



TESIS - TE142599

**SELEKSI KANAL PADA *ELECTROENCEPHALOGRAPH*  
(EEG) MENGGUNAKAN METODE *CORRELATION  
FEATURE SELECTION* (CFS) UNTUK IDENTIFIKASI  
*CYBERSICKNESS***

ALFI ZUHRIYA KHOIRUNNISAA  
07111650062001

DOSEN PEMBIMBING  
Prof. Dr. Ir. Mauridhi Hery Purnomo, M.Eng.  
Dr. Adhi Dharma Wibawa ., ST.,MT.

PROGRAM MAGISTER  
BIDANG KEAHLIAN TELEMATIKA  
DEPARTEMEN TEKNIK ELEKTRO  
FAKULTAS TEKNOLOGI ELEKTRO  
INSTITUT TEKNOLOGI SEPULUH NOPEMBER  
SURABAYA  
2018



TESIS - TE142599

**SELEKSI KANAL PADA *ELECTROENCEPHALOGRAPH*  
(EEG) MENGGUNAKAN METODE *CORRELATION*  
*FEATURE SELECTION* (CFS) UNTUK IDENTIFIKASI  
*CYBERSICKNESS***

ALFI ZUHRIYA KHOIRUNNISAA  
07111650062001

DOSEN PEMBIMBING  
Prof. Dr. Ir. Mauridhi Hery Purnomo, M.Eng.  
Dr. Adhi Dharma Wibawa, ST., MT.

PROGRAM MAGISTER  
BIDANG KEAHLIAN TELEMATIKA  
DEPARTEMEN TEKNIK ELEKTRO  
FAKULTAS TEKNOLOGI ELEKTRO  
INSTITUT TEKNOLOGI SEPULUH NOPEMBER  
SURABAYA  
2018





## LEMBAR PENGESAHAN

Tesis disusun untuk memenuhi salah satu syarat memperoleh gelar  
Magister Teknik (M.T)

di  
Institut Teknologi Sepuluh Nopember

oleh:

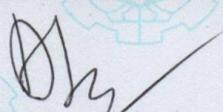
Alfi Zuhriya Khoirunnisaa  
NRP. 07111650062001

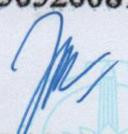
Tanggal Ujian : 06 Juli 2018

Periode Wisuda: September 2018

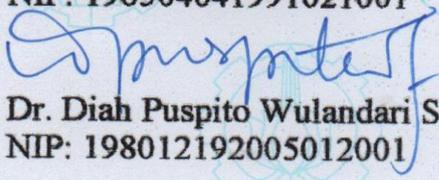
Disetujui oleh:

  
1. Prof. Dr. Ir. Mauridhi Hery Purnomo, M.Eng. (Pembimbing I)  
NIP: 195809161986011001

  
2. Dr. Adhi Dharma Wibawa ST., MT (Pembimbing II)  
NIP: 197605052008121003

  
3. Dr. I Ketut Eddy Purnama, ST., MT. (Penguji)  
NIP: 196907301995121001

  
4. Dr. Ir. Endroyono, DEA (Penguji)  
NIP: 196504041991021001

  
5. Dr. Diah Puspito Wulandari S.T., M.Sc. (Penguji)  
NIP: 198012192005012001

Dekan Fakultas Teknologi Elektro

  
Dr. Tri Arief Sardjono, S.T., M.T.  
NIP. 197002121995121001

*Halaman ini sengaja dikosongkan*

## **PERNYATAAN KEASLIAN TESIS**

Dengan ini saya menyatakan bahwa isi keseluruhan Tesis saya dengan judul “SELEKSI KANAL PADA *ELECTROENCEPHALOGRAPH* (EEG) MENGGUNAKAN METODE *CORRELATION FEATURE SELECTION* (CFS) UNTUK IDENTIFIKASI *CYBERSICKNESS*” adalah benar-benar hasil karya intelektual mandiri, diselesaikan tanpa menggunakan bahan-bahan yang tidak diijinkan dan bukan merupakan 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

Alfi Zuhriya Khoirunnisaa

NRP. 07111650062001

*Halaman ini sengaja dikosongkan*

# **SELEKSI KANAL PADA *ELECTROENCEPHALOGRAPH* (EEG) MENGGUNAKAN METODE *CORRELATION FEATURE SELECTION* (CFS) UNTUK IDENTIFIKASI *CYBERSICKNESS***

Nama mahasiswa : Alfi Zuhriya Khoirunnisaa  
NRP : 07111650062001  
Pembimbing : 1. Prof. Dr. Ir. Mauridhi Hery Purnomo, M. Eng  
2. Dr. Adhi Dharma Wibawa ST., MT

## **ABSTRAK**

*Cybersickness* merupakan sebuah fenomena yang sering muncul ketika seseorang melihat tayangan/paparan 3D dalam jangka waktu tertentu, dengan gejala-gejala yang terjadi diantaranya mual, pusing, ketegangan mata dan kehilangan keseimbangan.

Pada penelitian ini, identifikasi *cybersickness* dilakukan dengan menggunakan dua metode pengukuran yaitu berdasarkan *Simulator Sickness Questionnaire* (SSQ) dan EEG 14 kanal. Stimulus yang digunakan untuk menginduksi gejala *cybersickness* adalah melalui *video game* “Mirror Edge” pada dua kondisi yang berbeda yaitu *active game playing* dan *passive watching*. Proses dalam mengidentifikasi *cybersickness* harus menghasilkan data yang akurat sehingga penggunaan EEG sangat cocok diaplikasikan mengingat EEG memiliki sensitifitas dan akurasi yang tinggi terhadap aktivitas otak manusia. Namun, terdapat kelemahan dari penggunaan EEG multikanal diantaranya semakin banyak kanal maka semakin banyak *noise artefak* dan membutuhkan kompleksitas algoritma yang tinggi

Oleh karena itu, fokus utama dari penelitian ini adalah melakukan seleksi kanal pada EEG menggunakan metode *Correlation Feature Selection* (CFS). Seleksi kanal ini bertujuan untuk menghasilkan kanal-kanal yang relevan sehingga dapat digunakan sebagai langkah awal dalam mengidentifikasi *cybersickness*. Selain itu, seleksi kanal bertujuan untuk meningkatkan akurasi data dan mengurangi kompleksitas algoritma.

Adapun hasil seleksi kanal yang dihasilkan dari metode CFS yaitu pada kondisi *active game playing* didapatkan kanal AF4, FC6 dan P8. Penggunaan 3 kanal tersebut mampu meningkatkan akurasi sebesar 25% pada SVM-P dan 8,33% pada LDA dan KNN dibandingkan saat menggunakan EEG 14 kanal. Sedangkan pada kondisi *passive watching* menghasilkan 3 kanal terbaik yang terdiri dari AF4, FC5 dan FC6. Ketiga kanal ini mampu meningkatkan akurasi sebesar 6,25% pada LDA dan 3,125% pada KNN dan SVM-P dibandingkan ketika menggunakan 14 kanal EEG.

Kata kunci: *cybersickness*, sinyal EEG, CFS, seleksi kanal

*Halaman ini sengaja dikosongkan*

# **CHANNEL SELECTION OF *ELECTROENCEPHALOGRAPH (EEG)* USING *CORRELATION FEATURE SELECTION (CFS)* METHOD TO IDENTIFY *CYBERSICKNESS***

By : Alfi Zuhriya Khoirunnisaa  
Student Identity Number : 07111650062001  
Supervisor(s) : 1. Prof. Dr. Ir. Mauridhi Hery Purnomo, M. Eng  
2. Dr. Adhi Dharma Wibawa ST., MT

## **ABSTRACT**

Cybersickness is a phenomenon that often occurred when someone watching 3D movie or games in a certain period of time. The symptoms that occur including nausea, dizziness, eye strain and disorientation.

In this study, identification of cybersickness was done using two measurement methods that are based on Simulator Sickness Questionnaire (SSQ) and EEG 14 channel. The stimulus used to induce cybersickness symptoms is through the video game "Mirror Edge" in two different conditions: active game playing and passive watching. The process of identifying cybersickness must produce accurate data so that the use of EEG is highly applicable given the EEG has high sensitivity and accuracy to the activity of the human brain. However, there are disadvantages of using multicellular EEG such as the more channels the more noise artifacts and requires a high algorithm complexity

Therefore, the main focus of this research is to provide channel selection on EEG using the Correlation Feature Selection (CFS) method. The purpose of channel selection is to produce relevant channels that can be used as a first step in identifying cybersickness. In addition, channel selection aims to improve data accuracy and reduce algorithm complexity.

The channel selection results from the CFS method is the active game playing conditions obtained channel AF4, FC6 and P8. The use of these 3 channels is capable of increasing accuracy about 25% in SVM-P and 8.33 in LDA and KNN compared to when using EEG 14 channels. While the condition of passive watching produces the best 3 channels consisting of AF4, FC5 and FC6. All three channels are capable of increasing accuracy by 6.25% in LDA and 3.125% in KNN and SVM-P compared when using 14 EEG channels.

Key words: *cybersickness*, EEG signal, CFS, channel selection

*Halaman ini sengaja dikosongkan*

## KATA PENGANTAR

Alhamdulillah, segala puji bagi Allah, kita memuji-Nya, meminta pertolongan, pengampunan serta petunjuk-Nya. Kita berlindung kepada Allah dari semua keburukan amal kita. Semoga shalawat dan salam tetap tercurah kepada Rasulullah SAW, keluarga, sahabat beserta siapa saja yang mengikuti petunjuknya. Sekali lagi segala pujian hanyalah milih Allah SWT, Rabb semesta alam yang telah memberikan petunjuk serta karunia-Nya sehingga penulis dapat menyelesaikan tesis yang berjudul “Seleksi Kanal Pada *Electroencephalograph* (EEG) Menggunakan Metode *Correlation Feature Selection* (CFS) Untuk Identifikasi *Cybersickness*”.

Tesis ini disusun untuk memenuhi salah satu persyaratan memperoleh gelar Magister Teknik dalam bidang keahlian Telematika-PeTIK, Departemen Teknik Elektro, Fakultas Teknologi Elektro, Institut Teknologi Sepuluh Nopember Surabaya. Pada kesempatan ini penulis ingin menyampaikan rasa hormat dan ucapan terimakasih kepada:

1. Suami dan ananda tersayang Rifial Ridho Assidiqi dan Zahira Sayyidah Assidiqi yang tidak henti-hentinya memberikan semangat kepada penulis dari awal studi magister sampai akhirnya penulis dapat menyelesaikan pendidikan magister dengan lancar. Inshaallah perjuangan yang telah kita lalui menjadi berkah. Kedua orang tua Masjhari dan Titin Rustini, serta bapak dan ibu mertua Bejo Siswanto dan Suniatin yang senantiasa memberikan motivasi dan imun positif sehingga penulis merasa termotivasi untuk melakukan yang terbaik buat masa depan dan keluarga dan mohon maaf jikalau masih sering merepotkan bapak ibu sekalian. Buat adek-adeku Evada Aulia Azhari dan Sabila Zahra Umamy serta seluruh keluarga besar, penulis haturkan terimakasih yang sebesar-besarnya atas segala doa yang tidak terputus selama ini
2. Bapak Dr. Tri Arief Sarjono, S.T., M.T., selaku dekan Fakultas Teknologi Elektro, Institut Teknologi Sepuluh Nopember.

3. Bapak Dr. Adhi Dharma Wibawa, S.T., M. T. selaku koordinator bidang keahlian Magister Telematika-PeTIK dan dosen wali terimakasih atas bimbingan dan saran yang telah banyak diajarkan selama proses perkuliahan.
4. Bapak Prof. Dr. Ir. Mauridhi Hery Purnomo, M.Eng., selaku dosen pembimbing pertama yang selalu sabar membimbing, memberikan semangat, serta memberikan saran baik dalam ranah akademis maupun di luar akademis, serta mengingatkan penulis jika penulis mulai melenceng dari kewajibannya.
5. Bapak Dr. Adhi Dhama Wibawa, S.T., M.T., selaku dosen pembimbing kedua yang selalu memberikan arahan baik secara teknik maupun non teknis terkait dengan tesis yang penulis kerjakan. Berkat beliau juga, penulis mantap untuk mengambil topik tesis yang telah dikerjakan. Penulis juga ingin mengucapkan permohonan maaf jika selama proses bimbingan dengan beliau penulis sering kali menunda tugas yang diberikan sehingga beliau harus mengingatkan kembali mengenai kewajiban penulis.
6. Semua dosen Departemen Teknik Elektro jurusan Telematika-PeTIK ITS yang telah bersedia membagikan ilmunya kepada penulis, mudah-mudahan bermanfaat dan menjadi amalan tersendiri.
7. Semua Civitas Akademika Institut Teknologi Sepuluh Nopember Surabaya, atas semua kebersamaan dan dukungan yang selama ini diberikan kepada penulis selama menimba ilmu.
8. Teman-teman S2 Departemen Teknik Elektro terutama Telematika-PeTIK 2016: Putri, Lutfi, Giovanny, Mbak Ika, Mas Andi, Mas Allan, Pak Luk, Mbak Ajjah, Mas Alfin, Mas A4, Pak Samsul yang saling memberikan dukungan, motivasi dan bantuan lainnya.
9. Teman-teman grup riset Biomedik: Lutfi, Mas Andi, Afif, Bu evi, Walid, Mbak Fahima terimakasih atas segala bentuk diskusi yang sangat membangun dan membantu pembuatan tesis ini.
10. Teman-teman lab B 204 Iit dan lab B 205 (Aisyah, Ajeng, Chipe, Suhairi) terimakasih sudah menjadi bagian dari perjalanan penulis dan menghibur disaat penulis pusing memikirkan tesis.
11. Mahasiswa program doktoral Departemen Teknik Elektro, Institut Teknologi Sepuluh Nopember, Bu Evi, Bu Yuni, Bu Yuhana, Bu Peni yang telah

memberikan nasihat-nasihat serta masukan dalam proses pengerjaan tesis. Spesial untuk Bu Evi, terima kasih telah berbagi ilmu tentang EEG dan bersedia menyediakan waktu dan tenaga untuk berdiskusi terkait dengan topik penelitian penulis.

12. Semua pihak yang telah membantu, mendoakan dan memberikan motivasi dan dorongan serta doa yang tidak dapat saya sebutkan satu persatu.

Penulis menyadari bahwa tesis ini masih sangat jauh dari sempurna karena keterbatasan ilmu dan pengalaman serta pustaka yang digunakan sebagai acuan. Penulis berharap penelitian ini dapat dikembangkan lebih lanjut agar lebih bermanfaat dan bisa dimanfaatkan di bidang pemerintahan khususnya. Oleh karena itu, penulis sangat mengharapkan kritik dan saran yang bersifat membangun agar tesis ini menjadi lebih baik.

Akhir kata, penulis berharap tesis ini memberikan manfaat bagi kita semua terutama untuk pengembangan ilmu pengetahuan.

