing-masing file berisi nilai sepanjang 4097.

Untuk mengolah masing-masing folder maka dibuatlah sebuah matrik $m \times n$ dimana untuk masing-masing folder yang berisi banyak baris (m) menunjukkan tabel yang berisi nilai-nilai dari masing-masing file. Sedangkan tabel dengan banyaknya kolom merepresentasikan banyaknya file pada satu folder.

Sedangkan untuk dataset lokal yang didapatkan dengan jumlah total pasien enam orang dengan hasil perekaman *EEG* standart internasional sistem 10/20 multi channel. Data hasil perekaman disimpan dalam bentuk *ascii*. Setelah itu data yang didapatkan dipilih sesuai dengan referensi yang telah diberikan oleh tenaga medis.

Time	16.32.25	elapsed	00.00.17	epoch	2/182
	16.36.40		00.04.32		28/182
	16.42.32		00.10.25		63/182
	09.09.18		00.00.47		5/185
	09.09.26		00.00.55		6/185


Tabel 4.1 Keterangan waktu kejadian pada data EEG

Pada Tabel 4.1 merupakan contoh keterangan yang diberikan oleh ahli medis, dimana pada *time* merupakan waktu kejadian sedangkan *elapsed* merupakan lamanya kejadian dengan satuan detik selain itu juga terdapat *epoch* yang menandakan jangka waktu tiap halaman perekaman, dimana setiap halaman *epoch* jangka waktunya adalah 10 detik dengan frekuensi interval 2milidetik sehingga didapatkan sampling frekuensi sebesar 500 Hz dan didapatkan panjang setiap data sebanyak 5000 nilai. Langkah selanjutnya data EEG dipisahkan menjadi *singel channel* dengan panjangnya data 5000 nilai kemudian disimpan dalam file berbentuk *.txt* untuk dikelompokkan menjadi lima folder sama seperti pada data publik dengan masing-masing setiap folder berjumlah 100 file. Banyaknya pasien berjumlah enam orang Tabel 3.1 Dimana pada pasien pertama dan kedua diambil dari setiap channel dengan total 22 channel untuk dimasukkan ke dalam folder A dan B yaitu folder mata terbuka dan folder mata tertutup. Sedangkan pasien ketiga sampai dengan keenam akan dikelompokkan ke dalam *epileptogenic zone* dan *hippocampal formation of the opposite hemisphete* karena data yang diperoleh mengandung gelombang kejang, adapun data yang didapat adalah bagian temporal maka jika epileptogenic zone berada di temporal kiri *channel* yang dapat digunakan adalah (T_1, T_3, T_5) dan *hippocampal formation of the opposite hemisphete* adalah (T_2, T_4, T_6) sedangkan jika epileptogenic zone berada di temporal kanan *channel* yang dapat digunakan adalah (T_2, T_4, T_6) dan *hippocampal formation of the opposite hemisphete* adalah (T_1, T_3, T_5). Hasil dari masing-masing data akan dimasukkan ke dalam folder C untuk data *hippocampal formation of the opposite hemisphete* dan folder D untuk data pada *epileptogenic zone* . Untuk pasien kelima dan keenam karena dalam proses perekaman mengalami kondisi kejang pada prefrontal FP dan channel yang digunakan adalah semua channel untuk dimasukkan pada folder E.

4.2 Preprocessing Data


4.2.1 Proses Dekomposisi Sinyal

Pada Gambar 4.1 merupakan salah satu contoh sinyal awal yang akan dilakukan dekomposisi sinyal, pada tahap awal dengan sinyal masukan data sinyal *EEG* pada setiap folder yang berformat *.txt* baik data




Gambar 4.1 Sinyal Awal

publik maupun data dar lokal akan dicari nilai *extreme* (*local maxima* dan *local minima*) dan memberikan tanda pada setiap extreme baik *local maxima* dan *local minima*, kemudian setelah semua *local maxima* dan *local minima* diidentifikasi Gambar 4.2 maka hubungkan semua *local maxima* dan *local minima* dimana *envelope maxima* untuk *local maxima* dan *envelope minima* untuk *local minima* pada sinyal dengan menggunakan interpolasi kubik *spline*



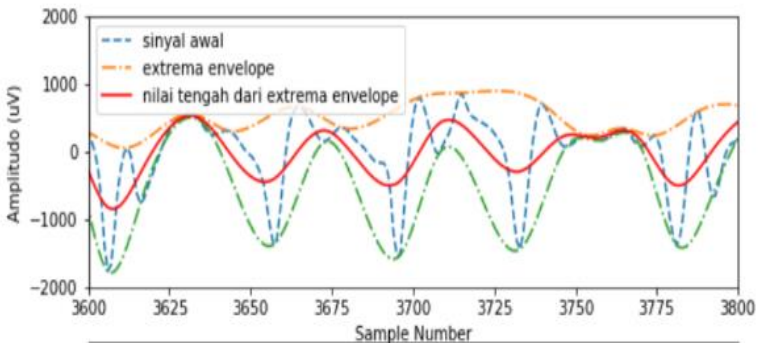
Gambar 4.2 Mendapatkan nilai *extreme* sinyal

maka setiap puncak lokal *maxima* dan puncak *local minima* akan dihubungkan Gambar 4.3. Setelah sinyal terhubung antara *envelope maxima* dan *envelope minima* langkah selanjutnya adalah mencari nilai tengah dengan cara menjumlahkan antara *envelope maxima* dan *envelope minima* kemudian membaginya menjadi dua sehingga didapatkan nilai tengah seperti yang terlihat pada gambar 4.4.



Gambar 4.3 Mendapatkan nilai *envelope* sinyal


Dari nilai tengah yang telah didapatkan dari setiap sinyal awal kemudian dilakukan proses untuk mendapatkan *IMF*, *IMF* merupakan sinyal yang didapatkan ketika sinyal awal dikurangi dengan nilai tengah. Proses untuk mendapatkan *IMF* dinamakan proses shifting.



Gambar 4.4 Mendapatkan nilai tengah dari sinyal

Dalam proses *shifting IMF* yang didapat akan dijadikan inputan untuk mendapatkan nilai *IMF* selanjutnya hingga didapatkan hasil yang optimal, dan dari proses dekomposisi sinyal mendapatkan komponen sisa (residu), dimana jika *IMF* dijumlahkan dengan residu akan mengembalikan sinyal ke sinyal awal.


Hasil dekomposisi sinyal menggunakan *EMD* dengan hasil dekomposisi berupa nilai *IMF*. Gambar 4.5 merupakan hasil dari *IMF EEG* kejang.



Gambar 4.5 Dekomposisi Sinyal *EEG* kejang

Pada sinyal masukan *EEG* kejang hasil *IMF* pertama memiliki nilai amplitudo yang lebih tinggi daripada *IMF* kedua, hasil *IMF* kedua memiliki amplitudo yang lebih tinggi daripada *IMF* ketiga, demikian seterusnya sampai *IMF* terakhir.

Untuk hasil pada sinyal masukan *EEG* normal pada *IMF* juga sama seperti *EEG* kejang dimana hasil *IMF* pertama memiliki nilai amplitudo yang lebih tinggi daripada *IMF* kedua, hasil *IMF* kedua memiliki amplitudo yang lebih tinggi daripada *IMF* ketiga, demikian seterusnya. Hasil dari *IMF EEG* normal dapat dilihat pada Gambar 4.6




Gambar 4.6 Dekomposisi Sinyal *EEG* normal

Dari hasil dekomposisi yang telah dilakukan, baik dekomposisi pada *EEG* kejang dan *EEG* normal nilai amplitudo yang dihasilkan berbeda-beda, besarnya nilai *IMF* berbanding terbalik dengan besarnya amplitudo yang dihasilkan dimana semakin besar *IMF* yang dihasilkan maka semakin kecil nilai amplitudo.


4.2.2 Analisis Sinyal

Hasil dekomposisi dari sinyal *EEG* yang bersifat non linier dan non stasioner, pada setiap data yang telah di dekomposisi dengan *EMD* menghasilkan beberapa *IMF* dan satu buah residu. Setelah didapatkan *IMF* kemudian akan di analisis sinyal yang dilakukan dengan pendekatan empiris pada domain waktu frekuensi menggunakan metode transformasi Hilbert yang ditemukan oleh N.E Huang. Dari hasil analisis sinyal didapatkan nilai real dari setiap *IMF* dan nilai imajiner *IMF* untuk dapat menghasilkan amplitudo sesaat serta frekuensi sesaat.