Surabaya, 15 Juli 2018

*Halaman ini sengaja dikosongkan*

## DAFTAR ISI

LEMBAR PENGESAHAN .....	iii
PERNYATAAN KEASLIAN TESIS .....	v
ABSTRAK .....	vii
ABSTRACT .....	ix
KATA PENGANTAR .....	xi
DAFTAR ISI .....	xv
BAB 1 PENDAHULUAN .....	1
1.1 Latar Belakang .....	1
1.2 Rumusan Masalah .....	4
1.3 Tujuan Penelitian .....	4
1.4 Batasan Masalah .....	5
1.5 Kontribusi .....	5
1.6 Metodologi Penelitian .....	5
BAB 2 KAJIAN PUSTAKA .....	7
2.1 Kajian Penelitian Terkait .....	7
2.2 Teori dasar tentang <i>Cybersickness</i> .....	9
2.2.1 Faktor-faktor yang Mempengaruhi Gejala <i>Cybersickness</i> .....	11
2.2.2 Metode Pengukuran Subjektif pada <i>Cybersickness</i> .....	12
2.2.3 Metode Pengukuran Objektif pada <i>Cybersickness</i> .....	13
2.3 Sinyal Electroencephalograph (EEG) .....	14
2.3.1 Sistem 10/20 Peletakan Posisi Kanal EEG .....	15
2.3.2 Artefact Removal pada Sinyal EEG .....	17
2.3.3 Dekomposisi Sinyal Menggunakan <i>Discrete Wavelet Transform</i> (DWT) .....	19
2.3.4 Ekstraksi Fitur .....	20
2.4 Klasifikasi .....	21
2.4.1 <i>Support Vector Machine</i> (SVM) .....	21
2.4.2 <i>Linier Discriminant Analysis</i> (LDA) .....	27

2.4.3	<i>K-Nearest Neighbour (KNN)</i> .....	28
2.5	Metode <i>Correlation based Feature Selection (CFS)</i> .....	29
BAB 3 METODOLOGI PENELITIAN .....		31
3.1	Tahap awal .....	31
3.1.1	Validasi <i>game</i> .....	31
3.1.2	Pemilihan Partisipan .....	32
3.2	Eksplorasi Alat .....	33
3.3	Pengambilan Data.....	35
3.3.1	Tahap pra-induksi <i>cybersickness</i> .....	36
3.3.2	Tahap Induksi <i>Cybersickness</i> .....	37
3.3.3	Tahap Pasca-Induksi <i>Cybersickness</i> .....	37
3.4	Pengolahan Data.....	38
3.4.1	Pengolahan Data Simulator Sickness Questionnaire (SSQ).....	38
3.4.2	Pengolahan Data Sinyal EEG .....	39
3.4.3	Evaluasi Performansi Seleksi Kanal.....	44
BAB 4 HASIL DAN PEMBAHASAN .....		47
4.1	Pemilihan Data Raw dan Pelabelan Partisipan.....	47
4.2	Pengukuran secara Subjektif .....	48
4.2.1	Hasil Pengukuran Secara Subjektif pada <i>Active game playing</i> .....	54
4.2.2	Hasil Pengukuran Secara Subjektif pada <i>Passive watching</i> .....	56
4.2.3	Perbandingan Hasil SSQ antara <i>Active game playing</i> dan <i>Passive watching</i> .....	58
4.3	Hasil Pengolahan Sinyal EEG .....	59
4.3.1	Hasil Tahap Awal (Pre-processing) pada Pengolahan Sinyal EEG .....	60
4.3.2	Hasil Dekomposisi Sinyal Menggunakan DWT .....	64
4.4	Ekstraksi Fitur .....	65
4.5	Seleksi Fitur Menggunakan Metode <i>Correlation Feature Selection (CFS)</i> .....	66
4.6	Analisa Seleksi Fitur Pada Setiap Partisipan <i>Active Game Playing</i> dan <i>Passive Watching</i> .....	67
4.7	Seleksi Kanal pada EEG.....	70
4.8	Evaluasi Performansi pada Seleksi Kanal EEG .....	71
4.9	Analisa Hasil Secara Keseluruhan .....	74

BAB 5 KESIMPULAN.....	77
5.1 Kesimpulan .....	77
5.2 Penelitian Selanjutnya.....	77
DAFTAR PUSTAKA .....	79
LAMPIRAN -LAMPIRAN.....	81
LAMPIRAN 1 .....	81
LAMPIRAN 2 .....	82
LAMPIRAN 3 .....	83
BIOGRAFI PENULIS .....	85

*Halaman ini sengaja dikosongkan*

## DAFTAR GAMBAR

Gambar 2.1 Metode pengukuran untuk menentukan lokasi electrode berdasarkan system 10-20 pengukuran bidang anterior-posterior (a), pengukuran bidang central coronal (b), pengukuran berdasarkan lingkaran tengkorak (c).....	16
Gambar 2.2 Sistem Peletakan Elektrode 10-20 [18].....	17
Gambar 2.3 Sinyal EOG yang tercampur pada Sinyal EEG.....	18
Gambar 2.4 Proses Dekomposisi Sinyal.....	20
Gambar 2.5 (a) Fungsi klasifikasi <i>linear</i> pada kasus <i>linearly separable</i> dan (b) Fungsi klasifikasi <i>non-linear</i> pada kasus <i>linearly non-separable</i> .....	21
Gambar 2.6 <i>Hyperplane</i> pemisah $x^T w + b = 0$ dan margin di dalam kasus <i>linearly separable</i> .....	22
Gambar 2.7. Bidang pemisah $x^T w + b = 0$ dan margin di dalam kasus <i>linearly non-separable</i> .....	24
Gambar 2.8. Transformasi dari <i>data space</i> dua-dimensi menjadi <i>feature space</i> tiga dimensi $\mathbb{R}^2 \mapsto \mathbb{R}^3$ (diambil dari [25]).....	26
Gambar 2.9 Skema pada <i>Correlation Based Feature Selection</i> (CFS).....	30
Gambar 3.1. Prosedur Metodologi Penelitian.....	31
Gambar 3.2 Sample Tampilan <i>Game</i> “Mirror Edge”.....	32
Gambar 3.3. Cek koneksi Internet pada <i>Software</i> .....	34
Gambar 3.4. Cek Ketahanan Baterai.....	34
Gambar 3.5. Pemasangan Hardware terhadap partisipan dan Posisi Elektroda pada EmotivPro.....	35
Gambar 3.6. Data stream yang ditampilkan pada software EmotivPro.....	35
Gambar 3.7 Metodologi Penelitian.....	36
Gambar 3.8 Kondisi partisipan saat induksi <i>cybersickness</i> berlangsung.....	37
Gambar 3.9. Metode Pengolahan Data EEG.....	39
Gambar 3.10. Metode Pra proses sinyal EEG menggunakan ICA.....	40
Gambar 3.11. Segmentasi data.....	41
Gambar 3.12 Dekomposisi level menggunakan DWT.....	42
Gambar 3.13 Metode Pengolahan Data.....	43
Gambar 3.14 Prosedur Seleksi Kanal Menggunakan <i>Metode Correlation Feature Selection</i> (CFS).....	44
Gambar 3.15. Diagram Alir Proses Seleksi Fitur dan Klasifikasi.....	46
Gambar 4.1. Hasil SSQ pada Kategori Nausea pada (a) <i>Active game playing</i> (9 partisipan) dan (b) <i>Passive watching</i> (4 partisipan).....	50
Gambar 4.2 Hasil SSQ pada Kategori Oculomotor pada (a) <i>Active game playing</i> (9 partisipan) dan (b) <i>Passive watching</i> (4 partisipan).....	51
Gambar 4.3 Hasil SSQ pada Kategori Disorientasi pada (a) <i>Active game playing</i> (9 partisipan) dan (b) <i>Passive watching</i> (4 partisipan).....	53
Gambar 4.4 Hasil Rata-rata Pengukuran SSQ pada kondisi <i>Active game playing</i> (Mean = 9 partisipan).....	54

Gambar 4.5 Total Score SSQ pada setiap partisipan saat induksi <i>active game playing</i> .....	55
Gambar 4.6 Hasil Rata-rata Pengukuran SSQ pada <i>Passive watching</i> (Mean = 4 partisipan) .....	56
Gambar 4.7 Total Score SSQ pada setiap partisipan saat induksi <i>passive watching</i> .....	57
Gambar 4.8. Nilai hasil perbandingan SSQ antara <i>Active game playing</i> dan <i>Passive watching</i> (total partisipan 4 orang).....	58
Gambar 4.9 Mulai menggunakan toolbox EEGLAB menggunakan MATLAB ...	60
Gambar 4.10 Memasukan data raw di EEGLAB .....	61
Gambar 4.11 Data Raw Partisipan Sebelum proses ICA .....	62
Gambar 4.12 Pengaturan lokasi 14 kanal pada EEGLAB .....	62
Gambar 4.13 Proses Run ICA berlangsung .....	63
Gambar 4.14 Hasil Data Raw setelah Proses ICA.....	64
Gambar 4.15 Dekomposisi sinyal menggunakan db4 pada sinyal (a) teta, (b) alpha dan (c) beta .....	65
Gambar 4.16 Posisi dari Seleksi Kanal pada : (a) Induksi <i>active game playing</i> dan (b) Induksi <i>Passive watching</i> .....	71
Gambar 4.17 Hasil Klasifikasi Data menggunakan algoritma : (a) SVM-P, (b) LDA dan (c) KNN pada Induksi <i>Active game playing</i> .....	72
Gambar 4.18 Hasil Klasifikasi Data menggunakan algoritma : (a) SVM-P, (b) LDA dan (c) KNN pada Induksi <i>Passive watching</i> .....	73

## DAFTAR TABEL

Tabel 2.1. 3 Sub-Kategori Pada <i>Simulator Sickness Questionnaire (SSQ)</i> .....	13
Tabel 2.2 Hubungan antara Gejala dan Profil SSQ.....	13
Tabel 3.1 Rentang frekuensi gelombang hasil dari Dekomposisi sinyal .....	42
Tabel 4.1. Pelabelan data Partisipan .....	48
Tabel 4.2 Hasil Seleksi Fitur Menggunakan Metode CFS pada setiap partisipan ( <i>active game playing</i> ).....	66
Tabel 4.3 Hasil Seleksi Fitur Menggunakan Metode CFS pada setiap partisipan ( <i>passive watching</i> ).....	67
Tabel 4.4 Hasil Seleksi Fitur <i>Power percentage</i> pada Partisipan saat Induksi <i>Active game playing</i> .....	68
Tabel 4.5 Hasil Seleksi Fitur <i>Power percentage</i> pada Partisipan saat Induksi <i>Passive watching</i> .....	68

*Halaman ini sengaja dikosongkan*

# BAB 1

## PENDAHULUAN

### 1.1 Latar Belakang

Dewasa ini, perkembangan teknologi yang sangat pesat telah mampu mengubah pola hidup manusia secara signifikan. Salah satu dampak dari kemajuan teknologi adalah ketergantungan manusia terhadap teknologi yang sangat tinggi, sebagai contoh masyarakat lebih memilih untuk berkomunikasi di dunia maya daripada berkomunikasi secara langsung dengan komunitas mereka. Kondisi ini diperkuat dengan adanya survei yang dilakukan oleh *www.emarketer.com*, dimana Indonesia melampaui 100 juta pengguna *smartphone* aktif di tahun 2018. Berbagai fitur yang ditawarkan oleh *smartphone* membuat manusia tidak bisa lepas dari teknologi.

Perkembangan teknologi juga terjadi pada bidang hiburan, salah satunya adalah munculnya teknologi *three-dimensional* (3D) yang tidak hanya diaplikasikan pada film melainkan juga *game*. Hal ini dapat memberikan peluang bagi perusahaan *game* untuk berinovasi dalam menciptakan *game* berbasis 3D yang memiliki tampilan gambar yang lebih bagus, detail dan tampak seperti nyata. Perkembangan *game* 3D juga didukung oleh teknologi *Virtual Reality* (VR). VR merupakan teknologi antarmuka yang berfungsi menghasilkan gambar yang *immersive* dan nyata yang diaplikasikan kedalam *stereoskopis* 3D. Oleh karena itu, hal ini mampu menarik masyarakat untuk lebih memilih *game* 3D daripada *game* 2D. Teknologi VR dilengkapi dengan *screenplay* (*Virtual Environment* (VE)) dapat menciptakan seolah-olah pemain *game* berinteraksi langsung dengan karakter di dalam *game* tersebut (*immersive feeling*). Berdasarkan survei yang dilakukan oleh *Entertainment Software Association* (ESA) pada tahun 2016 [1] bahwasanya sebanyak 63% penggemar *game* di dunia tidak asing dengan adanya teknologi VR dan sebagian besar dari mereka cenderung akan membeli perangkat VR yaitu *Head Mounted Display* (HMD) di masa yang akan datang.

Kecanduan *smartphone* dan *game* merupakan salah satu efek dari era digital. Efek ini memberikan dampak negatif jika tidak digunakan secara bijak. Para

ilmuwan sering menyebutnya sebagai gejala *Cybersickness*. *Cybersickness* adalah sebuah fenomena yang sering terjadi pada manusia ketika melihat tampilan/paparan 3D pada film, layar *smartphone* dan bermain *game* menggunakan *Virtual Reality* (VR) atau monitor. Fenomena ini muncul diakibatkan oleh pergerakan pada layar virtual atau *stereoskopis* 3D sehingga membuat manusia mengalami *immersive*. *Cybersickness* menimbulkan beberapa gejala yang tidak menyenangkan seperti mual, pusing, ketegangan mata dan kehilangan keseimbangan [2]. Berdasarkan penelitian yang dilakukan oleh Cobb pada tahun 1999 [3], disebutkan bahwa sebanyak 80% dari semua partisipan yang mengikuti eksperimen mengalami peningkatan gejala *cybersickness* saat mereka melihat paparan *virtual reality* selama 10 menit.

*Cybersickness* merupakan bagian dari Motion Sickness (MS). Keduanya memiliki gejala yang sama, meskipun definisi dari keduanya berbeda. *Cybersickness* terjadi ketika seseorang seakan-akan mengalami pergerakan yang disebabkan oleh virtual scene/monitor, namun pada kenyataannya tubuh mereka tidak mengalami pergerakan atau cenderung statis, sedangkan Motion Sickness sering dihubungkan dengan mabuk transportasi, seperti mabuk laut (sea sickness), mabuk udara (air sickness) maupun mabuk darat (car sickness). Gejala Motion Sickness terjadi saat penumpang merasakan pergerakan yang disebabkan oleh alat transportasi yang digunakan.[4]

Penelitian mengenai investigasi *cybersickness* telah banyak dilakukan sebelumnya, baik menggunakan metode pengukuran subjektif maupun objektif. Pada penelitian yang dilakukan oleh [4],[5],[6], para peneliti melakukan investigasi *cybersickness* dengan cara memberikan stimulus menggunakan video game. Setelah itu, peneliti meminta partisipan untuk mengisi kuesioner *cybersickness* seperti pada *Motion Sickness Susceptibility Questionnaire* (MSSQ), *Simulator Sickness Questionnaire* (SSQ) atau *Nausea Rating Level*. Hal ini dilakukan untuk mengetahui kondisi partisipan sebelum dan setelah induksi dilakukan. Namun, metode ini dinilai memiliki tingkat validasi yang rendah karena tingkat subjektivitas yang sangat tinggi. Oleh karena itu, metode pengukuran secara objektif ditawarkan untuk menanggulangi masalah tersebut. Pengukuran objektif yang biasa digunakan oleh beberapa peneliti terdahulu untuk menginvestigasi gejala *cybersickness*

diantara Electroencephalograph (EEG), Electrocardiograph (ECG), Electrogastrograph (EGG), Galvanic Skin Response (GSR). Penelitian yang dilakukan oleh Kim *et al* tahun 2005 [7], menggunakan pengukuran secara subjektif (MSSQ dan SSQ) dan objektif secara multimodal (electrocardiograph (ECG 100), electrooculogram (EOG 100), skin conductance (GSR 100), photoplethysmogram (PPG 100), skin temperature (SKT 100), electrogastrogram (EGG 100), respiration pneumogram (RSP 100), and encephalograms (EEG 100)). Tujuan utama dari penelitian yang dilakukan oleh Kim adalah untuk mengetahui perubahan karakteristik pada komponen physiological saat induksi berlangsung pada partisipan. Penelitian yang sama dilakukan oleh Wibirama *et al* tahun 2014 [8], Untuk menginvestigasi *cybersickness* peneliti menggunakan pengukuran ECG, 3D gaze tracker sebagai pengukuran objektif dan menggunakan SSQ sebagai pengukuran secara subjektif. Film berbasis 3D digunakan sebagai stimulus dalam eksperimen tersebut. Sedangkan penelitian yang dilakukan oleh Ali *et al* pada tahun 2015[9], Peneliti menggunakan EEG dan SSQ untuk menginvestigasi terjadinya *cybersickness* serta untuk membandingkan gejala *cybersickness* yang terjadi pada dua induksi yang berbeda yaitu melalui film berbasis 2D dan 3D.