Gambar 4.7 Amplitudo sesaat pada sinyal kejang

Amplitudo sesaat yang didapatkan dari dari *IMF* baik pada kondisi kejang Gambar 4.7 dan amplitudo sesaat tidak kejang Gambar 4.8 menunjukkan perbedaan *amplitude envelope* dari *IMF* yang dihasilkan sinyal *EEG* dalam keadaan tidak kejang perbedaannya lebih besar daripada sinyal *EEG* saat terjadinya kejang. Nilai yang dihasilkan oleh *amplitude envelope* didapatkan dari akar persamaan kuadrat (2.5)




Gambar 4.8 Amplitudo sesaat pada sinyal tidak kejang

Frekuensi sesaat yang didapatkan dari *IMF* pada kondisi kejang
Gambar 4.9



Gambar 4.9 Frekuensi sesaat pada sinyal kejang

dan frekuensi sesaat sinyal tidak kejang Gambar 4.10 menunjukkan perbedaan yang terlihat dari frekuensi sesaat pada sinyal *EEG* kondisi kejang tingkat perubahan frekuensi modulasi lebih rendah daripada sinyal *EEG* tidak kejang. Nilai yang dihasilkan oleh frekuensi sesaat yang didapatkan dari akar persamaan kuadrat (2.7)



Gambar 4.10 Frekuensi sesaat pada sinyal tidak kejang

4.2.3 Ekstraksi Fitur

Ekstraksi fitur dengan (B_{AM}) dan (B_{FM}) yang akan digunakan sebagai inputan *SVM* untuk melakukan klasifikasi didapat dari nilai-nilai amplitudo sesaat dan frekuensi sesaat dimana akan dimanfaatkan untuk mendapatkan fitur (B_{AM}) dan (B_{FM}) dari empat *IMF* pertama dengan mengacu pada studi literatur[2] menggunakan perhitungan statistika *P-value*. Dari fitur *bandwidth* empat *IMF* pertama memiliki *P-value* kecil sehingga sinyal *EEG* tidak dapat diklasifikasikan hanya dengan menggunakan *threshold*. Oleh karena itu didapatkan total delapan fitur yang akan menjadi inputan dimana hasil dari ekstraksi fitur pada (B_{AM1} - B_{AM4}) dan (B_{FM1} - B_{FM4}).

Berdasarkan referensi yang digunakan[2] dari hasil amplitudo sesaat pada data sinyal *EEG* kondisi tidak kejang perbedaan amplitudo sesaat lebih tinggi sehingga membuat fitur (B_{AM}) dari *IMF* sinyal *EEG* pada kondisi tidak kejang lebih besar daripada sinyal *EEG* kondisi kejang. Sedangkan frekuensi sesaat dari *IMF* menunjukkan frekuensi modulasi lebih rendah terjadi pada sinyal *EEG* keadaan kejang dengan nilai (B_{FM}) lebih kecil jika dibandingkan dengan *IMF* sinyal *EEG* keadaan tidak kejang.

4.3 Klasifikasi

Setelah dilakukan ekstraksi fitur pada data rekaman *EEG* hasil dari ekstraksi fitur kemudian digunakan untuk proses klasifikasi. Pada penelitian ini klasifikasi dilakukan dengan menggunakan metode *SVM*, *SVM* merupakan salah satu metode *supervised learning*, dimana data telah dilatih dan terdapat target untuk mengelompokkan suatu data. Untuk melakukan proses klasifikasi data yang telah didapat dari hasil ekstraksi fitur akan dibagi menjadi kelompok data *training* dan kelompok data *testing*.

Dimana data yang akan digunakan adalah data dengan delapan kolom sebagai banyaknya fitur dengan empat kolom pertama sebagai fitur dari B_{AM} empat kolom terakhir sebagai fitur dari B_{FM} dan satu kolom digunakan untuk memberikan label kelas pada masing-masing data jika data *EEG* kejang maka akan diberi nilai "1" sedangkan untuk label kelas tidak kejang diberi nilai "0" yang akan digunakan untuk proses klasifikasi. Pada Tabel 4.2 merupakan salah satu contoh proses yang dilakukan dalam klasifikasi dimana baris digunakan sebagai banyaknya data hasil ekstraksi fitur dengan setiap data ekstraksi fitur berisi 500 data, dengan data sebanyak 400 nilai merupakan data pada kelas tidak kejang dan 100 nilai lagi merupakan kelas pada keadaan normal. Pada proses

klasifikasi ini menggunakan perbandingan 80:20 dari keseluruhan data. Jadi dari 500 nilai setiap baris data akan dikelompokkan menjadi X sebagai data fitur sedangkan y sebagai label kelas Tabel 4.2.

Implementasi *SVM* dengan inputan parameter-parameter, $X_{training}$ sebagai variabel yang berisi 400 data *training* dari setiap fitur dan $X_{testing}$ sebagai variabel yang berisi 100 data testing. Untuk kelas yang akan dikelompokkan dengan variabel $y_{training}$ berisi data kelas untuk proses training, sedangkan variabel $y_{testing}$ berisi kelas untuk proses *testing*. Pada *SVM* terdapat beberapa macam-macam fungsi kernel yang umum digunakan untuk mengoptimalkan hasil yaitu fungsi kernel *RBF*, *polynomial*, *mexican hat* dan *morlet*.

	Bam4	Bfm4	keadaan
0	0.590	0.211	0.0
1	0.910	0.261	0.0
2	0.294	0.149	0.0
3	0.749	0.248	0.0
4	0.064	0.019	1.0
5	0.604	0.284	0.0
6	0.390	0.735	0.0
7	0.625	0.028	1.0
8	0.303	0.229	0.0
9	0.488	0.066	1.0

Tabel 4.2 Contoh hasil ekstraksi fitur pada B_{AM4} dan B_{FM4} serta label kelas

4.3.1 Confusion Matrix

Setelah didapatkan hasil ekstraksi fitur kemudian data diberikan label dan dilakukan klasifikasi terhadap dataset maka akan didapatkan prediksi dari sebuah data testing. Dimana data label kelas 0 diprediksi 0 maka akan dimasukkan ke dalam *TN*, sedangkan data label kelas 0 diprediksi 1 maka dimasukkan ke dalam *FP*, data label kelas 1 diprediksi 0 maka dimasukkan ke dalam *FN* dan yang terakhir jika label kelas 1 diprediksi 1 maka akan dimasukkan ke dalam *TP*. Seperti yang dapat dilihat pada tabel 4.3

	Bam4	Bfm4	keadaan	prediksi
0	0.590	0.211	0.0	0.0
1	0.910	0.261	0.0	0.0
2	0.294	0.149	0.0	0.0
3	0.749	0.248	0.0	0.0
4	0.064	0.019	1.0	0.0
5	0.604	0.284	0.0	0.0
6	0.390	0.735	0.0	0.0
7	0.625	0.028	1.0	1.0
8	0.303	0.229	0.0	0.0
9	0.488	0.066	1.0	1.0

Tabel 4.3 Contoh hasil klasifikasi

4.3.2 K-Fold Cross Validation

Pada *cross validation* data yang akan klasifikasi akan dibagi menjadi 10 bagian dengan menggunakan dataset. Sebanyak 100 data digunakan untuk *testing*, dipilih secara *random* demi mendapatkan proporsi data yang seimbang maka dilakukan dengan permutasi untuk mempertahankan populasi dari data tersebut. Hasil dari *10-fold cross validation* dapat dilihat pada lampiran A dan B.

4.3.2 Receive Operating Characteristics (ROC)

Kurva *ROC* adalah suatu yang umum digunakan untuk mengetahui suatu kinerja dengan menggunakan luas dibawah kurva, disebut dengan *AUC*. Pada penelitian ini luas kurva yang dibandingkan antara $IMF_1, IMF_2, IMF_3, IMF_4$ dan gabungan dari semua *IMF* pada masing-masing kernel. Adapun nilai yang dihasilkan adalah antara 0-1 karena bentuk kurva sebuah persegi. Dimana jika nilai yang dihasilkan mendekati 1 maka semakin ideal.

4.4 Pengujian Data

Untuk memperoleh performansi suatu metode, maka diperlukan suatu proses pengujian. Pada penelitian ini, proses pengujian metode *SVM* menggunakan perhitungan akurasi, spesifitas, sensitifitas. Pengujian yang dilakukan terdiri dari data publik dan data lokal dengan skenario uji sebagai berikut:

4.4.1 Pengujian dengan beberapa fungsi kernel

Pengujian yang dilakukan dengan perhitungan performansi fungsi kernel yang dilakukan dengan berbagai macam kernel yang berbeda-beda yaitu kernel *RBF*, kernel *polinomial*, kernel *mexican hat* dan kernel *morlet*. Dimana untuk fungsi kernel *RBF* dengan parameter σ yang merupakan besarnya kontrol untuk lebar pada fungsi kernel *RBF* dengan nilai $\sigma = 0.4$. Kemudian untuk fungsi kernel *polinomial* dengan parameter l sebagai tingkatan *polinomial*. Perhitungan performansi dilakukan dengan studi literatur[2] dengan nilai $l = 5$. Sedangkan kernel *mexican hat* menggunakan parameter $\alpha = 1$ sebagai dilatasi dan kernel *morlet* menggunakan parameter $w_0 = 0.75$ seperti yang terdapat pada referensi[2]. Hasil performa didapatkan dengan akurasi, sensitivitas dan spesifitas dari setiap *IMF* pada ekstraksi fitur dengan fungsi kernel *RBF*, *polinomial*, *mexican hat* dan *morlet*.

4.4.1.1 Data Publik

Uji coba yang dilakukan pada data publik dengan metode *SVM* pada berbagai macam kernel, yaitu kernel *RBF*, *polinomial*, *mexican hat*, *morlet* dengan 10 kali percobaan seperti yang terdapat pada lampiran A. Pada bab ini ditampilkan hasil nilai akurasi minimal, maksimal, rata-rata dan juga nilai sensitifitas minimal, maksimal, rata-rata serta nilai sensitifitas minimal, maksimal, rata-rata yang didapatkan dari masing-masing *IMF* dan semua *IMF* yang digabungkan kemudian diuji cobakan.

Hasil terbaik terdapat pada perhitungan kernel *RBF* dengan ekstraksi fitur (B_{AM}) dan (B_{FM}) dengan data testing sebanyak 100 data menggunakan parameter $\sigma = 0.4$ seperti yang terdapat pada referensi[2] sebagai besarnya kontrol untuk fungsi *RBF* yang terbaik Tabel 4.4 adalah pada IMF_1 dengan rata-rata hasil akurasi sebesar 95,5%, spesifikasi sebesar 94,38% dan sensitifitas sebesar 100%.

Kernel	<i>IMF</i>		Akurasi (%)	Spesifikasi (%)	Sensitifitas (%)
<i>RBF</i> ($\sigma = 0,4$)	<i>IMF1</i>	min:	92,00	90,00	100,00
		max:	97,00	96,25	100,00
		rerata:	95,50	94,38	100,00
	<i>IMF2</i>	min:	91,00	92,50	65,00
		max:	98,00	98,75	95,00
		rerata:	94,40	97,12	83,50
	<i>IMF3</i>	min:	91,00	93,75	70,00
		max:	96,00	100,00	90,00
		rerata:	94,30	97,38	82,00
	<i>IMF4</i>	min:	90,00	92,50	75,00
		max:	96,00	100,00	90,00
		rerata:	93,50	96,38	82,00
	Semua <i>IMF</i>	min:	93,00	96,25	80,00
		max:	99,00	100,00	100,00
		rerata:	96,90	98,38	91,00

Tabel 4.4 Data publik hasil penelitian dengan menggunakan kernel *RBF*

Untuk pengujian dengan kernel *polynomial* menggunakan data publik dengan parameter l yaitu *degree* dari kernel *polynomial* dengan nilai besarnya l sebesar 5 seperti yang terdapat pada referensi[2] didapatkan hasil percobaan rata-rata terbaik pada IMF_1 dengan rata-rata hasil akurasi sebesar 91,5%, spesifikasi sebesar 89,62% dan sensitifitas sebesar 99% Tabel 4.5.

Kernel	<i>IMF</i>		Akurasi (%)	Spesifikasi (%)	Sensitifitas (%)
<i>Poly-Nomial</i> ($l=5$)	<i>IMF1</i>	min:	86,00	82,50	95,00
		max:	95,00	93,75	100,00
		rerata:	91,50	89,62	99,00
	<i>IMF2</i>	min:	85,00	83,75	85,00
		max:	91,00	92,50	100,00
		rerata:	88,50	88,38	89,00
	<i>IMF3</i>	min:	84,00	82,50	80,00
		max:	93,00	92,50	100,00
		rerata:	88,80	88,50	90,00
	<i>IMF4</i>	min:	82,00	81,25	80,00
		max:	91,00	91,25	100,00
		rerata:	87,10	86,88	88,00
	Semua <i>IMF</i>	min:	91,00	90,00	70,00
		max:	97,00	97,50	100,00
		rerata:	93,00	94,62	86,50

Tabel 4.5 Data publik hasil penelitian dengan menggunakan kernel *Polynomial*

Selanjutnya dengan pengujian pada kernel *mexican hat* yang merupakan salah satu jenis dari kernel *wavelet*, dalam *SVM mexican hat* merupakan salah satu jenis kernel yang sering digunakan. Pada penelitian ini dengan menggunakan data publik, digunakan parameter a , dimana a merupakan dilatasi pada fungsi kernel *mexican hat* seperti yang terdapat pada referensi[2] didapatkan hasil percobaan rata-rata terbaik dengan menggunakan IMF_1 dengan rata-rata hasil akurasi sebesar 96,1%, spesifikasi sebesar 95,88% dan sensitifitas sebesar 97% Tabel 4.6.

Kernel	<i>IMF</i>		Akurasi (%)	Spesifikasi (%)	Sensitifitas (%)
<i>Mexican hat</i> ($\alpha = 1$)	<i>IMF1</i>	min:	94,00	92,50	90,00
		max:	99,00	98,75	100,00
		rerata:	96,10	95,88	97,00
	<i>IMF2</i>	min:	90,00	91,25	80,00
		max:	97,00	98,75	90,00
		rerata:	94,20	96,50	85,00
	<i>IMF3</i>	min:	93,00	96,25	75,00
		max:	96,00	98,75	95,00
		rerata:	94,70	97,12	85,00
	<i>IMF4</i>	min:	91,00	93,75	75,00
		max:	97,00	98,75	90,00
		rerata:	94,20	96,50	85,00
	Semua <i>IMF</i>	min:	91,00	95,00	75,00
		max:	97,00	100,00	95,00
		rerata:	94,50	97,25	83,50

Tabel 4.6 Data publik hasil penelitian dengan menggunakan kernel *mexican hat*

Kemudian dengan pengujian pada kernel *morlet* yang juga merupakan salah satu jenis kernel yang sering digunakan dalam *SVM*. Pada penelitian ini dengan menggunakan data publik, besarnya α yaitu 0,6, dan $w_0 = 0,75$ seperti yang terdapat pada referensi[2] didapatkan hasil percobaan rata-rata terbaik pada IMF_1 dengan rata-rata hasil akurasi sebesar 96,8%, spesifikasi sebesar 96,62% dan sensitifitas sebesar 97,5% Tabel 4.7.

Kernel	<i>IMF</i>		Akurasi (%)	Spesifikasi (%)	Sensitifitas (%)
<i>Morlet</i> ($\alpha = 0,6,$ $w_0 = 0,75$)	<i>IMF1</i>	min:	95,00	95,00	95,00
		max:	100,0	100,00	100,00
		rerata:	96,80	96,62	97,50
	<i>IMF2</i>	min:	90,00	92,50	75,00
		max:	98,00	100,00	90,00
		rerata:	95,20	97,38	86,50
	<i>IMF3</i>	min:	91,00	93,75	75,00
		max:	97,00	100,00	95,00
		rerata:	94,50	97,00	84,50
	<i>IMF4</i>	min:	92,00	93,75	75,00
		max:	97,00	100,00	95,00
		rerata:	94,70	97,62	83,00
	Semua <i>IMF</i>	min:	94,00	96,25	75,00
		max:	98,00	100,00	95,00
		rerata:	95,80	98,25	86,00

Tabel 4.7 Data publik hasil penelitian dengan menggunakan kernel *morlet*

4.4.1.2 Data lokal

Pada penelitian ini juga melakukan uji coba yang dilakukan dengan menggunakan data lokal dengan metode *SVM* serta menggunakan berbagai macam kernel, yaitu kernel *RBF*, *polynomial*, *mexican hat*, *morlet* dengan uji coba sebanyak 10 kali menggunakan *cross validation* sehingga dapatkan hasil nilai akurasi, spesifitas, dan sensitifitas dari 10 kali percobaan yang terdapat pada lampiran B. Pada Tabel 4.8 Menyajikan hasil uji coba kernel *RBF* dengan data testing sebanyak 100 data.

Kernel	<i>IMF</i>		Akurasi (%)	Spesifikasi (%)	Sensitifitas (%)
<i>RBF</i> ($\sigma = 0,4$)	<i>IMF1</i>	min:	86,00	88,75	75,00
		max:	96,00	100,00	95,00
		rerata:	91,80	93,75	84,00
	<i>IMF2</i>	min:	85,00	88,75	70,00
		max:	95,00	97,50	90,00
		rerata:	90,40	93,38	78,50
	<i>IMF3</i>	min:	90,00	95,00	70,00
		max:	94,00	97,50	85,00
		rerata:	92,20	96,25	76,00
	<i>IMF4</i>	min:	88,00	90,00	70,00
		max:	95,00	96,25	90,00
		rerata:	90,40	93,12	79,50
	Semua <i>IMF</i>	min:	90,00	95,00	70,00
		max:	98,00	100,00	90,00
		rerata:	94,60	97,38	83,50

Tabel 4.8 Data lokal hasil penelitian dengan menggunakan kernel *RBF*

Kernel *RBF* dengan parameter $\sigma = 0,4$ seperti yang terdapat pada referensi[2] sebagai besarnya kontrol untuk fungsi *RBF* yang terbaik Tabel 4.8 pada semua *IMF* dengan rata-rata hasil akurasi sebesar 94,6%, spesifikasi sebesar 97,38% dan sensitifitas sebesar 83,5%.