Pada penelitian ini, *cybersickness* diidentifikasi menggunakan SSQ sebagai metode pengukuran subjektif dan EEG multi kanal sebagai alat ukur objektif. Hal ini dikarenakan EEG memiliki sensitifitas yang tinggi dan efektif dalam mengetahui perubahan aktivitas otak pada manusia, dimana otak memiliki fungsi utama yaitu mengendalikan semua fungsi tubuh manusia. Namun, meskipun diakui sebagai alat ukur yang memiliki sensitivitas dan objektifitas yang tinggi, terdapat beberapa permasalahan yang muncul dalam hasil perekaman sinyal EEG pada multi kanal, diantaranya adanya gangguan/noise yang semakin tinggi dan kompleksitas sebuah algoritma yang tinggi. Oleh karena itu, fokus utama pada penelitian ini adalah melakukan seleksi kanal pada EEG dengan cara menghilangkan kanal-kanal yang tidak relevan menggunakan metode *Correlation Feature Selection* (CFS). Pemilihan kanal yang relevan diharapkan dapat digunakan sebagai langkah awal dalam mengidentifikasi *cybersickness*, sehingga sinyal yang didapatkan dari hasil perekaman menggunakan EEG lebih optimal dan akurat serta tidak membutuhkan kompleksitas algoritma yang tinggi.

Untuk membangkitkan *cybersickness* digunakan induksi berupa *video game* “Mirror Edge” yang merupakan rekomendasi dari komunitas *game* Surabaya (GADAS), selain itu *game* ini juga pernah digunakan oleh [6] pada kasus yang sama. Perekaman dan seleksi kanal EEG dilakukan pada dua kondisi induksi yang berbeda yaitu pada *active game playing* dan *passive watching*.

## 1.2 Rumusan Masalah

*Cybersickness* adalah fenomena yang sering ditemukan di era digital. Namun, perhatian masyarakat terhadap fenomena tersebut dirasa sangat kurang. Permasalahan ini jika tidak ditangani secara cepat dan tepat akan bersifat fatal dan berdampak pada menurunnya tingkat fokus seseorang sehingga dapat menimbulkan kelelahan fisik dan mental, sehingga perlu adanya identifikasi *cybersickness* untuk menanggulangi hal tersebut. Salah satu cara untuk mengidentifikasi *cybersickness* adalah menggunakan alat ukur EEG multi kanal. Namun, salah satu kelemahan dari penggunaan EEG multikanal adalah semakin banyak kanal yang digunakan maka semakin banyak noise/artefak yang mempengaruhi hasil perekaman sinyal EEG serta memerlukan kompleksitas algoritma yang sangat tinggi. Oleh karena itu, diperlukan metode seleksi kanal untuk menghasilkan kanal-kanal yang lebih relevan sehingga dapat dijadikan sebagai langkah awal dalam mengidentifikasi *cybersickness* dengan lebih optimal. Selain itu, seleksi kanal juga berfungsi dalam meningkatkan akurasi.

## 1.3 Tujuan Penelitian

Adapun tujuan penelitian ini adalah sebagai berikut:

- Untuk mencari kanal yang paling relevan dengan menggunakan metode *Correlation Feature Selection* (CFS) sehingga kanal-kanal tersebut dapat dijadikan sebagai langkah awal dalam melakukan identifikasi *cybersickness*.
- Membandingkan akurasi pada algoritma SVM-P, LDA dan KNN antara sebelum dan setelah menggunakan seleksi kanal

#### 1.4 Batasan Masalah

Pada penelitian ini dilakukan batasan-batasan sebagai berikut:

- Subjek penelitian adalah mahasiswa yang berumur 19 – 30 tahun dengan kondisi sehat, memiliki penglihatan normal, tidak mengkonsumsi dan ketergantungan obat dan tidak memiliki gangguan tidur.
- Stimulus yang digunakan pada penelitian ini adalah video *game* “Mirror Edge” yang diciptakan oleh EA Digital Illusion CE (DICE) 2008. *Game* ini merupakan rekomendasi dari komunitas *game* Surabaya (GADAS) dan pernah digunakan oleh Guo *et al* tahun 2008.
- Partisipan belum pernah bermain *game* “Mirror Edge” sebelumnya. Sehingga diadakan *training session* terhadap setiap partisipan sebelum pengambilan data dilakukan.
- Penelitian ini menggunakan alat ukur EEG Emotive Epoch 14 kanal dengan frekuensi sampling 256 Hz.
- Penelitian ini hanya focus pada seleksi kanal pada EEG menggunakan Metode seleksi fitur *Correlation Feature Selection* (CFS).

#### 1.5 Kontribusi

Pemanfaatan seleksi kanal pada sinyal EEG dalam menginvestigasi kondisi *cybersickness* diharapkan dapat:

- Mengetahui kanal-kanal yang paling relevan untuk dijadikan sebagai indikator dalam mengidentifikasi *cybersickness*.
- Mengetahui perbandingan hasil akurasi antara sebelum dan sesudah pemanfaatan metode *Correlation Feature Selection* (CFS) pada algoritma SVM-P, LDA dan KNN.

#### 1.6 Metodologi Penelitian

Secara garis besar metode yang akan digunakan untuk menyelesaikan penelitian ini terdiri dari beberapa tahapan sebagai berikut:

- Pengambilan data *cybersickness* melalui perekaman sinyal EEG multi kanal dan pengisian kuesioner SSQ pada partisipan dengan induksi bermain video game 3D (Mirror Edge).
- Melakukan pre-processing, segmentation dan dekomposisi level band frekuensi pada sinyal EEG.
- Melakukan ekstraksi fitur pada sinyal EEG, terutama pada frekuensi band alpha, beta dan theta.
- Melakukan estimasi pelabelan data berdasarkan hasil kuesioner SSQ, kondisi sebelum bermain game ditentukan sebagai label kondisi baseline, sedangkan kondisi setelah bermain game ditentukan sebagai label kondisi *cybersickness*
- Melakukan seleksi kanal menggunakan metode *Correlation Feature Selection* (CFS).
- Mengevaluasi hasil akurasi pada kanal yang telah terpilih menggunakan algoritma SVM-P, LDA dan KNN.

## **BAB 2**

### **KAJIAN PUSTAKA**

Bab ini membahas mengenai kajian pustaka yang menjadi dasar dalam penelitian ini, diantaranya kajian penelitian yang terkait dan teori dasar dari penelitian ini.

#### **2.1 Kajian Penelitian Terkait**

Telah banyak penelitian mengenai investigasi *cybersickness*, baik menggunakan pengukuran secara subjektif, objektif atau perpaduan antara keduanya. Penelitian yang dilakukan oleh [5],[4] dan [6] merupakan penelitian *cybersickness* yang menggunakan kuesioner untuk mengukur gejala dari *cybersickness*. Bahit et al [5] menggunakan Simulator Sickness Questionnaire (SSQ) untuk menginvestigasi *cybersickness* menggunakan induksi *driving simulator*, dimana pengambilan data dilakukan pada pagi dan malam hari. SSQ merupakan metode pengukuran subjektif yang dikembangkan oleh Kennedy et al pada tahun 1993 dengan judul penelitian “*Simulator Sickness Questionnaire: An Enhanced Method for Quantifying Simulator Sickness*”. Sedangkan penelitian yang dilakukan oleh Davis tahun 2015 [4] yaitu mengukur terjadinya time onset *cybersickness* dengan dua tipe induksi roller coaster 3D yang berbeda (*Parrot Coaster dan Helix Coaster*) dan menggunakan HMD Oculus Rift. Pengukuran subjektif yang digunakan adalah *nausea level rating* dengan skala 0-10 yang diukur setiap 2 menit sekali dari total induksi 14 menit pada setiap partisipan. Hasil dari penelitian ini adalah induksi Helix Coaster menghasilkan level *cybersickness* lebih tinggi daripada Parrot coaster dikarenakan tampilannya sangat realistic dan terlihat seperti nyata sehingga partisipan mengalami perasaan immersive sanga tinggi daripada induksi menggunakan Parrot coaster. Adapun Guo et al tahun 2003, juga menggunakan SSQ sebagai pengukuran secara subjektif yang diterapkan pada 2 model kondisi yang berbeda yaitu menginvestigasi *cybersickness* pada kondisi *active game playing* dan *passive watching*. Adapun hasil dari penelitian ini adalah nilai SSQ pada induksi passive watching lebih tinggi daripada induksi active game

playing. Semakin tinggi nilai SSQ maka semakin tinggi gejala *cybersickness* yang terjadi.

Namun, penggunaan pengukuran secara subjektif memiliki validasi yang sangat kurang dikarenakan pengukurannya berdasarkan *self-report* dari partisipan yang memiliki sifat subjektifitasnya yang tinggi. Oleh karena itu, pengukuran secara objektif/fisiologis ditawarkan untuk menanggulangi masalah tersebut. Telah banyak jenis pengukuran fisiologis yang digunakan untuk menginvestigasi terjadinya *cybersickness* diantaranya *Electroencephalograph* (EEG), *Electrocardiograph* (ECG), *Galvanic Skin Response* (GSR), dll. Dennison et al [10] menggunakan perpaduan pengukuran subjektif (SSQ dan MSSQ) dan objektif (EEG, EGG, ECG, GSR) untuk menginvestigasi terjadinya *cybersickness* pada partisipan yang diinduksi menggunakan virtual environment melalui HMD dan layar monitor, dimana hasil dari penelitian ini didapatkan bahwa seseorang yang melihat paparan *virtual environment* menggunakan HMD lebih cepat mengalami gejala *cybersickness* daripada saat melihat melalui layar monitor. Sedangkan, Kim et al tahun 2005 [7] menggunakan EEG multi kanal dan SSQ untuk mengetahui karakteristik yang berubah saat stimulus berlangsung melalui fitur *relative band power* beta dan teta pada kanal tertentu. Terdapat hubungan antara hasil dari EEG dan SSQ, *cybersickness* terjadi ketika nilai SSQ naik sedangkan nilai *relative beta* ( $\beta$ ) *band power* turun dan delta ( $\delta$ ) *band power* naik. Hal ini dikarenakan, ketika seseorang mengalami *cybersickness* maka tingkat konsentrasi dan fokus seseorang akan turun, dimana dua hal ini paling banyak dipengaruhi oleh frekuensi band beta. Lain halnya pada penelitian yang dilakukan oleh [9], focus penelitian yang dilakukan adalah membandingkan antara teknologi 3D pasif dengan paparan konvensional 2D menggunakan EEG sebagai pengukuran secara objektif dan SSQ sebagai pengukuran secara subjektif. Adapun hasil dari pengukuran SSQ adalah seseorang yang melihat paparan 3D lebih cepat mengalami gejala *cybersickness* daripada saat melihat paparan 2D. Sedangkan berdasarkan pengukuran sinyal EEG, seseorang yang melihat paparan 2D mengalami peningkatan pada bagian otak frontal pada theta band tetapi mengalami tren penurunan pada frontal-theta band dan temporal-beta band pada saat kondisi seseorang melihat paparan 3D. Dari

penjelasan diatas dapat disimpulkan bahwa melihat paparan 3D terlalu lama dapat memberikan efek negative pada perubahan aktivitas otak secara signifikan.

## 2.2 Teori dasar tentang *Cybersickness*

Perkembangan teknologi *virtual reality* berdampak pada munculnya fenomena *cybersickness*. Menurut La Viola Jr et al [2], *cybersickness* merupakan fenomena yang disebabkan ketika seseorang melihat paparan virtual environment seperti film 3D, video *game* 3D dalam waktu tertentu, dengan gejala yang terjadi diantaranya ketegangan pada mata, pusing, muka pucat, berkeringat, mual dan kehilangan keseimbangan. Definisi ini didukung oleh penelitian yang dilakukan oleh [3], dimana sebanyak 80% dari partisipan yang mengikuti penelitian mengalami peningkatan gejala *cybersickness* saat melihat paparan virtual environment lebih dari 10 menit. Semua partisipan mengalami perasaan *immersive* ketika melihat paparan 3D sehingga seolah-olah mereka berinteraksi dengan dunia *virtual reality*.

*Cybersickness* merupakan bagian dari *motion sickness*, keduanya memiliki gejala yang sama. Namun yang membedakan adalah, gejala *motion sickness* terjadi ketika seseorang melakukan perjalanan dan mengalami mabuk perjalanan akibat dari pergerakan dari alat transportasi yang digunakan seperti bus, kapal, pesawat dll. Sehingga dapat dikatakan bahwa *motion sickness* erat hubungannya dengan mabuk perjalanan. Sedangkan gejala *cybersickness* terjadi akibat seseorang karena pengaruh melihat tayangan/paparan *virtual reality* yang terlalu lama dimana pengguna merasa pergerakan yang dinamis dalam dunia maya, padahal sebenarnya tubuh mereka *stasioner* atau tidak terjadi pergerakan pada dunia nyata atau dikenal dengan teori *sensory conflict*.

Menurut [4], *Cybersickness* juga dapat dipengaruhi oleh induksi spesifik yang didapatkan pengguna pada lingkungan virtual. Faktor utama yang mempengaruhi adalah kemampuan tingkat kontrol yang dimiliki pengguna dan durasi terhadap lingkungan virtual yang dijadikan sebagai induksi. Peserta yang memiliki kontrol yang baik dalam lingkungan virtual dapat memprediksi gerakan masa depan dengan lebih baik maka tidak akan mengalami peningkatan gejala *cybersickness*. Namun, mereka yang tidak memiliki kendali atas lingkungan virtual

dan tidak memiliki tingkat kepastian yang sama tentang lingkungan lebih rentan terhadap gejala *cybersickness*.

Induksi *cybersickness* terdiri dari 3 macam, yaitu visual, vestibular dan visual-vestibular. Induksi visual adalah induksi yang hanya mempengaruhi pergerakan visual, seperti melihat tayangan film 3D, video *game* dalam lingkungan virtual baik menggunakan *Head Mounted Display* (HMD) maupun monitor (*screen*). Induksi vestibular adalah induksi yang mempengaruhi saraf sistem vestibular, seperti bermain komedi putar. Sedangkan, induksi visual-vestibular adalah induksi yang mempengaruhi kedua sistem saraf, seperti bermain *game* menggunakan HMD secara aktif, dimana avatar dalam *game* dikontrol menggunakan gerakan tubuh. Sehingga gerakan tubuh mempengaruhi gerakan avatar pada dunia virtual.

Ada tiga teori utama yang mempengaruhi *cybersickness* [2], diantaranya : *Pertama*, teori konflik sensor (*Sensory Conflict Theory*) teori ini merupakan teori pertama, tertua dan sering dihubungkan dengan terjadinya gejala *cybersickness*. Teori konflik sensori terdiri dari 2 sensor utama yang terlibat pada lingkungan virtual yaitu visual dan vestibular. Kedua sensor ini memberikan informasi tentang orientasi individu dan gerakan yang dirasakan. Teori ini menjelaskan bahwa terdapat ketidakcocokan/konflik dari kedua indra, dalam artian sistem vestibular mungkin memberitahu individu bahwa tubuh mereka stationer namun sistem visual mengatakan bahwa tubuh mereka bergerak. Ketidakcocokan sensor ini menyebabkan terjadinya gejala *cybersickness*.