Proses pengujian selanjutnya yaitu menggunakan kernel *polynomial* yang diuji cobakan. Untuk mengetahui hasil rata-rata dari pengujian maka disajikan pada Tabel 4.9

Kernel	<i>IMF</i>		Akurasi (%)	Spesifikasi (%)	Sensitifitas (%)
<i>Poly-Nomial</i> (<i>l=5</i>)	<i>IMF1</i>	min:	78,00	75,00	85,00
		max:	92,00	90,00	100,00
		rerata:	84,60	82,25	94,00
	<i>IMF2</i>	min:	80,00	76,25	80,00
		max:	89,00	88,75	100,00
		rerata:	84,50	82,75	91,50
	<i>IMF3</i>	min:	79,00	75,00	75,00
		max:	89,00	90,00	95,00
		rerata:	82,70	82,25	84,50
	<i>IMF4</i>	min:	80,00	77,50	80,00
		max:	90,00	90,00	100,00
		rerata:	85,00	83,88	89,50
	Semua <i>IMF</i>	min:	79,00	76,25	85,00
		max:	93,00	91,25	100,00
		rerata:	86,30	84,88	92,00

Tabel 4.9 Data lokal hasil penelitian dengan menggunakan kernel *Polynomial*

dengan parameter l adalah degree dari kernel polynomial dengan nilai besarnya l sebesar 5 mengacu pada referensi[2]. Hasil dengan 10 kali percobaan pada *IMF* didapatkan rata-rata terbaik dengan menggunakan semua *IMF* dimana nilai akurasi sebesar 86,3%, spesifikasi sebesar 84,188% dan sensitifitas sebesar 92% Tabel 4.9.

Setelah melakukan pengujian pada kernel *polynomial*, maka berikutnya pengujian menggunakan kernel *mexican hat* Tabel 4.10.

Kernel	<i>IMF</i>		Akurasi (%)	Spesifikasi (%)	Sensitifitas (%)
<i>Mexican hat</i> ($\alpha = 1$)	<i>IMF1</i>	min:	91,00	92,50	75,00
		max:	98,00	100,00	90,00
		rerata:	94,90	97,38	85,00
	<i>IMF2</i>	min:	88,00	91,25	70,00
		max:	94,00	98,75	85,00
		rerata:	91,50	95,50	75,50
	<i>IMF3</i>	min:	92,00	93,75	70,00
		max:	95,00	100,00	85,00
		rerata:	93,20	97,00	78,00
	<i>IMF4</i>	min:	92,00	95,00	70,00
		max:	96,00	98,75	90,00
		rerata:	93,60	97,25	79,00
	Semua <i>IMF</i>	min:	94,00	96,25	75,00
		max:	99,00	100,00	95,00
		rerata:	96,50	99,38	85,00

Tabel 4.10 Data lokal hasil penelitian dengan menggunakan kernel *mexican hat*

Dalam SVM *mexican hat* masuk dalam salah satu kernel yang umum digunakan dan merupakan bagian dari *wavelet*, didapatkan hasil percobaan rata-rata terbaik pada semua *IMF* dengan rata-rata hasil akurasi 96,5%, spesifikasi 99,38% dan sensitifitas 85%.

Jika pada pengujian sebelumnya menggunakan kernel *mexican hat* maka pada pengujian ini dilakukan dengan menggunakan kernel *morlet* Tabel 4.11 yang masuk kedalam salah satu jenis kernel dimana sering digunakan dalam SVM dan termasuk dalam salah satu jenis *wavelet*,

Kernel	<i>IMF</i>		Akurasi (%)	Spesifikasi (%)	Sensitifitas (%)
<i>Morlet</i> ($\alpha = 0,6$, $w_0 = 0,75$)	<i>IMF1</i>	min:	91,00	93,75	75,00
		max:	97,00	98,75	95,00
		rerata:	94,10	96,50	84,50
	<i>IMF2</i>	min:	92,00	95,00	70,00
		max:	96,00	97,50	95,00
		rerata:	93,60	96,38	82,50
	<i>IMF3</i>	min:	90,00	92,50	70,00
		max:	96,00	98,75	85,00
		rerata:	93,70	97,00	80,50
	<i>IMF4</i>	min:	91,00	92,50	70,00
		max:	96,00	98,75	90,00
		rerata:	93,70	96,88	81,00
	Semua <i>IMF</i>	min:	94,00	98,75	75,00
		max:	98,00	100,00	95,00
		rerata:	96,30	99,25	84,50

Tabel 4.11 Data lokal hasil penelitian dengan menggunakan kernel *morlet*

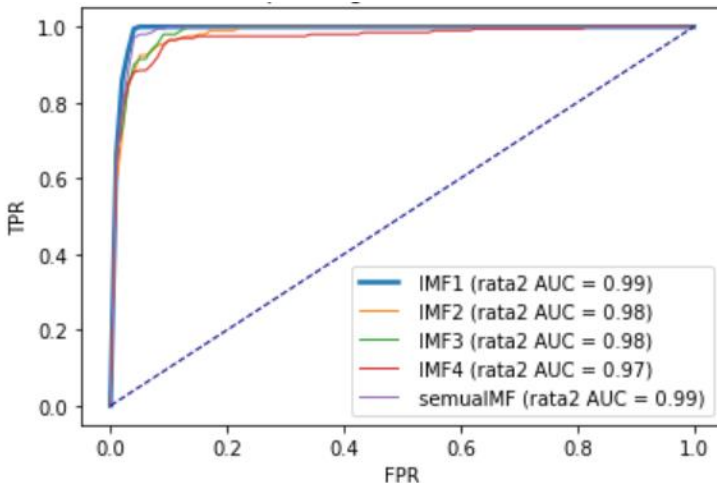
Pada penelitian ini dengan menggunakan data publik, besarnya a yaitu 0,6 dan $w_0 = 0,75$ seperti yang terdapat pada referensi[2] didapatkan hasil percobaan rata-rata terbaik pada semua *IMF* dengan rata-rata hasil akurasi sebesar 96,3%, spesififikasi sebesar 99,25% dan sensitifitas sebesar 84% Tabel 4.11.

4.4.2 Pengujian dengan ROC

Untuk melakukan evaluasi performa pada penelitian menggunakan data *EEG* kejang dan tidak kejang baik dari data publik maupun data dari lokal maka diperlukan performasi untuk membandingkan hasil pengujian yang telah dilakukan guna mendapatkan hasil yang diinginkan. Adapun uji coba yang dilakukan dengan (*ROC*) dan perhitungan yang didapatkan diukur melalui daerah dibawah kurva *ROC* yang disebut dengan area dibawah kurva (*AUC*). Dimana bentuk *AUC* merupakan segiempat sehingga nilainya selalu diantara 0-1 jika daerah dibawah kurva mendekati 1 maka nilai tersebut termasuk dalam ideal.

4.4.2.1 Data Publik


Dari hasil pengujian menggunakan *ROC* dengan data publik,



Gambar 4.11 ROC kernel *RBF* pada data publik

yang dilakukan pada *IMF* yaitu *IMF*₁,*IMF*₂,*IMF*₃,*IMF*₄ dan semua *IMF* menggunakan kernel *RBF* digunakan jumlah data testing sebanyak 100 data. Didapatkan hasil rata-rata dari 10 kali percobaan, dapat kita lihat melalui grafik Gambar 4.11 dimana nilai *AUC* pada *IMF*₁ dan nilai *AUC* pada semua *IMF* merupakan yang terbesar dengan nilai 0,99 dibandingkan dengan nilai *AUC* pada *IMF*₂ dan *IMF*₃ sebesar 0,98 serta *IMF*₄ sebesar 0,97


Selanjutnya hasil pengujian menggunakan *ROC* dengan data publik yang dilakukan menggunakan kernel *polynomial* pada *IMF* yaitu *IMF*₁,*IMF*₂,*IMF*₃,*IMF*₄ dan semua *IMF* dengan jumlah data testing sebanyak 100 data didapatkan hasil rata-rata dari 10 kali percobaan yaitu dihasilkan *AUC* dengan nilai yang terbesar didapatkan pada *IMF*₁ dan gabungan *IMF* sebesar 0,98 berikutnya *IMF*₃ dan *IMF*₄ dengan nilai yang sama sebesar 0,96 selanjutnya pada *IMF*₂ sebesar 0,95 Gambar 4.12.



Gambar 4.12 *ROC* kernel *polynomial* pada data publik


Setelah dilakukan pengujian dengan kernel *polynomial* selanjutnya dilakukan pengujian menggunakan *ROC* untuk mendapatkan *AUC* dengan menggunakan data publik yang dilakukan pada *IMF* yaitu *IMF*₁,*IMF*₂,*IMF*₃,*IMF*₄ dan gabungan semua *IMF* menggunakan kernel *mexican hat* didapatkan hasil rata-rata dari 10 kali percobaan dengan

jumlah data testing sebanyak 100 data. Dihasilkan nilai AUC sebesar 0,99 pada IMF_1 . Kemudian besarnya IMF yang terbesar ke dua setelah IMF_1 adalah IMF_3 dan IMF_4 dan gabungan semua IMF dengan nilai yang sama 0,98 setelah itu pada IMF_2 memiliki nilai yaitu sebesar 0,97. Dimana dapat kita lihat melalui grafik Gambar 4.13.



Gambar 4.13 ROC kernel *mexican hat* pada data publik

Jika sebelumnya telah mendapatkan hasil pengujian menggunakan ROC dalam kernel *mexican hat* maka kali ini digunakan kernel *morlet* dengan menggunakan data publik yang dilakukan pada IMF yaitu $IMF_1, IMF_2, IMF_3, IMF_4$ dan gabungan semua IMF dengan kernel *morlet* didapatkan hasil rata-rata dari 10 kali percobaan dengan jumlah data testing sebanyak 100 data. Dimana dapat kita lihat melalui grafik Gambar 4.14 nilai AUC pada IMF_1 , IMF_3 dan gabungan IMF merupakan yang terbesar yaitu dengan nilai 0,99 dibandingkan dengan nilai AUC yang terbesar berikutnya yaitu pada IMF_2 dan IMF_4 yang memiliki nilai sebesar 0,98.

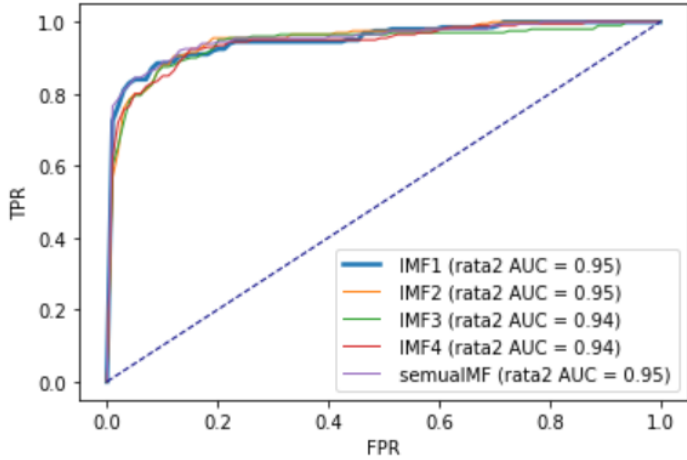


Gambar 4.14 ROC kernel morlet pada data publik

4.4.2.2 Data lokal


Pada pengujian sebelumnya telah didapatkan hasil pengujian menggunakan *ROC* pada data publik, selanjutnya pada subbab ini akan dilakukan pengujian yang sama menggunakan *ROC* menggunakan data dari lokal.

Pada pengujian ini dilakukan pada *IMF* yang terdiri dari $IMF_1, IMF_2, IMF_3, IMF_4$ dan gabungan semua *IMF* menggunakan kernel *RBF* dengan jumlah data testing sebanyak 100 data serta dilakukan percobaan sebanyak 10 kali. Didapatkan nilai *AUC* dengan nilai terbesar yaitu pada IMF_1, IMF_2 dan gabungan semua *IMF* sebesar 0,95 setelah itu IMF_3 dan IMF_4 sebesar 0,94 dapat dilihat pada Gambar 4.15.



Gambar 4.15 ROC kernel *RBF* pada data lokal


Selanjutnya pengujian memakai kernel *polynomial* Gambar 4.16 untuk mendapatkan hasil pengujian menggunakan ROC



Gambar 4.16 ROC kernel *polynomial* pada data lokal

pada data lokal. Pengujian ini dilakukan pada *IMF* yang terdiri dari $IMF_1, IMF_2, IMF_3, IMF_4$ dan gabungan semua *IMF*. Jumlah data *testing* sebanyak 100 data serta dilakukan percobaan sebanyak 10 kali. Didapatkan nilai *AUC* yaitu hasil *AUC* dengan hasil terbesar dengan gabungan *IMF* yaitu 0,96 kemudian pada IMF_2, IMF_3, IMF_4 dengan nilai sama sebesar 0,95 dan terakhir pada IMF_1 dengan nilai sebesar 0.86.


Selanjutnya pengujian dilakukan pada kernel *mexican hat* untuk mendapatkan hasil pengujian menggunakan *ROC* dengan data lokal. Jumlah data *testing* yang digunakan sebanyak 100 data dilakukan pada *IMF* yaitu IMF_1, IMF_2, IMF_3 dan IMF_4 dan gabungan semua *IMF* dengan 10 kali percobaan. Didapatkan nilai *AUC* yang terbesar pada gabungan *IMF* sebesar 0,97 selanjutnya IMF_1, IMF_3 dan IMF_4 dengan nilai 0,92 dan yang terakhir didapatkan hasil pada IMF_2 sebesar 0,91 Gambar4.17.



Gambar 4.17 ROC kernel *mexican hat* pada data lokal

Pengujian yang terakhir dilakukan pada kernel *morlet* dengan menggunakan data lokal. Pada pengujian ini dilakukan pada *IMF* yang terdiri dari $IMF_1, IMF_2, IMF_3, IMF_4$ dan gabungan semua *IMF* dengan jumlah data *testing* sebanyak 100 data serta dilakukan percobaan sebanyak 10 kali. Didapatkan nilai *AUC* yaitu hasil *AUC* yang terbesar pada gabungan *IMF* sebesar 0,97 kemudian IMF_1 dan IMF_2 sebesar 0,95

selanjutnya IMF_3 dengan besar 0,93 dan yang terakhir pada IMF_4 sebesar 0,92 Gambar 4.18



Gambar 4.18 ROC kernel *morlet* pada data lokal

Halamana ini sengaja dikosongkan

BAB 5

PENUTUP

5.1 Kesimpulan

Pada penelitian yang telah dilakukan klasifikasi kondisi kejang dan tidak kejang dari gelombang otak sinyal *EEG* dilakukan dengan menggunakan metode *EMD* dengan proses *shifting* menghasilkan *IMF*. Dimana *IMF* yang didapatkan selanjutnya digunakan untuk mendapatkan ekstraksi fitur bandwidth yaitu (B_{AM}) dan (B_{FM}). Dari ekstraksi fitur yang didapat akan dilakukan klasifikasi menggunakan *SVM* dengan parameter yang telah ditentukan yaitu kernel *RBF*, kernel *polynomial*, kernel *mexican hat* dan kernel *morlet* serta digunakan *ROC* untuk pengujian hasil pada kernel *RBF*, kernel *polynomial*, kernel *mexican hat* dan kernel *morlet* dalam penelitian ini. Setelah dilakukan beberapa pengujian dengan menggunakan data publik dan data lokal, didapatkan hasil sebagai berikut:

1. Dari hasil Pengujian yang dilakuka pada setiap *IMF* yang diuji dengan menggunakan data lokal rata-rata performa untuk semua *IMF* cenderung lebih tinggi dibandingkan dengan hanya menggunakan satu *IMF*.
2. Pengujian yang dilakukan pada data publik hasil performasi terbaik yaitu menggunakan kernel *morlet* pada IMF_1 didapatkan hasil rata-rata performa akurasi sebesar 96,8% , spesifitas 96,62% dan sensitifitas sebesar 97,5%.
3. Pengujian yang dilakukan pada data lokal hasil performasi terbaik yaitu menggunakan semua *IMF* pada kernel *mexican hat* dengan hasil rata-rata performa akurasi sebesar 96,3%, spesifitas 99,25% dan sensitifitas sebesar 84,5%.
4. Evaluasi menggunakan *ROC* didapatkan daerah *AUC* pada masing-masing *IMF* serta semua *IMF* data publik pada berbagai kernel hasil rata-rata terbaik pada kernel *morlet* sebesar 0,99.
5. Evaluasi yang dilakukan dengan mengguakan data *RSUA* menggunakan *ROC*, dimana kurva *AUC* rata-rata terbaik dengan kernel *mexican hat* dan kernel *morlet* pada *gabungan semua IMF* sebesar 0,97.
6. Dari dataset yang digunakan yaitu data *EEG* yang didapat dari data publik dan data *EEG* dari lokal memiliki hasil klasifikasi yang

berbeda karena data yang digunakan memiliki frekuensi *sampling* yang beda dan panjangnya waktu perekaman yang berbeda.

5.2 Saran

Untuk mengembangkan penelitian lebih lanjut. Adapun saran yang dapat diberikan diantaranya:

1. Mengoptimalkan pemilihan channel-channel sinyal *EEG* yang lain yang belum digunakan untuk proses klasifikasi.
2. Mengembangkan suatu sistem untuk membersihkan data sinyal *EEG* dari *artefact*.
3. Mengimplementasikan dengan metode lain pada dataset yang ada untuk mendapatkan hasil yang lebih baik.