*Kedua*, Teori racun (*Poison Theory*), Teori ini menstimulus rangsangan visual dan rangsangan vestibular yang dapat menyebabkan *motionsickness* sehingga tanpa sengaja mengaktifkan sensor otak untuk mendeteksi racun. Teori ini menunjukkan bahwa konsumsi racun dapat menyebabkan efek fisiologis dan melibatkan koordinasi visual, vestibular dan sensor masukan lainnya. *Virtual reality* dapat mempengaruhi sistem visual dan vestibular sedemikian rupa sehingga tubuh salah membaca informasi dan mengira telah menelan beberapa jenis zat beracun sehingga menimbulkan gejala *cybersickness*.

*Ketiga*, Teori Ketidakstabilan Postural (*Postural Instability Theory*), Teori ini bertujuan bagaimana seseorang dalam mengatur kestabilan postural di

lingkungan. Ketidakstabilan postural yang berkepanjangan dapat menyebabkan gejala *cybersickness*. Perubahan visual yang tidak sama dengan keadaan normal pada gerakan tubuh dapat menyebabkan konflik pada postural normal.

### **2.2.1 Faktor-faktor yang Mempengaruhi Gejala *Cybersickness***

Setelah mengetahui teori dasar dari *cybersickness*, selanjutnya akan dijelaskan mengenai faktor-faktor yang mempengaruhi gejala *cybersickness*. *Cybersickness* dipengaruhi oleh faktor individu yang terdiri dari *umur*, *gender*, *penyakit* dan *posisi saat simulasi berlangsung*. Menurut [2], anak-anak usia 2 sampai 12 tahun sangat rentan mengalami gejala *cybersickness*, kemudian hal ini berkurang seiring dengan bertambahnya usia yaitu sekitar 12 sampai 21 tahun. Sedangkan, seseorang yang berusia 50 tahun tidak rentan mengalami *cybersickness*. Untuk faktor gender dijelaskan bahwa perempuan lebih rentan terkena *cybersickness* daripada laki-laki, hal ini dikarenakan perempuan memiliki *field of view* lebih luas daripada laki-laki. Seseorang yang memiliki penyakit kronis ataupun penyakit yang berhubungan dengan kelelahan, stress, flu dan sesak nafas seharusnya tidak diperkenankan untuk melihat tayangan 3D dikarenakan dapat mempercepat terjadinya *cybersickness* sehingga dapat mempengaruhi kondisi psikis dan fisiologis seseorang. Faktor terakhir adalah posisi partisipan saat simulator berlangsung, dimana berdasarkan *postural instability* teori, seseorang yang duduk saat terpapar lingkungan virtual dapat mengurangi terjadinya gejala *cybersickness* daripada seseorang yang berdiri, karena posisi duduk lebih bersifat stabil secara postural tubuh daripada berdiri

Penelitian yang dilakukan oleh [11], faktor individu pada *cybersickness* juga dipengaruhi oleh stimulus yang digunakan. Renee Lisa et al menggunakan stimulus *video game* pada penelitiannya dan menyebutkan bahwa partisipan yang mempunyai kemampuan bermain *game* dengan baik maka cenderung tidak rentan mengalami *cybersickness*. Selain itu, faktor *cybersickness* juga dipengaruhi oleh *hardware* dan *software* yang digunakan sebagai stimulus, diantaranya:

1. Penggunaan HMD pada saat melihat paparan 3D dapat meningkatkan gejala *cybersickness* dikarenakan selain gejala muncul akibat dari pengaruh paparan tetapi juga akibat dari berat dari HMD itu sendiri,

2. Ukuran layar (*screen size*), semakin besar layar yang digunakan untuk menampilkan paparan 3D maka *field of view* juga semakin luas sehingga hal ini dapat meningkatkan terjadinya gejala *cybersickness*,
3. Gambar *stereo* dapat meningkatkan terjadinya *cybersickness* daripada *bi-ocular*.

### **2.2.2 Metode Pengukuran Subjektif pada *Cybersickness***

Ada beberapa metode pengukuran yang digunakan untuk mengukur tingkat *cybersickness* seseorang, diantaranya:

#### *2.2.2.1 Motion Sickness Susceptibility Questionnaire (MSSQ)*

Metode ini dikembangkan oleh Golding JF pada tahun 2006 [12] untuk memprediksi bagaimana kerentanan seseorang terhadap *motion sickness* berdasarkan pengalaman di masa lalu. MSSQ memiliki 2 sub metode penilaian. Submetode yang pertama adalah MSSQ-A dimana metode ini menilai kerentanan terjadinya *motion sickness* berdasarkan pengalaman perjalanan di masa kecil (sebelum berumur 12 tahun). Submetode yang kedua adalah MSSQ-B metode ini mengukur kerentanan *motion sickness* pada perjalanan yang dilakukan pada 10 tahun terakhir. Pertanyaan yang dijawab adalah berapa sering partisipan merasakan sakit atau muntah selama melakukan aktifitas yang berbeda dan setelah itu dilakukan skoring dengan 5 poin ukuran yang berbeda: 0 tidak pernah, 1 jarang, 2 kadang-kadang, 4 sering, 5 selalu. Frekuensi perjalanan menggunakan transportasi yang berbeda juga dianalisa dan digunakan untuk menghitung skor final. Pengukuran menggunakan MSSQ telah dilakukan oleh [10]. Pengukuran menggunakan MSSQ pernah digunakan oleh [13] untuk mengetahui tingkat *sickness*.

#### *2.2.2.2 Simulator Sickness Questionnaire (SSQ)*

*Simulator Sickness Questionnaire* (SSQ) dikembangkan oleh [14] pada tahun 1993. SSQ terdiri dari 16 gejala, dengan skala penilaian terdiri dari 4 skala yaitu: 0 (tidak merasakan *cybersickness*), 1 (sedikit), 2 (sedang) dan 3 (parah). 16 gejala kemudian dikelompokkan menjadi 3 sub kategori yang terdiri dari *Nausea*, *Oculomotor* dan *Disorientation*, seperti pada Tabel 2.1.

Tabel 2.1. 3 Sub-Kategori Pada *Simulator Sickness Questionnaire (SSQ)*

<b>Nausea</b>	<b>Oculomotor</b>	<b>Disorientation</b>
Ketidaknyaman scr umum	Ketidaknyaman scr umum	Susah Fokus
Air liur meningkat	Lelah	Mual
Berkeringat	Sakit kepala	Kepala merasa penuh
Mual	Ketegangan mata	Penglihatan blur
Susah konsentrasi	Susah Fokus	Pusing (mata terbuka)
Perut merasa tdk nyaman	Susah konsentrasi	Pusing (mata tertutup)
Bersendawa	Penglihatan blur	Vertigo

Kategori *Nausea* adalah gejala *cybersickness* yang berhubungan dengan tingkat kemualan seseorang, *Oculomotor* adalah gejala *cybersickness* yang berhubungan dengan sistem pergerakan pada otot mata, sedangkan *Disorientation* adalah gejala *cybersickness* yang berhubungan dengan tingkat keseimbangan. SSQ tidak hanya diperuntukkan untuk mengukur gejala *cybersickness*, melainkan untuk mengukur tingkat *motion* pada simulator kemiliteran, mabuk laut dan mabuk udara. Kennedy et al [14] mengukur munculnya gejala tersebut berdasarkan peringkat dari ketiga sub kategori yang dapat dilihat pada Tabel 2.2. gejala *cybersickness* terjadi ketika  $SSQ-D > SSQ-N > SSQ-O$ , Namun ketentuan ini tidak berlaku pada semua penelitian [3].

Tabel 2.2 Hubungan antara Gejala dan Profil SSQ

<b>Rating</b>	<b>Military simulator</b>	<b>Sea sickness</b>	<b>Space sickness</b>	<b>Cybersickness</b>
<b>Highest rating</b>	Oculomotor	Nausea	Nausea	Disorientasi
<b>Middle rating</b>	Nausea	Oculomotor	Disorientasi	Nausea
<b>Lowest rating</b>	Disorientasi	Disorientasi	Oculomotor	Oculomotor

### 2.2.3 Metode Pengukuran Objektif pada *Cybersickness*

Penelitian yang dilakukan oleh [10] untuk menganalisa terjadinya *cybersickness* yaitu menggunakan beberapa pengukuran psikologis yang direkam menggunakan Biopac MP150 (BIOPAC sistem, Inc.) Sinyal direkam menggunakan modul untuk ECG, EGG, EOG, PPG, upaya pernapasan dan respon kulit

galvanic. Hasilnya bahwa ada perubahan aktivitas perut, kedipan mata dan pernapasan yang menunjukkan ketidaksesuaian antara sinyal dari dunia nyata dan dunia virtual untuk mengaktifkan sistem saraf otonom sebagai respon ketidaknyamanan situasi.

Analisa pengukuran menggunakan metode objektif juga dilakukan oleh [7], peneliti mengumpulkan sejumlah 16 parameter elektropsikologikal selama pengguna melihat tayangan/paparan di dalam *virtual reality*. Hasil dari penelitian ini menyebutkan bahwa beberapa parameter meningkat pada *gastric tachyarrhythmias*, rata-rata kedipan mata, konduktansi kulit, pernapasan sinus arrhythmias dan daya delta pada EEG, sementara parameter yang menurun adalah detak jantung, suhu *fingertrip*, dan daya beta pada EEG. Perubahan parameter pada *gastric tachyarrhythmias*, rata-rata kedipan mata, rata-rata pernapasan, pernapas sinus arrhythmias dan detak jantung memiliki korelasi yang positif dan signifikan terhadap nilai subjektif dari *cybersickness*.

Penelitian yang dilakukan oleh [8], menggunakan *Electrocardiography* (ECG) dan 3D *gaze tracking* untuk investigasi *Visual Induced Motion Sickness* (VIMS) atau *Cybersickness*, stimulus yang digunakan adalah 2 jenis film yang berbeda ( 1 film 3D yang memiliki motion rendah dan 1 film 3D yang memiliki motion tinggi). Adapun hasil dari penelitian ini adalah seseorang cenderung mengalami *cybersickness* saat melihat film 3D dengan tingkat pergerakan yang sangat tinggi (*high motion*) daripada film 3D yang memiliki pergerakan rendah. Gejala *cybersickness* terjadi ketika ada perubahan frekuensi dari sinyal ECG dan *gaze tracking* yang tidak stabil selama induksi berlangsung.

### **2.3 Sinyal Electroencephalograph (EEG)**

Dari beberapa metode pengukuran secara objektif/fisiologis, pengukuran menggunakan EEG merupakan metode yang paling baik untuk menginvestigasi terjadinya *cybersickness*. Hal ini dikarenakan, sinyal EEG sangat sensitive terhadap aktivitas otak manusia sehingga pengukuran menggunakan EEG dinilai sangat efektif dan efisien.[15],[13],[16]

*Electroencephalogram* (EEG) merupakan salah satu pengukuran *electrophysiological* yang berfungsi untuk merekam dan memonitor aktifitas otak manusia. Pengukuran ini bersifat *non-invasive* dengan cara menempatkan elektroda

pada scalp. Pengukuran EEG berdasarkan fluktuasi tegangan hasil dari arus ion dalam neuron otak. Diagnosa yang digunakan biasanya fokus pada spectral EEG, yaitu osilasi saraf yang disebut gelombang otak yang dapat diamati pada sinyal EEG. Gelombang sinyal EEG berdasarkan rentang frekuensi dibagi menjadi 4 gelombang yaitu:

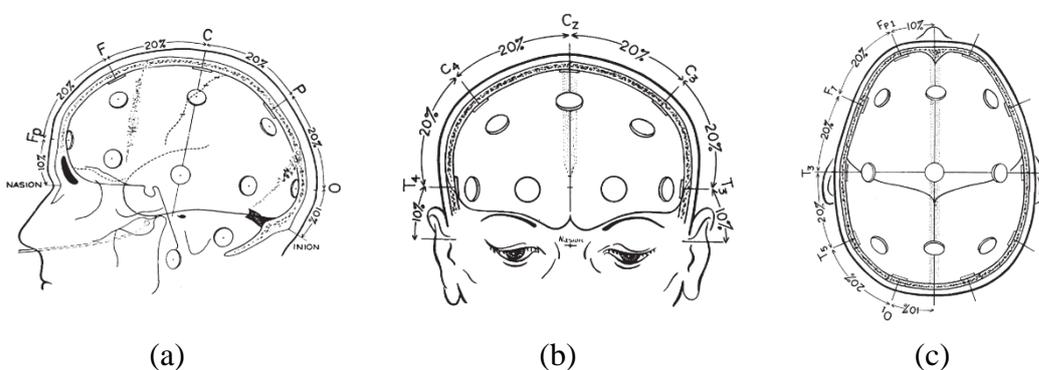
1. Gelombang delta ( $\delta$ ), Gelombang delta memiliki rentang frekuensi 0,5-4 Hz. Gelombang ini muncul saat seseorang dalam kondisi kantuk, tertidur lelap, dan pada bayi. Selain itu juga ditemukan saat seseorang mengerjakan tugas secara berkesinambungan dengan perhatian penuh. Lokasi delta band terletak pada bagian frontal pada orang dewasa dan posterior pada anak-anak.
2. Gelombang theta ( $\theta$ ), Gelombang theta memiliki rentang frekuensi 4-8 Hz. Gelombang ini muncul saat terjadi aktifitas penurunan konsentrasi, kondisi kantuk ringan dan kewaspadaan. Gelombang theta ditemukan pada lokasi yang tidak berhubungan dengan tugas yang dilakukan oleh tangan (task at hand)
3. Gelombang alpha ( $\alpha$ ), Gelombang alpha memiliki rentang frekuensi 8-12 Hz. Gelombang ini muncul saat terjaga. Aktifitas gelombang alpha terlihat saat mata tertutup dan terbuka. Gelombang alpha meningkat saat mata tertutup dan menurun saat mata terbuka. Selain itu, gelombang ini berhubungan dengan aktivitas manusia saat rileksasi tanpa perhatian dan konsentrasi. Gelombang ini biasanya ditemukan pada area posterior dari kepala dan bagian central.
4. Gelombang beta ( $\beta$ ), Gelombang beta memiliki rentang frekuensi 12-30 Hz. Gelombang ini muncul saat seseorang mengalami kewaspadaan. Selain itu, gelombang ini juga mengindikasikan seseorang yang mengalami rasa semangat dengan aktivitas mental prima. Lokasi gelombang beta banyak ditemukan pada bagian frontal.

### **2.3.1 Sistem 10/20 Peletakan Posisi Kanal EEG**

Sistem Internasional 10-20 pada EEG merupakan standar sistem internasional peletakan elektrode-elektrode *scalp* pada manusia berdasarkan usulan Dr. Hebert H. Jasper. Peletakan electrode pada scalp berdasarkan pada standar anatomi tengkorak manusia yaitu nasion, inion, dan preauricular sebelah kanan dan kiri. Pengukuran berdasarkan bidang anterior-posterior dibagi menjadi 5 bagian dan

dilambangkan dengan kode huruf. Bagian 10% pertama dari total pengukuran bidang yaitu fronto polar (Fp), sedangkan bagian selanjutnya memiliki interval sebesar 20%. Secara berurutan bagian kedua hingga kelima adalah *frontal* (F), *central* (C), *parietal* (P) dan *occipital* (O) [17].