DAFTAR PUSTAKA

- [1] L. D. Iasemidis, D. S. Shiau, W. Chaovalitwongse, J. C. Sackellares, P. N. Pardalos, J. C. Principe, P. R. Carney, A. Prasad, B. Veeramani, and K. Tsakalis, "Adaptive epileptic seizure prediction system," *IEEE Trans. Biomed. Eng.*, vol. 50, no. 5, pp. 616–627, May 2003.
- [2] V. Bajaj and R. B. Pachori, "Classification of Seizure and Non-seizure EEG Signals using Empirical Mode Decomposition," *IEEE Transaction on Information Technology in Biomedicine*, 2012.
- [3] V. Srinivasan, C. Eswaran and N. Sriraam, "Artificial neural network based epileptic detection using time-domain and frequency-domain features," *J.. Med. Syst.*, vol. 29, no. 6, pp. 647–660, Dec. 2005.
- [4] B. Boashash, M. Mesbah, and P. Colditz, "Time frequency detection of EEG abnormalities," in *Time-Frequency Signal Analysis and Processing: A Comprehensive Reference*. Missouri: Elsevier, 2003, ch. 15, article15.5, pp. 663–670.
- [5] R. G. Andrzejak, K. Lehnertz, F. Mormann, C. Rieke, P. David, and C.E. Elger, "Indications of nonlinear deterministic and finite-dimensional structures in time series of brain electrical activity: Dependence on recording region and brain state," *Phys. Rev. E*, vol. 64, no. 6, p. 061907, 2001.
- [6] WHO. Epilepsy: epidemiology, etiology and prognosis. WHO Fact Sheet No. 1665. 2001
- [7] G Shorvon, S, *Handbook of Epilepsy Treatment*, London: Springer, 2000.

- [8] Westbrook GL. Seizures and epilepsy. Dalam: Kandel ER, Schwartz JH, Jessel TM, ed. *Principals of neural science*. New York: MCGraw-Hill, 2000. h.940-55.
- [9] *ELEKTROENSEFALOGRAM* (2018, April 25) [Online] <https://nardinurses.files.wordpress.com/2008/01/eeg.pdf>
- [10] PENJELASAN TEKNIS TEKNOLOGI GELOMBANG OTAK (2018, Mei 25) [Online] http://www.gelombangotak.com/teknologi_gelombang_otak.htm
- [11] Afriansyah, A. K. (2008). “Studi Pengembangan Aplikasi Low Cost EEG (ELEKTROENSEFALOGRAF) Untuk Memonitor kualitas Tidur Selama Terapi Akupuntur”. Bandung: ITB.
- [12] 10-20 *System Positioning* (2018, Mei 25) [Online] https://www.transcranial.com/local/manuals/10_20_pos_man_v1_0.pdf
- [13] N. E. Huang, Z. Shen, S. R. Long, M. C. Wu, H. H. Shih, Q. Zheng, N. C. Yen, C. C. Tung, and H. H. Liu, “The empirical mode decomposition and Hilbert spectrum for nonlinear and non-stationary time series analysis,” *Proc. R. Soc. Lond. A*, vol. 454, pp. 903–995, 1998.
- [14] Nugroho, dkk. “Support Vector Machine – Teori Dan Aplikasinya Dalam Bioinformatika”. 2003
- [15] Sembiring, K. (2007). “Penerapan Teknik Support Vector Machine untuk Pendeteksian Intrusi pada Jaringan”. Bandung: Teknik Elektro dan Informatika, ITB
- [16] Pipit Pitria (2018, Mei 20) [Online] http://elib.unikom.ac.id/files/disk1/714/jbptunikompp-gdl-pipitpitri-35651-7-unikom_p-a.pdf

LAMPIRAN

Data publik dengan K-10

IMF 1 Kernel RBF

<i>TN</i>	<i>FP</i>	<i>FN</i>	<i>TP</i>	Akurasi	Spesifikasi	Sensitifitas
72	8	0	20	92	90	100
76	4	0	20	96	95	100
77	3	0	20	97	96,25	100
77	3	0	20	97	96,25	100
74	6	0	20	94	92,5	100
75	5	0	20	95	93,75	100
75	5	0	20	95	93,75	100
77	3	0	20	97	96,25	100
76	4	0	20	96	95	100
76	4	0	20	96	95	100

IMF 2 Kernel RBF

<i>TN</i>	<i>FP</i>	<i>FN</i>	<i>TP</i>	Akurasi	Spesifikasi	Sensitifitas
74	6	2	18	92	92,5	90
75	5	3	17	92	93,75	85
79	1	3	17	96	98,75	85
78	2	5	15	93	97,5	75
78	2	4	16	94	97,5	80
79	1	2	18	97	98,75	90
79	1	1	19	98	98,75	95
78	2	5	15	93	97,5	75
78	2	7	13	91	97,5	65
79	1	1	19	98	98,75	95

IMF 3 Kernel RBF

<i>TN</i>	<i>FP</i>	<i>FN</i>	<i>TP</i>	Akurasi	Spesifikasi	Sensitifitas
75	5	4	16	91	93,75	80
78	2	3	17	95	97,5	85
79	1	5	15	94	98,75	75
77	3	4	16	93	96,25	80
78	2	3	17	95	97,5	85
78	2	2	18	96	97,5	90
77	3	2	18	95	96,25	90
80	0	6	14	94	100	70
78	2	4	16	94	97,5	80
79	1	3	17	96	98,75	85

IMF 4 Kernel RBF

<i>TN</i>	<i>FP</i>	<i>FN</i>	<i>TP</i>	Akurasi	Spesifikasi	Sensitifitas
75	5	5	15	90	93,75	75
76	4	4	16	92	95	80
78	2	4	16	94	97,5	80
74	6	4	16	90	92,5	80
78	2	2	18	96	97,5	90
77	3	2	18	95	96,25	90
78	2	2	18	96	97,5	90
80	0	5	15	95	100	75
78	2	5	15	93	97,5	75
77	3	3	17	94	96,25	85

Semua *IMF* Kernel *RBF*

<i>TN</i>	<i>FP</i>	<i>FN</i>	<i>TP</i>	Akurasi	Spesifikasi	Sensitifitas
77	3	1	19	96	96,25	95
77	3	4	16	93	96,25	80
80	0	1	19	99	100	95
79	1	2	18	97	98,75	90
80	0	3	17	97	100	85
79	1	3	17	96	98,75	85
78	2	0	20	98	97,5	100
78	2	1	19	97	97,5	95
80	0	3	17	97	100	85
79	1	0	20	99	98,75	100

IMF 1 Kernel *Polynomial*

<i>TN</i>	<i>FP</i>	<i>FN</i>	<i>TP</i>	Akurasi	Spesifikasi	Sensitifitas
75	5	0	20	95	93,75	100
66	14	0	20	86	82,5	100
69	11	0	20	89	86,25	100
72	8	0	20	92	90	100
69	11	0	20	89	86,25	100
71	9	1	19	90	88,75	95
74	6	0	20	94	92,5	100
72	8	0	20	92	90	100
74	6	0	20	94	92,5	100
75	5	1	19	94	93,75	95

IMF 2 Kernel Polynomial

<i>TN</i>	<i>FP</i>	<i>FN</i>	<i>TP</i>	Akurasi	Spesifikasi	Sensitifitas
70	10	3	17	87	87,5	85
69	11	2	18	87	86,25	90
67	13	2	18	85	83,75	90
71	9	0	20	91	88,75	100
69	11	2	18	87	86,25	90
70	10	2	18	88	87,5	90
73	7	3	17	90	91,25	85
71	9	3	17	88	88,75	85
74	6	3	17	91	92,5	85
73	7	2	18	91	91,25	90

IMF 3 Kernel Polynomial

<i>TN</i>	<i>FP</i>	<i>FN</i>	<i>TP</i>	Akurasi	Spesifikasi	Sensitifitas
72	8	3	17	89	90	85
70	10	2	18	88	87,5	90
66	14	2	18	84	82,5	90
71	9	0	20	91	88,75	100
68	12	2	18	86	85	90
72	8	2	18	90	90	90
71	9	1	19	90	88,75	95
71	9	3	17	88	88,75	85
73	7	4	16	89	91,25	80
74	6	1	19	93	92,5	95

IMF 4 Kernel Polynomial

<i>TN</i>	<i>FP</i>	<i>FN</i>	<i>TP</i>	Akurasi	Spesifikasi	Sensitifitas
72	8	1	19	91	90	95
65	15	3	17	82	81,25	85
70	10	3	17	87	87,5	85
72	8	4	16	88	90	80
69	11	2	18	87	86,25	90
68	12	2	18	86	85	90
73	7	3	17	90	91,25	85
66	14	4	16	82	82,5	80
68	12	0	20	88	85	100
72	8	2	18	90	90	90

Semua IMF Kernel Polynomial

<i>TN</i>	<i>FP</i>	<i>FN</i>	<i>TP</i>	Akurasi	Spesifikasi	Sensitifitas
76	4	1	19	95	95	95
77	3	6	14	91	96,25	70
77	3	3	17	94	96,25	85
78	2	6	14	92	97,5	70
75	5	3	17	92	93,75	85
73	7	0	20	93	91,25	100
76	4	3	17	93	95	85
78	2	1	19	97	97,5	95
75	5	3	17	92	93,75	85
72	8	1	19	91	90	95