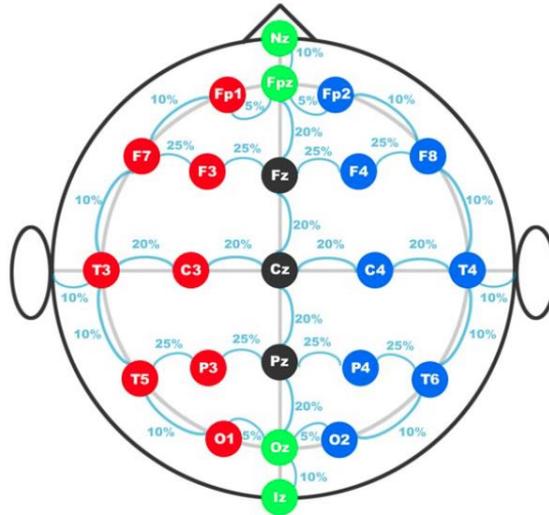
Ilustrasi peletakan electrode berdasarkan bidang anterior-posterior dapat dilihat pada Gambar 2.1a dimana bagian central hanya digunakan sebagai penanda pada system 10-20 karena tidak memiliki referensi khusus yang sesuai dengan standar anatomi tengkorak manusia. Pengukuran kedua berdasarkan bidang *central coronal* mulai dari preauricular kiri hingga kanan. Bagian 10% pertama dari preauricular kiri maupun kanan merupakan bagian *temporal* (T). Bagian kedua yaitu 20% setelah bagian temporal baik dari temporal kanan maupun kiri merupakan bagian *central* (C). Sedangkan bagian *central* yang merupakan pertemuan antara temporal kanan dan kiri diberi kode central z (Cz). Z dapat diartikan sebagai zero. Ilustrasi peletakan electrode berdasarkan bidang coronal dapat dilihat pada Gambar 2.1b. Pengukuran ketiga berdasarkan pada bidang keliling antara bagian tengah fronto polar (Fp) hingga *occipital* (O). Bagian 10% dari tengah Fp merupakan Fp kiri dan kanan. Sedangkan bagian 20% selanjutnya secara berurutan adalah bagian inferior frontal, temporal tengah dan posterior temporal. Bagian 10% sisa adalah bagian occipital kanan dan kiri. Ilustrasi pengukuran pada bidang keliling dapat dilihat pada Gambar 2.1c.



Gambar 2.1 Metode pengukuran untuk menentukan lokasi electrode berdasarkan system 10-20 pengukuran bidang anterior-posterior (a), pengukuran bidang central coronal (b), pengukuran berdasarkan lingkaran tengkorak (c).

Kode angka pada sistem 10-20 digunakan untuk menunjukkan posisi elektroda tersebut. Kode angka ganjil (1,3,5,7) pada elektroda menunjukkan posisi

electroda berada pada preauricular bagian kiri. Sedangkan kode angka genap (2,4,6,8) pada electrode menunjukkan posisi electrode berada pada preauricular bagian kanan. Keseluruhan peletakan electrode berdasarkan system 10-20 dapat dilihat pada Gambar 2.2



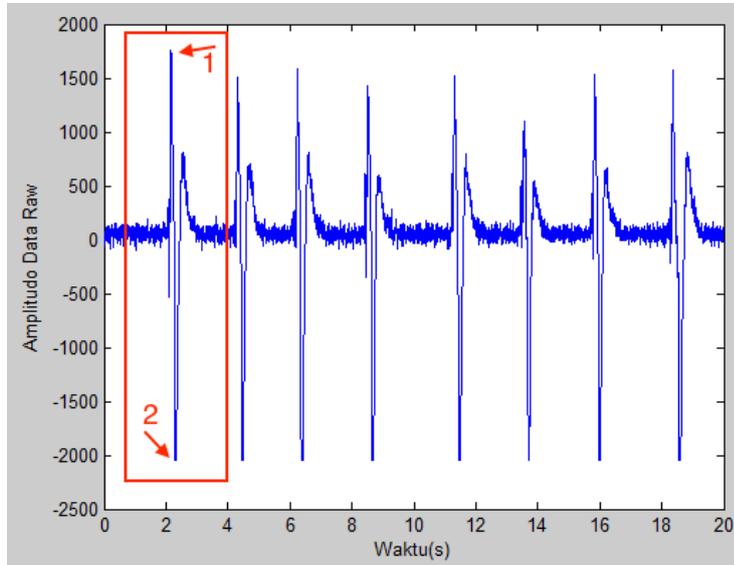
Gambar 2.2 Sistem Peletakan Elektrode 10-20 [18]

### 2.3.2 Artefact Removal pada Sinyal EEG

Penggunaan sinyal EEG sebagai alat ukur objektif/fisiologis memiliki kelemahan yaitu rentan terhadap gangguan atau *noise*. Hal ini dikarenakan sinyal EEG sangat sensitive terhadap aktivitas yang terjadi didalam maupun diluar subjek. Adapun gangguan yang berasal dari dalam diri subjek diantaranya disebabkan oleh aktivitas motorik seperti gerakan anggota tubuh, saat subjek bernapas (*muscular artefact*) atau saat subjek melakukana aktivitas gerakan bola mata atau berkedip. Dengan demikian, selama perekaman berlangsung subjek diminta untuk meminimalisir gerakan tubuh agar tidak banyak menimbulkan noise. Gangguan yang berasal dari luar subjek yaitu gangguan dari sinyal-sinyal lain yang berada disekitar lingkungan subjek seperti terjadi interferensi dengan sinyal elektromagnetik (sinyal WI-FI). Oleh karena itu, setiap alat EEG memiliki ground yang digunakan untuk meminimalisir terjadinya gangguan diluar subjek.

Noise yang paling dominan pada sinyal EEG adalah terganggunya sinyal EEG dengan sinyal EOG. Artefak ini sangat sulit untuk dihindari kemunculannya apalagi jika perekaman dilakukan dalam keadaan mata terbuka. Karakteristik sinyal

EOG yang memiliki amplitudo yang sangat tinggi (spike) sangat mengganggu data raw dari sinyal EEG. Adapun gambaran sinyal EOG yang tercampur pada sinyal EEG dapat dilihat pada Gambar 2.3 ditandai dengan kotak berwarna merah.



Gambar 2.3 Sinyal EOG yang tercampur pada Sinyal EEG

Sinyal EOG merupakan noise utama yang harus dihilangkan pada sinyal EEG. Pada penelitian sebelumnya, telah banyak metode *artefact removal* khususnya pada multikanal untuk memisahkan sinyal EOG dengan sinyal EEG. Salah satunya menggunakan *Independent Component Analysis* (ICA). Metode ICA merupakan metode terbaik pada kasus multi kanal untuk menghilangkan noise [19]. ICA merupakan salah satu metode *Blind Source Separation* (BSS) yang paling populer. Prinsip kerja ICA adalah membagi satu set sinyal yang telah tercampur menjadi 1 set komponen tersendiri, sehingga mengaplikasikan ICA pada data raw EEG maka beberapa komponen dipisahkan sebagai data asli dan komponen data *artefact*.

Sinyal yang tercampur direpresentasikan sebagai  $x = (x_1, \dots, x_m)^T$  dan komponen tersebut (hidden components) berupa vector acak  $s = (s_1, \dots, s_n)^T$ .  $m$  merupakan sinyal ke- $m$  dan  $n$  adalah komponen tersembunyi ke- $n$ . Adapun model persamaan dari ICA dapat dilihat pada Persamaan 2.1.

$$x_i = a_{i,1} + s_1 + \dots + a_{i,k} + s_k + \dots + a_{i,n} + s_n \quad (2.1)$$

$x_i$  merupakan komponen dari data vector acak  $x = (x_1, \dots, x_m)^T$  dengan menambah komponen independent  $s_k$  dengan  $k=1, \dots, n$  dan  $a_{i,k}$  merupakan konstan parameter atau matriks campuran. Dari model generative ICA pada persamaan 2.1 dapat ditulis kembali menggunakan bentuk vektorial yang ditunjukkan pada Persamaan dengan  $x$  merupakan sinyal yang dicari.[20]

$$x = \sum_{k=1}^n a_k s_k \quad (2.2)$$

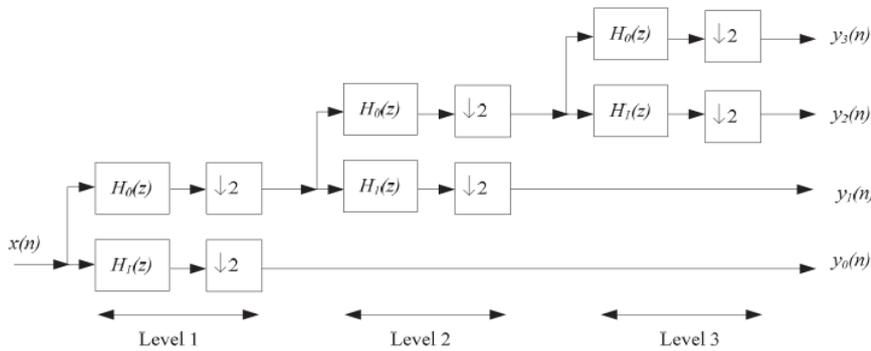
Tujuan dari ICA adalah untuk mencari sinyal asli dengan cara mengembalikan mixing matrik dengan cari mencari bobot  $w$  dari matriks. Adapun untuk mencari bobot  $w$  dalam ICA ada beberapa macam metode yaitu FastIca, binica dan Infomax. Pada penelitian ini, pencarian bobot  $w$  menggunakan algoritma Infomax yang berdasarkan mutual informasi.

### 2.3.3 Dekomposisi Sinyal Menggunakan *Discrete Wavelet Transform* (DWT)

Proses *artefact removal* merupakan tahap awal dari pengolahan sinyal EEG. Setelah itu, sinyal EEG dipecah menjadi beberapa band frekuensi menjadi sinyal dengan frekuensi delta ( $\delta$ ), theta ( $\theta$ ), alfa ( $\alpha$ ), beta ( $\beta$ ) dan gamma ( $\gamma$ ). Metode ekstraksi sinyal EEG menjadi sub band frekuensi dapat melalui proses filterisasi atau dekomposisi level. Metode filterisasi dapat menggunakan Filter IIR *Band Pass Filter* (BPF) *Butterworth* atau *Chebisev* sebagai jendela konvolusi yang digunakan. Selain itu, dapat menggunakan metode dekomposisi level melalui penerapan *Discrete Wavelet Transform* (DWT).

DWT merupakan bagian dari transformasi wavelet yang menggambarkan sebuah sinyal berdasarkan frekuensi-waktu. Teknik ini sangat cocok diterapkan pada sinyal EEG yang memiliki sifat sinyal bergerak (*non-stasioner*) [21]. Sinyal yang bersifat *non-stasioner* memiliki karakteristik mengalami perubahan frekuensi pada satuan waktu. Sinyal bergerak dianalisa menggunakan teknik *multi-resolution analysis*. Pada, DWT teknik *multi resolution analysis* dilakukan dengan cara melewatkan sinyal yang akan dianalisa kedalam dua filterisasi DWT yaitu *highpass filter* (menganalisa frekuensi tinggi) dan *lowpass filter* (menganalisa frekuensi rendah). Analisis frekuensi yang berbeda menggunakan resolusi yang berbeda [22].

Pembagian sinyal berdasarkan frekuensi tinggi dan frekuensi rendah pada DWT disebut sebagai dekomposisi. Proses dekomposisi sinyal dapat dilihat pada Gambar 2.4.



Gambar 2.4 Proses Dekomposisi Sinyal

Dekomposisi sinyal *non-stasioner* membagi sinyal menjadi approximation ( $H_0(z)$ ) dan detail ( $H_1(z)$ ). Setiap kenaikan level pada proses dekomposisi sinyal maka terjadi penurunan sub sample menjadi 2 yang berdasarkan aturan Nyquist. Sehingga jika sinyal asal memiliki rentang frekuensi 0 sampai  $\pi$  rad/s sehingga setelah melewati highpass dan lowpass filter, rentang frekuensi di subsample menjadi  $\pi/2$  rad/s pada frekuensi tertinggi. Proses dekomposisi ini dapat melalui satu atau lebih tingkatan sesuai dengan frekuensi yang dibutuhkan, seperti yang terlihat pada Gambar 2.4 yang membagi sinyal hingga level ke-3.

Setelah melakukan dekomposisi sinyal, langkah selanjutnya pada teknik wavelet adalah pemilihan kernel terbaik, Ada beberapa macam tipe kernel yang terdapat pada teknik ini diantaranya: *haar*, *morlet (mother wavelet)*, *symlet*, *daubechies*, *coiflets*, dimana setiap kernel memiliki karakteristik-karakteristik tersendiri [23].

### 2.3.4 Ekstraksi Fitur

Eksraksi fitur merupakan bagian yang paling penting pada sebuah penelitian, khususnya untuk menginvestigasi terjadinya *cybersickness*. Hal ini dikarenakan, pemilihan fitur yang akan menentukan pemodelan pola dari distribusi data, dimana pemodelan ini nantinya berpengaruh pada algoritma klasifikasi yang digunakan. Ekstraksi fitur yang digunakan pada penelitian ini adalah fitur *Power*

Percentage (PP), yang telah digunakan sebelumnya oleh [24] pada sinyal EEG satu kanal. Adapun persamaan dari fitur PP adalah sebagai berikut:

$$PP_{\alpha} = \frac{\sum_{f_{\alpha}} S(f)}{\sum_{f=f_1}^{f_2} S(f)}, f_{\alpha} \in [8,12] \quad (2.3)$$

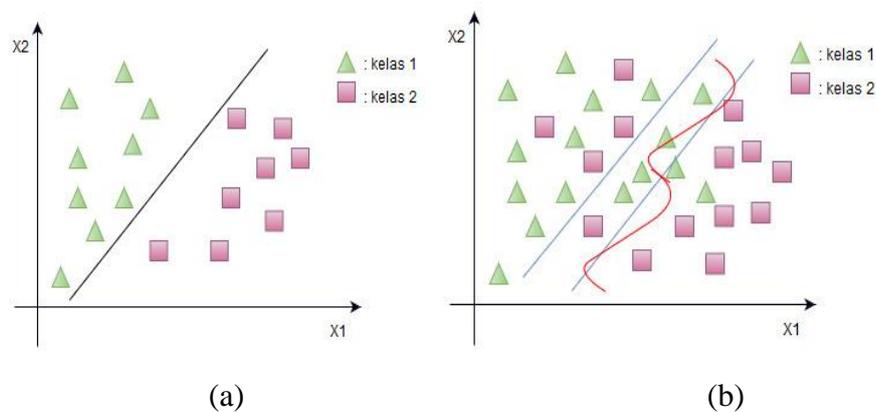
dimana  $S(f)$  merupakan nilai PSD yang didapatkan dengan menggunakan metode Welch pada frekuensi sinyal EEG pada domain waktu  $x(t)$ . Frekuensi sinyal sesuai dengan band frekuensi yang akan dicari. Pada penelitian ini band frekuensi yang digunakan adalah theta, alpha dan beta, yang didenotasikan sebagai  $PP_{\theta}$ ,  $PP_{\alpha}$  dan  $PP_{\beta}$ .

## 2.4 Klasifikasi

Ada 3 algoritma klasifikasi yang digunakan pada penelitian ini diantaranya:

### 2.4.1 Support Vector Machine (SVM)

Support Vector Machine (SVM) merupakan algoritma klasifikasi *supervised* yang dikembangkan oleh Vladimir Vapnik dan Corinna Cortes. Prinsip utama dari algoritma pembelajaran SVM adalah membangun bidang pemisah (*hyperplane*) terbaik dengan cara meminimalisir terjadinya rata-rata error. Konsep utama dari SVM adalah membagi *hyperplane* menjadi dua kelas yang dapat diaplikasikan pada klasifikasi linear dan nonlinear. Sedangkan pada klasifikasi linear, SVM dibedakan menjadi dua kasus yaitu *linearly separable* dan *linearly non-separable* sesuai dengan sebaran data yang digunakan, seperti yang dapat dilihat pada Gambar 2.5.



Gambar 2.5 (a) Fungsi klasifikasi *linear* pada kasus *linearly separable* dan (b) Fungsi klasifikasi *non-linear* pada kasus *linearly non-separable*

### 2.4.1.1 SVM pada kasus Linearly Separable

*Linearly separable* merupakan kasus klasifikasi pada data yang dapat dipisahkan secara linear sesuai dengan fungsi classifier linier  $f$  yang diberikan pada persamaan:

$$\mathcal{F} = \{x^T w + b, w \in R^p, b \in R\} \quad (2.4)$$

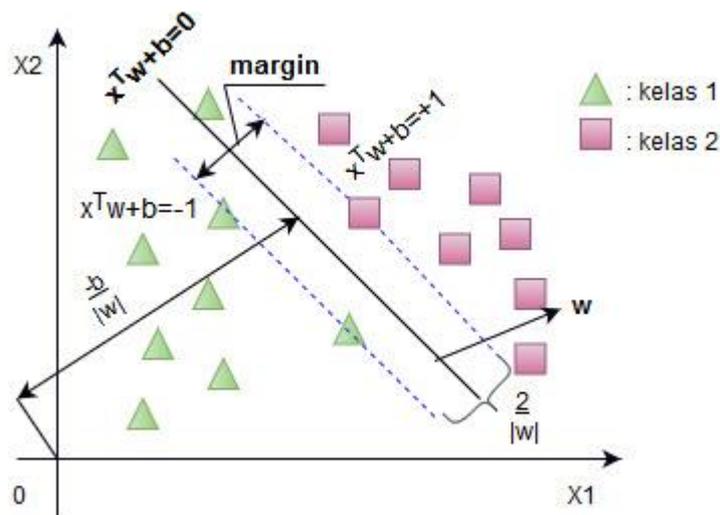
Pertama yang dilakukan adalah memilih  $f \in \mathcal{F}$  untuk menentukan *support vector* yang disebut dengan memasimalkan margin. Pada Gambar 2.6 menunjukkan proses klasifikasi dua kelas pada SVM dimana  $d_+$  dan  $d_-$  adalah margin. Tanda silang dan lingkaran yang di bold adalah support vector.  $x^T w + b = 0$  adalah *hyperplane* pemisah. Kemudian  $d_+(d_-)$  akan menjadi jarak paling dekat dengan objek terdekat dari kelas  $+1$  ( $-1$ ). Karena pemisahan dapat diselesaikan tanpa error, semua observasi  $i = 1, 2, \dots, n$  harus memenuhi:

$$x^T w + b \geq +1 \text{ untuk } y_i = +1$$

$$x^T w + b \geq -1 \text{ untuk } y_i = -1$$

Kedua persamaan/konstrain tersebut dapat dikombinasikan menjadi satu menjadi persamaan berikut:

$$y_i(x^T w + b) - 1 \geq 0, i = 1, 2, \dots, n \quad (2.5)$$



Gambar 2.6 *Hyperplane* pemisah  $x^T w + b = 0$  dan margin di dalam kasus *linearly separable*

Bidang pemisah kanonik (*canonical hyperplanes*)  $x^T w + b = \pm 1$  adalah sejajar dan jarak antara masing-masing konstrain dan *hyperplane* pemisah adalah  $d_+ = d_- = \frac{1}{\|w\|}$ , dimana  $w$  adalah bobot dari vector-vector yang dihasilkan (*weight vector*),  $b$  adalah posisi bidang relatif terhadap pusat koordinat atau bias yang bernilai scalar. Sehingga didapatkan nilai maksimum margin antar bidang pembatas adalah

$$\frac{1-b-(-1-b)}{\|w\|} = \frac{2}{\|w\|} \quad (2.6)$$

Pada persamaan (2.6) harus memenuhi kriteria memaksimalkan  $\frac{1}{\|w\|}$  sama dengan meminimumkan  $\|w\|^2$  karena hal ini dapat memaksimalkan sebaran data. Secara umum, persoalan ini lebih mudah diselesaikan ke dalam persamaan *Langrangian*. Persamaan langrangian primal problem nantinya akan disubstitusikan kedalam hasil KKT (Karush-Kuhn-Tucker) didapatkan Langrangian untuk dual problem ( $L_D$ ) dengan konstrain berbeda. Adapun persamaan primal problem dan dual problem dapat dilihat pada persamaan:

$$L_p(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^n \alpha_i [y_i (x_i^T w + b) - 1]$$

$$L_D(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j x_i x_j$$

Titik-titik  $i$  pada persamaan  $y_i (x_i^T w + b) = 1$  disebut *support vector*. Setelah proses training SVM yaitu menyelesaikan dual problem di atas dan memperoleh *lagrange multiplier* (sama dengan 0 untuk non-*Support vectors*) dapat diklasifikasikan sebagai sebuah kelompok dengan menggunakan aturan klasifikasi dengan persamaan berikut:

$$g(x) = \text{sign}(x^T w + b) \quad (2.15)$$

dimana  $w = \sum_{i=1}^n \alpha_i y_i x_i$  dan  $b = \frac{1}{2} (x_{+1} + x_{-1}) w$ .  $x_{+1}$  dan  $x_{-1}$  adalah dua *support vector* yang termasuk ke dalam kelas yang berbeda untuk  $y(x^T w + b) = 1$ . Nilai dari fungsi klasifikasi dapat dihitung dengan persamaan berikut.

$$f(x) = x^T w + b \quad (2.16)$$

Masing-masing skor  $f(x)$  berhubungan secara unik terhadap sebuah *default probability* (PD). Semakin tinggi nilai  $f(x)$  maka semakin tinggi pula PD.

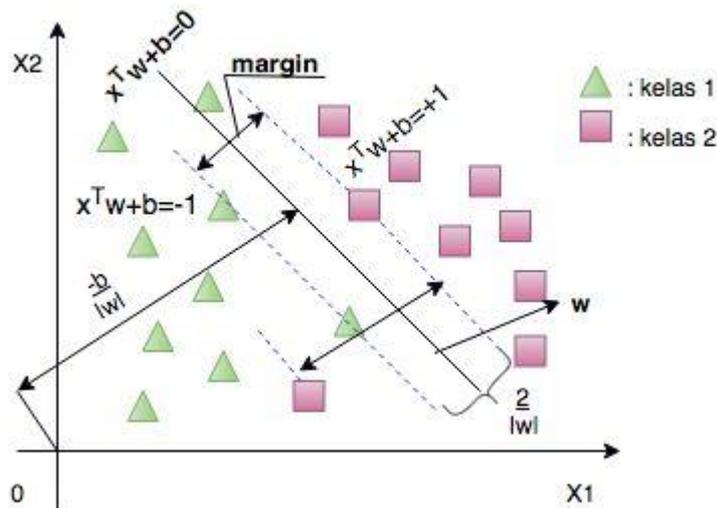
#### 2.4.1.2 SVM pada Kasus Linearly Non-separable

*Linearly Non-separable* adalah kasus klasifikasi SVM pada data yang tidak bisa dipisahkan secara linier seperti yang ditunjukkan pada Gambar 2.7. Untuk itu formula SVM harus dimodifikasi karena tidak akan ada solusi yang ditemukan. Pada kasus ini fungsi atau persamaan pada bidang pemisah (*hyperplane*) terbaik dilakukan dengan penambahan variabel *slack* ( $\xi_i$ ) yang sering juga disebut dengan *soft margin hyperplane*, sehingga didapatkan fungsi SVM sebagai berikut:

$$\begin{aligned} x_i^T w + b &\geq 1 - \xi_i \text{ untuk } y_i = +1, \\ x_i^T w + b &\geq -1 + \xi_i \text{ untuk } y_i = -1, \\ \xi_i &\geq 0. \end{aligned}$$

Fungsi tersebut dikombinasikan menjadi dua konstrain:

$$\begin{aligned} y_i(x_i^T w + b) &\geq 1 - \xi_i \\ \xi_i &\geq 0. \end{aligned} \quad (2.17)$$



Gambar 2.7. Bidang pemisah  $x^T w + b = 0$  dan margin di dalam kasus *linearly non-separable*

Pinalti untuk kesalahan klasifikasi, error klasifikasi  $\xi_i \geq 0$ , dihubungkan dengan jarak dari titik kesalahan klasifikasi  $x_i$  terhadap *cononical hyperplane* yang

membatasi kelasnya. Sehingga fungsi objektif yang sesuai terhadap maksimalisasi margin yang dipinalti diformulasikan menjadi persamaan berikut:

$$\frac{1}{2} \|w\|^2 + C \sum_{i=1}^n \xi_i \quad (2.18)$$

dimana  $C$  = parameter yang menentukan besar pinalti akibat kesalahan data klasifikasi dan nilainya ditentukan oleh pengguna. Meminimalkan fungsi objektif 2.18 dengan konstrain 2.17 memberikan kemungkinan margin terbesar dalam bidang pemisah. Selanjutnya, fungsi Lagrange untuk *primal problem* adalah:

$$L_P(w, b, \alpha, \mu, \xi) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n \xi_i - \sum_{i=1}^n \alpha_i \{y_i(x_i^T w + b) - 1 + \xi_i\} - \sum_{i=1}^n \mu_i \xi_i \quad (2.19)$$

dimana  $\alpha_i \geq 0$  dan  $\mu_i \geq 0$  adalah pengali *lagrange*. *Primal problem* dirumuskan sebagai berikut:

$$\min_{w, b, \xi} L_P(w, b, \xi)$$

Kondisi orde pertama pada kasus ini adalah:

$$\begin{aligned} \frac{\partial L_P}{\partial w} = 0 &: w - \sum_{i=1}^n \alpha_i y_i x_i = 0 \\ \frac{\partial L_P}{\partial b} = 0 &: \sum_{i=1}^n \alpha_i y_i = 0 \\ \frac{\partial L_P}{\partial \xi_i} = 0 &: C - \alpha_i - \mu_i = 0 \end{aligned}$$

Dengan kondisi untuk pengali *lagrange*:

$$\begin{aligned} \alpha_i &\geq 0 \text{ dan } \mu_i \geq 0 \\ \alpha_i \{y_i(x_i^T w + b) - 1 + \xi_i\} &= 0 \\ \mu_i \xi_i &= 0 \end{aligned}$$

Perhatikan bahwa  $\sum_{i=1}^n \alpha_i y_i b = 0$  oleh karena itu mirip dengan kasus *linearly separable*, *primal problem* dirumuskan menjadi:

$$L_D(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j x_i^T x_j, \quad (2.20)$$

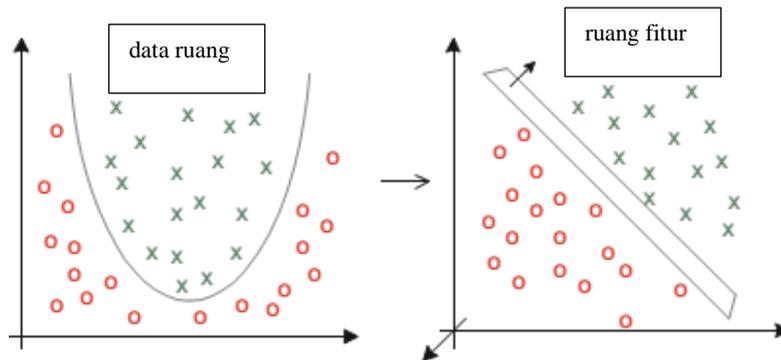
Dan *dual problem* sebagai berikut:

$$\max_{\alpha} L_D(\alpha) \quad \text{s.t.} \quad 0 \leq \alpha_i \leq C, \quad \sum_{i=1}^n \alpha_i y_i = 0$$

*Instance* yang memiliki nilai  $\alpha_i = C$  disebut *bounded support vector*.

### 2.4.1.3 Klasifikasi Non-linear SVM

SVM juga dapat digeneralisasi ke dalam kasus non-linier, yaitu dengan mentransformasikan *data space* ke dalam *feature space* sehingga dapat dipisahkan secara linier pada *feature space* melalui sebuah fungsi  $\psi: \mathbb{R}^p \mapsto \mathbb{H}$  menjadi ruang dimensi yang sangat besar,  $\mathbb{H}$ , dimana aturan klasifikasi adalah (hampir) linier. Ilustrasi dari kasus ini ditunjukkan pada Gambar 2.8 berikut:



Gambar 2.8. Transformasi dari *data space* dua-dimensi menjadi *feature space* tiga dimensi  $\mathbb{R}^2 \mapsto \mathbb{R}^3$  (diambil dari [25])

Fungsi transformasi pada SVM adalah menggunakan “*Kernel Trick*”. *Kernel trick* adalah menghitung *scalar product* melalui sebuah fungsi kernel  $K(x_i y_i) = \psi(x_i)^T \psi(x_j)$ , kemudian kernel trick tersebut dapat digunakan tanpa mengetahui transformasi  $\psi$  secara eksplisit [25]. Syarat sebuah fungsi untuk menjadi fungsi kernel adalah memenuhi *teorema mercer* yang menyatakan bahwa matriks kernel yang dihasilkan harus bersifat *positive definiteness*, sehingga untuk beberapa dataset  $x_1, \dots, x_n$  dan beberapa bilangan real  $\lambda_1, \dots, \lambda_n$ , fungsi K harus memenuhi.

$$\sum_{i=1}^n \sum_{j=1}^n \lambda_i \lambda_j K(x_i x_j) \geq 0 \quad (2.21)$$

Beberapa fungsi kernel yang umum digunakan, diantaranya:

- Kernel linier

$$K(x_i x_j) = x_i^T x_j \quad (2.22)$$

- Kernel Polinomial

$$K(x_i x_j) = (\delta x_i^T x_j + r)^p, \delta > 0 \quad (2.23)$$

- Kernel *Radial basis Function* (RBF)

$$K(x_i x_j) = \exp(-\gamma \|x_i - x_j\|^2), \gamma > 0 \quad (2.24)$$

- Kernel sigmoid

$$K(x_i x_j) = \tanh(\delta x_i^T x_j + r) \quad (2.25)$$

Fungsi kernel yang direkomendasikan untuk pertama kali dicoba menurut Hsu et al [26] adalah fungsi kernel RBF karena memiliki performansi yang sama dengan kernel linier pada parameter tertentu ( $C, \gamma$ ) dan lebih *robust* terhadap *outlier* karena range fungsi kernel RBF antara  $(-\infty, \infty)$  sedangkan fungsi kernel lain memiliki rentang  $(-1, 1)$  atau  $(0, 1)$ .