IMF 1 Kernel Mexican hat

<i>TN</i>	<i>FP</i>	<i>FN</i>	<i>TP</i>	Akurasi	Spesifikasi	Sensitifitas
77	3	1	19	96	96,25	95
75	5	1	19	94	93,75	95
77	3	1	19	96	96,25	95
79	1	0	20	99	98,75	100
76	4	0	20	96	95	100
77	3	2	18	95	96,25	90
78	2	0	20	98	97,5	100
76	4	1	19	95	95	95
74	6	0	20	94	92,5	100
78	2	0	20	98	97,5	100

IMF 2 Kernel Mexican hat

<i>TN</i>	<i>FP</i>	<i>FN</i>	<i>TP</i>	Akurasi	Spesifikasi	Sensitifitas
76	4	3	17	93	95	85
73	7	3	17	90	91,25	85
77	3	3	17	94	96,25	85
79	1	2	18	97	98,75	90
79	1	2	18	97	98,75	90
77	3	4	16	93	96,25	80
78	2	3	17	95	97,5	85
75	5	4	16	91	93,75	80
79	1	2	18	97	98,75	90
79	1	4	16	95	98,75	80

IMF 3 Kernel Mexican hat

<i>TN</i>	<i>FP</i>	<i>FN</i>	<i>TP</i>	Akurasi	Spesifikasi	Sensitifitas
79	1	3	17	96	98,75	85
77	3	3	17	94	96,25	85
77	3	3	17	94	96,25	85
78	2	4	16	94	97,5	80
77	3	1	19	96	96,25	95
79	1	4	16	95	98,75	80
78	2	3	17	95	97,5	85
78	2	5	15	93	97,5	75
77	3	1	19	96	96,25	95
77	3	3	17	94	96,25	85

IMF 4 Kernel Mexican hat

<i>TN</i>	<i>FP</i>	<i>FN</i>	<i>TP</i>	Akurasi	Spesifikasi	Sensitifitas
78	2	3	17	95	97,5	85
76	4	2	18	94	95	90
78	2	5	15	93	97,5	75
78	2	4	16	94	97,5	80
77	3	3	17	94	96,25	85
75	5	4	16	91	93,75	80
77	3	2	18	95	96,25	90
78	2	3	17	95	97,5	85
79	1	2	18	97	98,75	90
76	4	2	18	94	95	90

Semua *IMF* Kernel *Mexican hat*

<i>TN</i>	<i>FP</i>	<i>FN</i>	<i>TP</i>	Akurasi	Spesifikasi	Sensitifitas
79	1	3	17	96	98,75	85
76	4	4	16	92	95	80
79	1	4	16	95	98,75	80
80	0	3	17	97	100	85
77	3	5	15	92	96,25	75
77	3	4	16	93	96,25	80
77	3	2	18	95	96,25	90
76	4	5	15	91	95	75
79	1	2	18	97	98,75	90
78	2	1	19	97	97,5	95

IMF 1 Kernel *Morlet*

<i>TN</i>	<i>FP</i>	<i>FN</i>	<i>TP</i>	Akurasi	Spesifikasi	Sensitifitas
78	2	0	20	98	97,5	100
76	4	1	19	95	95	95
77	3	1	19	96	96,25	95
78	2	0	20	98	97,5	100
77	3	1	19	96	96,25	95
78	2	0	20	98	97,5	100
76	4	1	19	95	95	95
77	3	0	20	97	96,25	100
80	0	0	20	100	100	100
76	4	1	19	95	95	95

IMF 2 Kernel Morlet

<i>TN</i>	<i>FP</i>	<i>FN</i>	<i>TP</i>	Akurasi	Spesifikasi	Sensitifitas
78	2	2	18	96	97,5	90
78	2	2	18	96	97,5	90
78	2	2	18	96	97,5	90
78	2	2	18	96	97,5	90
78	2	5	15	93	97,5	75
80	0	2	18	98	100	90
78	2	2	18	96	97,5	90
78	2	4	16	94	97,5	80
79	1	2	18	97	98,75	90
74	6	4	16	90	92,5	80

IMF 3 Kernel Morlet

<i>TN</i>	<i>FP</i>	<i>FN</i>	<i>TP</i>	Akurasi	Spesifikasi	Sensitifitas
78	2	2	18	96	97,5	90
76	4	2	18	94	95	90
76	4	4	16	92	95	80
78	2	4	16	94	97,5	80
79	1	5	15	94	98,75	75
79	1	3	17	96	98,75	85
80	0	3	17	97	100	85
77	3	3	17	94	96,25	85
78	2	1	19	97	97,5	95
75	5	4	16	91	93,75	80

IMF 4 Kernel Morlet

<i>TN</i>	<i>FP</i>	<i>FN</i>	<i>TP</i>	Akurasi	Spesifikasi	Sensitifitas
79	1	3	17	96	98,75	85
78	2	2	18	96	97,5	90
77	3	5	15	92	96,25	75
79	1	5	15	94	98,75	75
78	2	5	15	93	97,5	75
79	1	4	16	95	98,75	80
80	0	3	17	97	100	85
78	2	3	17	95	97,5	85
78	2	1	19	97	97,5	95
75	5	3	17	92	93,75	85

Semua IMF Kernel Morlet

<i>TN</i>	<i>FP</i>	<i>FN</i>	<i>TP</i>	Akurasi	Spesifikasi	Sensitifitas
80	0	2	18	98	100	90
78	2	2	18	96	97,5	90
77	3	3	17	94	96,25	85
79	1	1	19	98	98,75	95
78	2	4	16	94	97,5	80
80	0	5	15	95	100	75
78	2	3	17	95	97,5	85
78	2	2	18	96	97,5	90
80	0	2	18	98	100	90
78	2	4	16	94	97,5	80

Data RSUA dengan K-10

IMF 1 Kernel RBF

<i>TN</i>	<i>FP</i>	<i>FN</i>	<i>TP</i>	Akurasi	Spesifikasi	Sensitifitas
78	2	5	15	93	97,5	75
73	7	4	16	89	91,25	80
72	8	3	17	89	90	85
75	5	2	18	93	93,75	90
80	0	4	16	96	100	80
76	4	4	16	92	95	80
76	4	2	18	94	95	90
72	8	1	19	91	90	95
71	9	5	15	86	88,75	75
77	3	2	18	95	96,25	90

IMF 2 Kernel RBF

<i>TN</i>	<i>FP</i>	<i>FN</i>	<i>TP</i>	Akurasi	Spesifikasi	Sensitifitas
73	7	6	14	87	91,25	70
75	5	4	16	91	93,75	80
71	9	3	17	88	88,75	85
76	4	4	16	92	95	80
78	2	5	15	93	97,5	75
75	5	4	16	91	93,75	80
76	4	5	15	91	95	75
75	5	4	16	91	93,75	80
71	9	6	14	85	88,75	70
77	3	2	18	95	96,25	90

IMF 3 Kernel RBF

<i>TN</i>	<i>FP</i>	<i>FN</i>	<i>TP</i>	Akurasi	Spesifikasi	Sensitifitas
78	2	6	14	92	97,5	70
78	2	5	15	93	97,5	75
77	3	3	17	94	96,25	85
76	4	4	16	92	95	80
77	3	6	14	91	96,25	70
77	3	4	16	93	96,25	80
77	3	6	14	91	96,25	70
77	3	5	15	92	96,25	75
76	4	6	14	90	95	70
77	3	3	17	94	96,25	85

IMF 4 Kernel RBF

<i>TN</i>	<i>FP</i>	<i>FN</i>	<i>TP</i>	Akurasi	Spesifikasi	Sensitifitas
77	3	6	14	91	96,25	70
73	7	5	15	88	91,25	75
72	8	3	17	89	90	85
73	7	3	17	90	91,25	85
75	5	4	16	91	93,75	80
76	4	4	16	92	95	80
76	4	5	15	91	95	75
73	7	4	16	89	91,25	80
73	7	5	15	88	91,25	75
77	3	2	18	95	96,25	90

Semua *IMF* Kernel *RBF*

<i>TN</i>	<i>FP</i>	<i>FN</i>	<i>TP</i>	Akurasi	Spesifikasi	Sensitifitas
79	1	4	16	95	98,75	80
76	4	4	16	92	95	80
76	4	3	17	93	95	85
80	0	2	18	98	100	90
80	0	4	16	96	100	80
77	3	3	17	94	96,25	85
79	1	3	17	96	98,75	85
77	3	2	18	95	96,25	90
76	4	6	14	90	95	70
79	1	2	18	97	98,75	90

IMF 1 Kernel *Polynomial*

<i>TN</i>	<i>FP</i>	<i>FN</i>	<i>TP</i>	Akurasi	Spesifikasi	Sensitifitas
69	11	3	17	86	86,25	85
64	16	2	18	82	80	90
62	18	1	19	81	77,5	95
64	16	1	19	83	80	95
72	8	0	20	92	90	100
67	13	2	18	85	83,75	90
69	11	0	20	89	86,25	100
62	18	1	19	81	77,5	95
60	20	2	18	78	75	90
69	11	0	20	89	86,25	100