#### 2.4.2 Linier Discriminant Analysis (LDA)

LDA pertama kali dikembangkan oleh R.A Fisher pada tahun 1936. Konsep awal dari klasifikasi LDA adalah mencari kombinasi linier variable (ciri) yang dapat dipisahkan kedalam dua kelas dengan baik. Pada fungsi pemisahan dua kelas yang dilakukan oleh Fisher adalah mencari nilai rasio dari nilai variance antar kelas dengan nilai rasio dari dalam kelas itu sendiri. LDA dapat memisahkan dua kelas dengan baik jika meemenuhi dua kriteria yaitu:

1. Memaksimalkan jarak antara dua data berdasarkan rata-rata (mean) data
2. Meminimalkan jarak dari variasi antar data pada masing-masing kelas, dalam

LDA variasi data disebut dengan “scatter” atau diagram sebar

Nilai separasi maksimal didapatkan pada Persamaan

$$Sep = \frac{\sigma^2_{between}}{\sigma^2_{within}} = \frac{\gamma(\mu_2 - \mu_1)^2}{\gamma^T(Cov_1 + Cov_2)\gamma} \quad (2.26)$$

Jika kelas yang akan diklasifikasika lebih dari du akelas, maka LDA perlu mencari bidang lain yang dapat ditemukan dengan menggunakan nilai variability pada kelas pada Persamaan dengan  $Class$  adalah jumlah kelas.

$$Cov_{between} = \frac{1}{class} \sum_{i=1}^{class} (\mu_i - \mu)(\mu_i - \mu)^T \quad (2.27)$$

### 2.4.3 K-Nearest Neighbour (KNN)

K-Nearest Neighbour (K-NN) merupakan salah satu tipe pembelajaran supervised yang paling mudah dan sederhana jika dibandingkan dengan algoritma pembelajaran yang lain. Prinsip kerja dari K-NN adalah menentukan atribut kelas dari atribut data uji (test data) sesuai dengan atribut yang dimiliki oleh data latih (training data) yang telah diklasifikasikan berdasarkan jarak terdekat atau tetangga terdekat (*nearest neighbor*). Untuk mencari jarak terdekat menggunakan rumus jarak (distance function) diantaranya Euclidean distance, Manhattan, Mahalanobis, Minkowski, Hamming dan Chebisev. Namun, rumus jarak Euclidean distance merupakan rumus yang paling sering digunakan oleh para peneliti. Hal ini dikarenakan menurut penelitian medis yang dilakukan Hu et al, penggunaan Euclidean distance memiliki performansi yang lebih bagus dalam mengklasifikasikan dataset. Adapun rumus dari Euclidean distance sebagai berikut:

$$d(x_i, x_j) = \sqrt{\sum_{r=1}^n (a_r(x_i) - a_r(x_j))^2} \quad (2.28)$$

Dimisalkan sebuah instance data  $x$  dideskripsikan oleh vector fitur  $(\alpha_1(x), \alpha_2(x), \dots, \alpha_n(x))$ , dimana  $\alpha_r(x)$  melambangkan nilai atribut ke- $r$  dari instance  $x$ . Kemudian jarak antara dua instance  $x_i$  dan  $x_j$  didefinisikan menjadi  $d(x_i, x_j)$ . Setelah jarak *Euclidean distance* dihasilkan, kemudian masing-masing dari data uji di rangking dari jarak terdekat ke jarak terjauh terhadap data latih dengan persamaan:

$$\hat{f}(x_q) \leftarrow \operatorname{argmax}_{v \in V} \sum_{i=1}^k \delta(v, f(x_i)), \quad (2.28)$$

dimana  $\delta(a, b) = 1$  jika  $a = b$  dan  $\delta(a, b) = 0$  lainnya. Kemudian gunakan nilai  $k$ -parameter. Jika kita memilih  $k=1$ , maka algoritma 1-NN akan menetapkan menetapkan  $\hat{f}(x_q)$  ke nilai  $f(x_i)$  dimana  $x_i$  adalah data latih yang paling dekat dengan  $x_q$ .

## 2.5 Metode *Correlation based Feature Selection* (CFS)

Sebuah *machine learning* menghasilkan sebuah *tools* yang didapatkan dari besarnya kuantitas sebuah data yang dapat dianalisa secara otomatis. Dasar dari sebuah *machine learning* adalah seleksi fitur. Seleksi fitur digunakan untuk mengidentifikasi fitur yang paling dominan dan yang memiliki pengaruh tinggi sehingga mempermudah sebuah data untuk dianalisa dan diprediksi melalui algoritma pembelajaran yang digunakan. Salah satu metode seleksi fitur yang paling banyak digunakan oleh para peneliti adalah Metode *Correlation Feature Selection* (CFS).

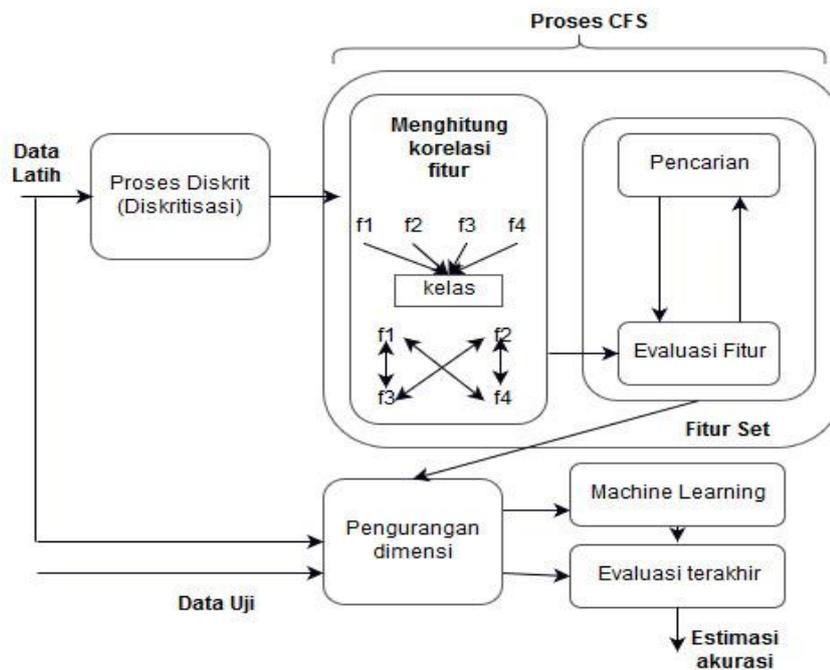
CFS adalah sebuah algoritma seleksi fitur yang paling sederhana yang mengurutkan subset fitur melalui korelasi yang dihasilkan oleh evaluasi fungsi *heuristic*. Prinsip kerja dari sebuah fungsi evaluasi tersebut adalah memilih fitur-fitur yang memiliki korelasi tinggi terhadap kelas, namun satu fitur dengan fitur lainnya tidak berkorelasi. Fitur yang tidak relevan atau redundan akan dihilangkan karena fitur tersebut memiliki korelasi rendah terhadap kelas. Adapaun fungsi evaluasi sebuah subset fitur pada CFS didapatkan dengan menggunakan persamaan:

$$M_s = \frac{k\overline{r_{cf}}}{\sqrt{k+k(k-1)\overline{r_{ff}}}} \quad (2.29)$$

dimana,  $M_s$  adalah heuristic “merit” dari subset fitur  $S$  yang terdiri dari  $k$  fitur,  $\overline{r_{cf}}$  adalah mean dari korelasi antara fitur dan kelas ( $f \in S$ ), dan  $\overline{r_{ff}}$  adalah nilai rata-rata dari inter-korelasi fitur-fitur. Numerator pada persamaan 2.29 dapat memberikan sebuah indikasi bagaimana prediksi kelas terhadap set dari beberapa fitur. Sedangkan denominator menunjukkan besarnya redundan diantara fitur-fitur yang digunakan.

Terdapat 3 tipe heuristic yang digunakan pada CFS yaitu *forward selection*, *backward elimination* dan *best first*. Prinsip kerja dari *Forward selection* adalah diawali dengan tidak ada fitur dan secara cepat menambah satu fitur pada suatu waktu hingga tidak ada fitur lain yang tidak mungkin ditambahkan sehingga menghasilkan evaluasi terbaik. *Backward elimination* diawali dengan subset fitur secara utuh dan secara cepat fitur-fitur tersebut akan dihapus satu persatu sepanjang

sebuah evaluasi tidak mengalami penurunan. Sedangkan, *best first* dapat dimulai dengan keduanya tidak ada fitur atau semua fitur. Prinsip kerja tipe ini merupakan gabungan dari *forward selection* and *backward elimination*. Untuk mencegah pencarian *best first* dalam mengeksplorasi pencarian subset fitur terbaik, maka kriteria pemberhentian pencarian subset fitur terbaik akan digunakan. Pencarian akan berakhir jika terdapat 5 subset yang diperluas berturut-turut tidak menunjukkan sebuah kenaikan daripada subset fitur yang ada saat ini.



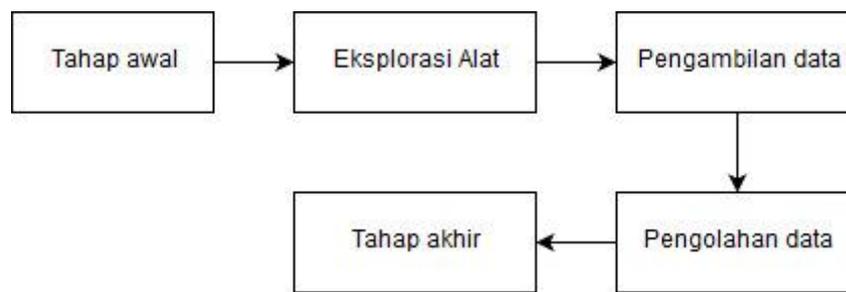
Gambar 2.9 Skema pada *Correlation Based Feature Selection* (CFS)

Pada Gambar 2.9 menunjukkan tahapan-tahapan pada algoritma CFS dan bagaimana metode ini berkolaborasi pada skema mesin pembelajaran. Data latih yang telah disalin akan didiskritkan menggunakan metode Fayyad dan Irani pada tahap persiapan. Kemudian data yang berbentuk diskrit kemudian masuk kedalam CFS. CFS menghitung fitur-kelas dan fitur-fitur yang saling berkorelasi menggunakan suatu pengukuran untuk mencari subset fitur. Subset dengan nilai “merit” tertinggi digunakan untuk mengurangi dimensi dari kedua data latih dan data training yang asli. Data set dan latih yang telah mengalami pengurangan dataset kemudian akan dilewatkan kedalam skema mesin pembelajaran untuk dilatih dan dites untuk diketahui akurasi dan prediksinya.

## BAB 3

### METODOLOGI PENELITIAN

Bab ini membahas mengenai gambaran umum metodologi penelitian yang digunakan. Prosedur penelitian digunakan untuk mencapai tujuan penelitian yang diinginkan, yakni mengenai investigasi *cybersickness* pada manusia melalui Electroencephalograph (EEG) menggunakan stimulus video *game*. Berikut langkah-langkah metodologi yang dilakukan dalam penelitian ini.



Gambar 3.1. Prosedur Metodologi Penelitian

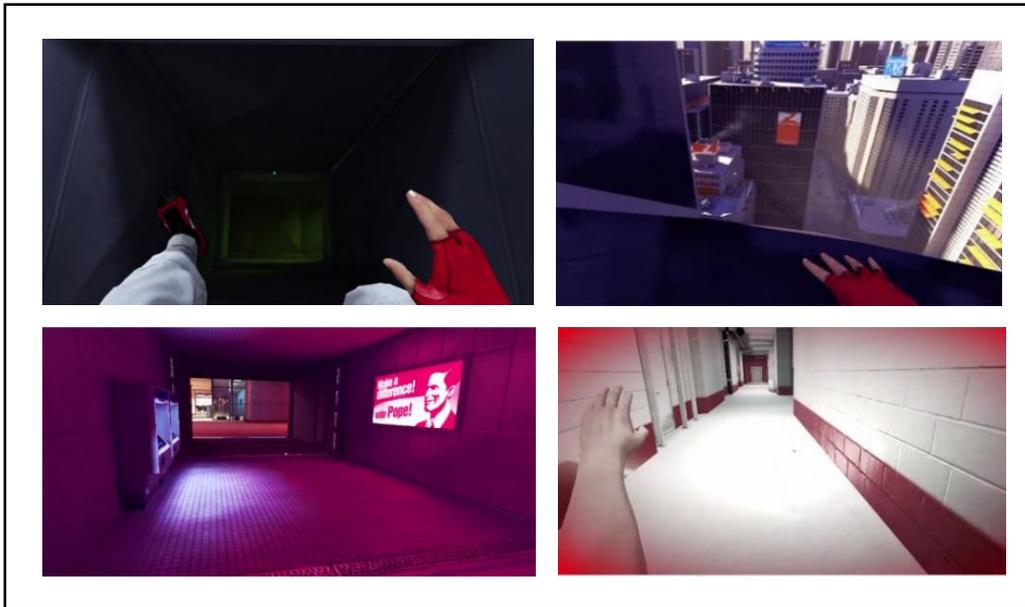
#### 3.1 Tahap awal

Tahap awal merupakan tahap persiapan sebelum melakukan penelitian inti. Perencanaan penelitian yang matang merupakan langkah awal suksesnya sebuah penelitian. Adapun tahap awal terdiri dari :

##### 3.1.1 Validasi *game*

Validasi *game* merupakan aspek penting pada penelitian ini, hal ini dikarenakan video *game* digunakan sebagai stimulus/induksi sehingga *game* yang terpilih harus benar-benar membuktikan bahwa *game* tersebut bisa menimbulkan terjadinya gejala *cybersickness* pada setiap partisipan yang mengikuti eksperimen ini. Validasi *game* pada penelitian ini dilakukan dengan cara meminta rekomendasi dari komunitas *game* Surabaya (GADAS), sehingga dihasilkan bahwa *game* “Mirror Edge” DICE yang diproduksi oleh EA *Game* sangat baik jika digunakan sebagai induksi pada kasus *cybersickness*. Selain itu, *Game* tersebut juga pernah digunakan oleh Guo et al [6] untuk mengukur tingkat *cybersickness* pada 30 orang partisipan menggunakan pengukuran secara subjektif SSQ. *Game* “Mirror Edge”

merupakan *game* first person player yang bercerita tentang adventure dengan latar belakang gedung-gedung yang sangat tinggi. *Keyboard* dan *mouse* digunakan untuk mengontrol dan menggerakkan avatar. Adapun contoh tampilan pada *game* “Mirror Edge” dapat dilihat pada Gambar 3.2.



Gambar 3.2 Sample Tampilan *Game* “Mirror Edge”

### 3.1.2 Pemilihan Partisipan

Terdapat 9 partisipan yang berpartisipasi pada penelitian ini (7 laki-laki dan 2 perempuan,  $M = 25.11$ ) yang berasal dari Suku Jawa dan Suku Minang. Seluruh partisipan memiliki penglihatan yang normal dan pengguna tangan kanan. Menurut hasil kuesioner secara personal, semua partisipan tidak memiliki riwayat penyakit kronis dan ketergantungan terhadap obat-obatan. Sebelum dilakukan pengambilan data, partisipan diminta untuk tidak mengonsumsi kafein, wajib sarapan dan tidur secukupnya pada sehari sebelum proses pengambilan (min. 6 jam).

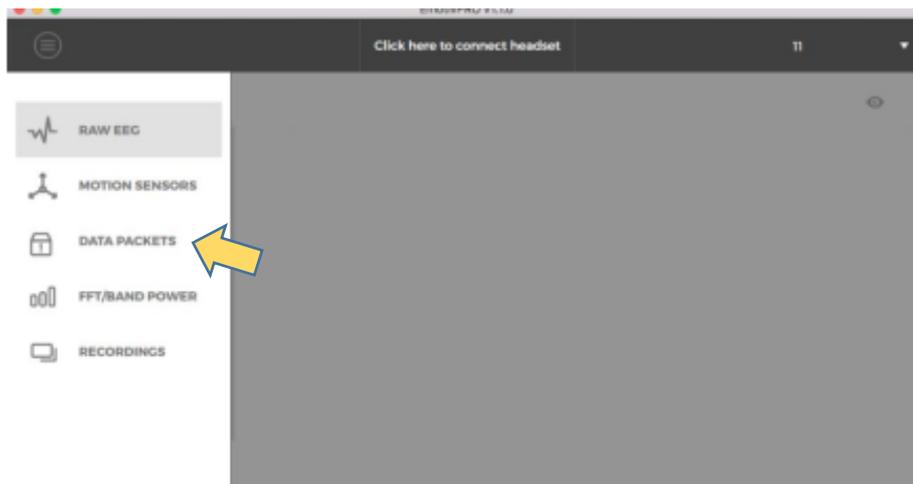
Sebelum melakukan eksperimen, partisipan diberikan penjelasan secara verbal terkait prosedur yang akan dilalui dan dijelaskan mengenai efek yang akan timbul saat stimulus *cybersickness* berlangsung. Partisipan boleh mengakhiri tahap induksi *cybersickness* jika ditengah perjalanan mengalami gejala *cybersickness* yang sangat tinggi.

Pengambilan data partisipan dilakukan sebanyak 2 kali yaitu pada kondisi *active game* dimana partisipan bermain *game* secara langsung dan kondisi *pasif watching* dimana partisipan melihat video dari permainan *game* “Mirror Edge”. Metode pengambilan data yang berbeda untuk membuktikan adanya teori *sensory conflict*. Teori ini menjelaskan bahwa *cybersickness* terjadi ketika ada konflik antara sensor vestibular dan visual atau ketika terdapat konflik antara realita dan ekspektasi. Salah satu contoh dari teori ini adalah pada kasus sopir bus, dimana “sopir” bus mengalami *motion sickness* lebih rendah daripada “penumpang”. Pada penelitian ini, *active game* diilustrasikan sebagai sopir dan *passive watching* diilustrasikan sebagai penumpang.