IMF 2 Kernel Polynomial

<i>TN</i>	<i>FP</i>	<i>FN</i>	<i>TP</i>	Akurasi	Spesifikasi	Sensitifitas
64	16	3	17	81	80	85
67	13	4	16	83	83,75	80
61	19	1	19	80	76,25	95
68	12	0	20	88	85	100
68	12	1	19	87	85	95
67	13	3	17	84	83,75	85
71	9	2	18	89	88,75	90
63	17	0	20	83	78,75	100
64	16	3	17	81	80	85
69	11	0	20	89	86,25	100

IMF 3 Kernel Polynomial

<i>TN</i>	<i>FP</i>	<i>FN</i>	<i>TP</i>	Akurasi	Spesifikasi	Sensitifitas
65	15	3	17	82	81,25	85
66	14	4	16	82	82,5	80
60	20	1	19	79	75	95
65	15	5	15	80	81,25	75
69	11	4	16	85	86,25	80
65	15	3	17	82	81,25	85
70	10	3	17	87	87,5	85
64	16	3	17	81	80	85
62	18	2	18	80	77,5	90
72	8	3	17	89	90	85

IMF 4 Kernel Polynomial

<i>TN</i>	<i>FP</i>	<i>FN</i>	<i>TP</i>	Akurasi	Spesifikasi	Sensitifitas
70	10	3	17	87	87,5	85
66	14	4	16	82	82,5	80
62	18	2	18	80	77,5	90
67	13	2	18	85	83,75	90
66	14	2	18	84	82,5	90
68	12	4	16	84	85	80
70	10	1	19	89	87,5	95
65	15	1	19	84	81,25	95
65	15	0	20	85	81,25	100
72	8	2	18	90	90	90

Semua IMF Kernel Polynomial

<i>TN</i>	<i>FP</i>	<i>FN</i>	<i>TP</i>	Akurasi	Spesifikasi	Sensitifitas
69	11	3	17	86	86,25	85
67	13	3	17	84	83,75	85
61	19	2	18	79	76,25	90
67	13	1	19	86	83,75	95
73	7	1	19	92	91,25	95
70	10	3	17	87	87,5	85
69	11	0	20	89	86,25	100
65	15	1	19	84	81,25	95
65	15	2	18	83	81,25	90
73	7	0	20	93	91,25	100

IMF 1 Kernel Mexican hat

<i>TN</i>	<i>FP</i>	<i>FN</i>	<i>TP</i>	Akurasi	Spesifikasi	Sensitifitas
80	0	2	18	98	100	90
77	3	3	17	94	96,25	85
74	6	3	17	91	92,5	85
80	0	3	17	97	100	85
79	1	5	15	94	98,75	75
79	1	3	17	96	98,75	85
78	2	2	18	96	97,5	90
79	1	5	15	94	98,75	75
75	5	2	18	93	93,75	90
78	2	2	18	96	97,5	90

IMF 2 Kernel Mexican hat

<i>TN</i>	<i>FP</i>	<i>FN</i>	<i>TP</i>	Akurasi	Spesifikasi	Sensitifitas
78	2	5	15	93	97,5	75
78	2	6	14	92	97,5	70
74	6	6	14	88	92,5	70
78	2	4	16	94	97,5	80
79	1	5	15	94	98,75	75
74	6	3	17	91	92,5	85
75	5	6	14	89	93,75	70
77	3	6	14	91	96,25	70
78	2	4	16	94	97,5	80
73	7	4	16	89	91,25	80

IMF 3 Kernel Mexican hat

<i>TN</i>	<i>FP</i>	<i>FN</i>	<i>TP</i>	Akurasi	Spesifikasi	Sensitifitas
78	2	4	16	94	97,5	80
77	3	4	16	93	96,25	80
75	5	3	17	92	93,75	85
77	3	4	16	93	96,25	80
80	0	6	14	94	100	70
77	3	5	15	92	96,25	75
78	2	3	17	95	97,5	85
78	2	4	16	94	97,5	80
78	2	6	14	92	97,5	70
78	2	5	15	93	97,5	75

IMF 4 Kernel Mexican hat

<i>TN</i>	<i>FP</i>	<i>FN</i>	<i>TP</i>	Akurasi	Spesifikasi	Sensitifitas
79	1	4	16	95	98,75	80
78	2	6	14	92	97,5	70
76	4	4	16	92	95	80
78	2	2	18	96	97,5	90
77	3	4	16	93	96,25	80
78	2	5	15	93	97,5	75
78	2	6	14	92	97,5	70
78	2	3	17	95	97,5	85
79	1	5	15	94	98,75	75
77	3	3	17	94	96,25	85

Semua *IMF* Kernel *Mexican hat*

<i>TN</i>	<i>FP</i>	<i>FN</i>	<i>TP</i>	Akurasi	Spesifikasi	Sensitifitas
80	0	3	17	97	100	85
80	0	3	17	97	100	85
77	3	3	17	94	96,25	85
80	0	4	16	96	100	80
80	0	5	15	95	100	75
79	1	3	17	96	98,75	85
80	0	1	19	99	100	95
80	0	3	17	97	100	85
80	0	1	19	99	100	95
79	1	4	16	95	98,75	80

IMF 1 Kernel *Morlet*

<i>TN</i>	<i>FP</i>	<i>FN</i>	<i>TP</i>	Akurasi	Spesifikasi	Sensitifitas
78	2	4	16	94	97,5	80
77	3	4	16	93	96,25	80
75	5	3	17	92	93,75	85
75	5	4	16	91	93,75	80
79	1	4	16	95	98,75	80
76	4	3	17	93	95	85
79	1	2	18	97	98,75	90
76	4	1	19	95	95	95
79	1	5	15	94	98,75	75
78	2	1	19	97	97,5	95

IMF 2 Kernel Morlet

<i>TN</i>	<i>FP</i>	<i>FN</i>	<i>TP</i>	Akurasi	Spesifikasi	Sensitifitas
78	2	6	14	92	97,5	70
78	2	5	15	93	97,5	75
78	2	2	18	96	97,5	90
78	2	5	15	93	97,5	75
77	3	3	17	94	96,25	85
76	4	3	17	93	95	85
77	3	4	16	93	96,25	80
76	4	1	19	95	95	95
76	4	4	16	92	95	80
77	3	2	18	95	96,25	90

IMF 3 Kernel Morlet

<i>TN</i>	<i>FP</i>	<i>FN</i>	<i>TP</i>	Akurasi	Spesifikasi	Sensitifitas
78	2	6	14	92	97,5	70
78	2	5	15	93	97,5	75
79	1	3	17	96	98,75	85
77	3	4	16	93	96,25	80
74	6	4	16	90	92,5	80
77	3	3	17	94	96,25	85
79	1	3	17	96	98,75	85
78	2	3	17	95	97,5	85
79	1	5	15	94	98,75	75
77	3	3	17	94	96,25	85

IMF 4 Kernel Morlet

<i>TN</i>	<i>FP</i>	<i>FN</i>	<i>TP</i>	Akurasi	Spesifikasi	Sensitifitas
79	1	4	16	95	98,75	80
78	2	6	14	92	97,5	70
74	6	3	17	91	92,5	85
78	2	2	18	96	97,5	90
76	4	4	16	92	95	80
79	1	3	17	96	98,75	85
79	1	4	16	95	98,75	80
77	3	2	18	95	96,25	90
78	2	6	14	92	97,5	70
77	3	4	16	93	96,25	80

Semua IMF Kernel Morlet

<i>TN</i>	<i>FP</i>	<i>FN</i>	<i>TP</i>	Akurasi	Spesifikasi	Sensitifitas
80	0	3	17	97	100	85
79	1	5	15	94	98,75	75
79	1	3	17	96	98,75	85
79	1	4	16	95	98,75	80
80	0	3	17	97	100	85
79	1	4	16	95	98,75	80
79	1	3	17	96	98,75	85
79	1	1	19	98	98,75	95
80	0	3	17	97	100	85
80	0	2	18	98	100	90

BIOGRAFI PENULIS



Nomala Gema Puji Putri, lahir di Nganjuk pada tanggal 3 Juni 1996, Merupakan anak kedua dari tiga bersaudara, Telah menyelesaikan pendidikan sekolah dasar di SDN Klampis Ngasem I Surabaya (2002-2008), SMPN 29 Surabaya (2008-2011), SMAN 4 Surabaya (2011-2014), Penulis memiliki bidang minat dalam bidang teknologi, industri dan literasi, Selama menjadi mahasiswa Institut Teknologi Sepuluh Nopember, penulis juga aktif dalam berpartisipasi dalam kegiatan Multimedia&Game Event dan organisasi kampus sebagai staff HIMATEKTRO ITS 2015/2016 dan sekretaris departemen kewirausahaan HIMATEKTRO ITS 2016/2017, Penulis dapat dihubungi melalui email: nomalagema38@gmail.com

Halamana ini sengaja dikosongkan