### **3.2 Eksplorasi Alat**

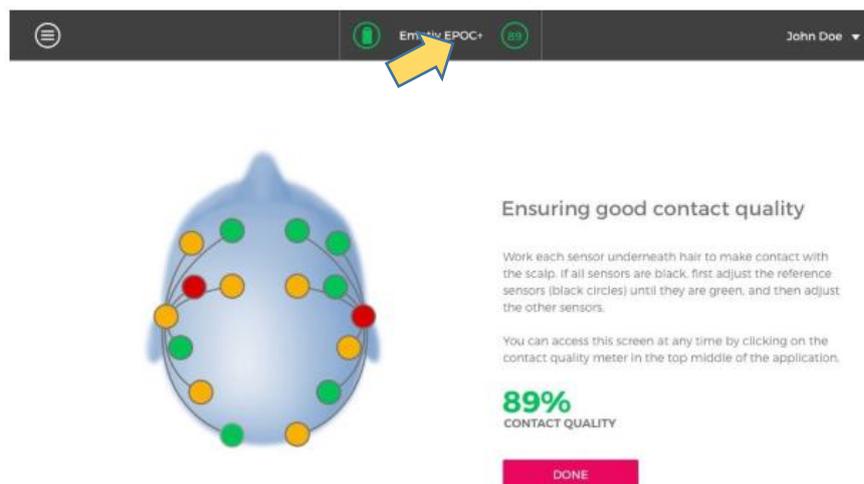
Pada penelitian ini sinyal EEG direkam menggunakan alat wireless Emotiv EPOCH 14 kanal. Adapun detail kanal terdiri dari AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4 dan 2 referensi CMS/DRL yang terletak di lokasi P3 dan P4. Peletakan 14 kanal berdasarkan standart peletakan electrode 10-20. Frekuensi sampling yang digunakan pada saat merekam sinyal EEG adalah 256 Hz. Perekaman EmotivPro menggunakan elektrode basah sehingga digunakan cairan kontak lensa (BioOne) untuk menjaga agar electrode tetap lembab. Kelembapan elektroda sangat mempengaruhi proses perekaman sinyal EEG. Adapun langkah-langkah dalam menggunakan Emotiv-EPOCH adalah sebagai berikut :

1. Membuat akun pada web resmi Emotiv EPOCH
2. Install aplikasi EmotivPro pada laptop yang akan digunakan di alamat seperti pada nomer 1, kemudian akun akan mendapatkan nomor lisensi resmi dari emotive. Setelah itu, cek koneksi antara Laptop dan Hardware yang digunakan.
3. Cek koneksi internet, paket data harus dalam keadaan lancar. bisa dilihat pada menu ‘data paket’



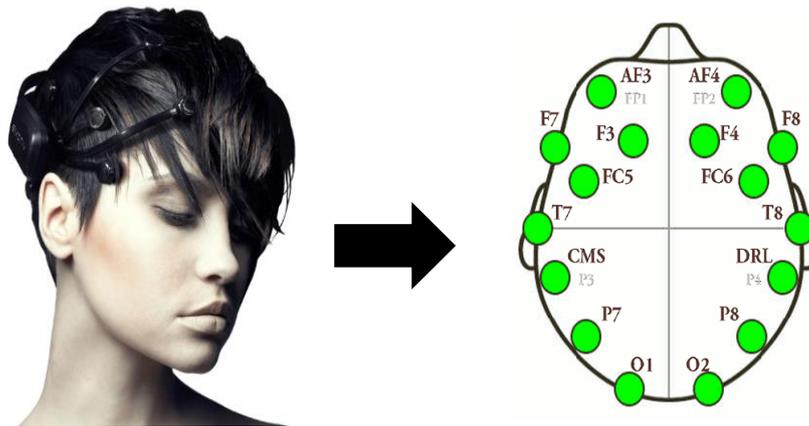
Gambar 3.3. Cek koneksi Internet pada *Software*

4. Cek baterai pada *headset emotive* sebelum digunakan, jika indikator baterai berwarna hijau maka headset emotive siap digunakan. Jika berwarna kuning atau merah ada baiknya untuk diisi dulu baterainya agar tidak mengganggu proses perekaman sinyal EEG



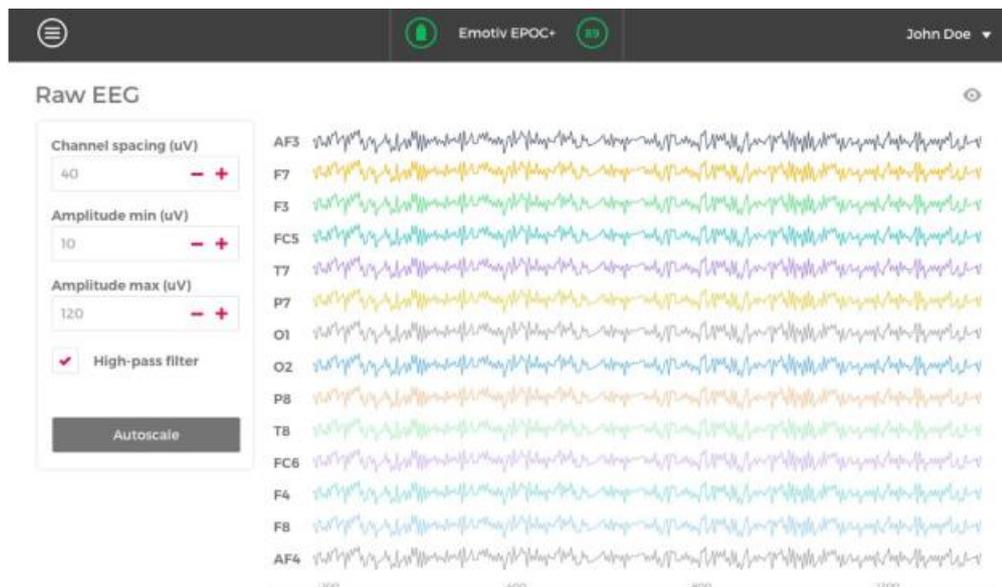
Gambar 3.4. Cek Ketahanan Baterai

5. Pasang hardware EmotivePro kepada partisipan yang akan direkam. Cek posisi elektroda, jika semua lampu indikator berwarna hijau maka hal ini menunjukkan semua elektroda dipasang pada posisi yang tepat dengan sinyal yang kuat.



Gambar 3.5. Pemasangan Hardware terhadap partisipan dan Posisi Elektroda pada EmotivPro

6. Pilih frekuensi sampling yang digunakan (pada penelitian ini digunakan  $fs=256$  Hz) dan cek data stream dengan cara kalibrasi jika sinyal yang ditampilkan pada software sesuai dengan apa yang diperintahkan oleh hardware maka perekaman sinyal EEG siap untuk dilakukan.



Gambar 3.6. Data stream yang ditampilkan pada software EmotivPro

### 3.3 Pengambilan Data

Prosedur pengambilan data terdiri dari 3 tahap yaitu Tahap pertama adalah tahap pra induksi *cybersickness*. Pada tahap ini partisipan yang akan diukur dikondisikan pada kondisi normal. Tahap kedua adalah tahap induksi, pada tahap

ini partisipan diinduksi menggunakan stimulus *video game* dengan tujuan membangkitkan kondisi *cybersickness*. Tahap terakhir adalah tahap pasca induksi, tahap ini bertujuan untuk mengukur kondisi partisipan setelah dilakukan stimulus *cybersickness*. Selain itu, pada tahap ini bertujuan untuk mengetahui apakah ada pengaruh yang signifikan antara tahap pra-induksi dan pasca-induksi akibat dari induksi yang digunakan. Prosedur pengambilan data terdiri dari 2 kondisi yang berbeda yaitu kondisi *active game playing* dan *passive watching* yang telah dijelaskan pada sub bab Pemilihan Partisipan. Penjelasan secara detail mengenai metode-metode yang digunakan dari tahap awal sampai akhir dalam rangka mennginvestigasi terjadinya *cybersickness* akan dijelaskan pada sub bab- sub bab selanjutnya.



Gambar 3.7 Metodologi Penelitian

### 3.3.1 Tahap pra-induksi *cybersickness*

Tahapan pra-induksi *cybersickness* diawali dengan pengisian kuesioner secara subjektif mengenai identitas dan kondisi partisipan sesaat sebelum dilakukan percobaan seperti pada Lampiran 1. Setelah itu, pengisian *Simulator Sickness Questionnaire* (SSQ) dilakukan pada masing-masing partisipan untuk mengukur tingkat *cybersickness* yang dialami oleh partisipan sebelum tahap induksi dimulai. SSQ ditampilkan dalam bentuk formulir yang diisi manual dengan pena dapat dilihat pada Lampiran 2. Hasil pengukuran SSQ dihitung menggunakan *Total Severity* (TS), hasil perhitungan ini dapat dijadikan sebagai kondisi awal partisipan. Selanjutnya, dilakukan perekaman sinyal EEG selama 4 menit. Pada saat perekaman, partisipan diminta dalam kondisi rileks, mata tertutup dan meminimalkan gerakan (kondisi *baseline*). Hal ini bertujuan untuk mengurangi munculnya gangguan sinyal pada EEG akibat gerakan tubuh dan gerakan mata.

### 3.3.2 Tahap Induksi *Cybersickness*

Pada tahap ini, partisipan diberikan kegiatan yang bertujuan untuk memicu gejala *cybersickness* menggunakan game “Mirror Edge” sebagai visual stimulus. Setiap partisipan bermain game dalam rentang waktu 16 menit. Game ditampilkan pada TV LED 40 inch, jarak antara monitor dan partisipan adalah 50 cm. Game dimainkan dengan cara mengontrol avatar menggunakan *keyboard* dan *mouse*. Terdapat *webcam* yang diletakkan di atas *monitor* dengan tujuan untuk mengetahui segala aktivitas yang dilakukan oleh partisipan selama permainan berlangsung. Hal ini juga dapat membantu penulis dalam memvalidasi apakah stimulus yang digunakan dapat menginduksi dengan baik. Perekaman EEG tetap berlangsung pada tahap ini. Kondisi partisipan pada tahap ini dapat dilihat pada Gambar 3.8.

Prosedur pada tahap induksi *cybersickness* juga berlaku pada pengambilan kondisi *passive watching*, namun yang membedakan adalah pada saat kondisi *passive watching* partisipan hanya melihat video permainan game “Mirror Edge” yang telah direkam sebelumnya.



Gambar 3.8 Kondisi partisipan saat induksi *cybersickness* berlangsung

### 3.3.3 Tahap Pasca-Induksi *Cybersickness*

Tahap pasca-induksi *cybersickness* merupakan prosedur terakhir pada pengambilan data. Pada tahap ini, partisipan melakukan pengisian SSQ kembali.

Hasil dari TS pada tahap pasca-induksi akan dibandingkan dengan pra-induksi. Dari hasil TS akan diketahui perubahan tingkat *cybersickness* pada partisipan sebelum dan sesudah induksi dilakukan. Perekaman EEG tidak dilakukan pada tahap ini.

### 3.4 Pengolahan Data

#### 3.4.1 Pengolahan Data Simulator Sickness Questionnaire (SSQ)

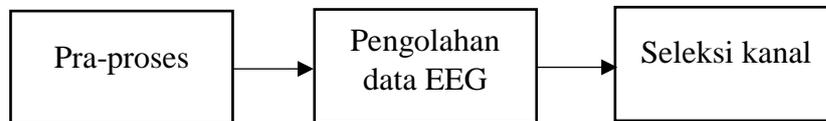
*Simulator Sickness Questionnaire* telah banyak digunakan oleh beberapa peneliti untuk mengukur tingkat *cybersickness* seseorang. SSQ pertama kali dibuat oleh Kennedy et al [14]. SSQ terdiri dari 16 gejala *cybersickness*, dimana 16 gejala tersebut dikelompokkan kembali menjadi 3 kategori yaitu *Nausea*, *Oculomotor* dan *Disorientasi* yang dapat dilihat pada. Total Severity *Cybersickness* (TSC) digunakan untuk menghitung hasil dari SSQ. Cara menghitung TSC dapat dilihat pada persamaan (3.1)

Gejala	Nausea	Oculomotor	Disorientasi
General discomfort	1	1	0
Fatigue	0	1	0
Headache	0	1	0
Eye strain	0	1	0
Difficulty focusing	0	1	1
Increased salivation	1	0	0
Sweating	1	0	0
Nausea	1	0	1
Difficulty concentrating	1	1	0
Fullness of head	0	0	1
Blurred vision	0	1	1
Dizzy (eyes open)	0	0	1
Dizzy (eyes closed)	0	0	1
Vertigo	0	0	1
Stomach awareness	1	0	0
Burping	1	0	0
Total	<b>[1]</b>	<b>[2]</b>	<b>[3]</b>
Beban pada setiap kategori	<b>9.54</b>	<b>7.58</b>	<b>13.92</b>

$$TS = (([1] \times 9.54) + ([2] \times 7.58) + ([3] \times 13.92)) \times 3.74 \quad (3.1)$$

### 3.4.2 Pengolahan Data Sinyal EEG

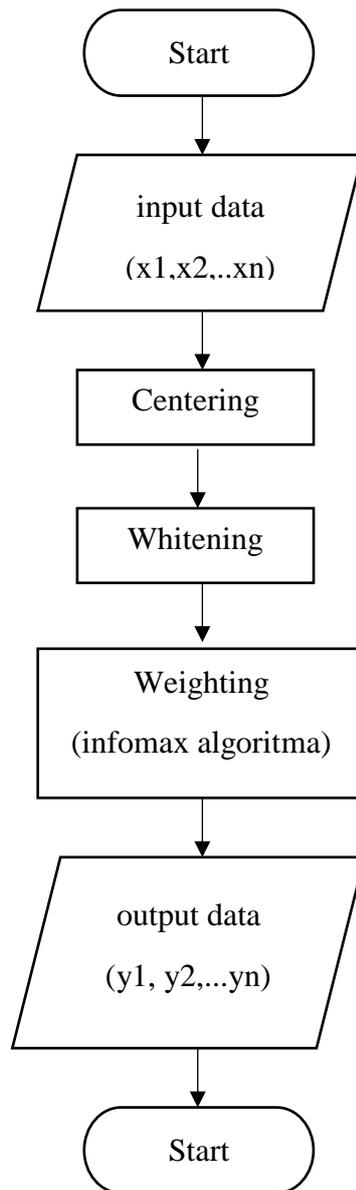
Data raw sinyal EEG didapatkan dari perekaman menggunakan alat emotive 14 kanal. Metode pengolahan data terdiri dari tiga tahapan utama yaitu Pra-proses, Ekstraksi fitur dan Klasifikasi. Dapat dilihat pada Gambar 3.9



Gambar 3.9. Metode Pengolahan Data EEG

#### 3.4.2.1 Metode Pra proses Data

Proses persiapan data (Pra proses) bertujuan untuk menyeragamkan dan membersihkan data dari noise yang muncul pada sinyal EEG. Hal ini dikarenakan, karakteristik data raw sinyal EEG terdiri dari data asli EEG dan noise artifak. Noise artifak yang umum terjadi pada sinyal EEG diantaranya *electrooculograph* (EOG), *muscular artifact* dan *body movement*. Namun, EOG merupakan noise yang paling dominan pada sinyal EEG karena memiliki amplitudo yang sangat tinggi. Oleh karena itu, noise tersebut harus dipisahkan dengan data asli sinyal EEG. Pada penelitian ini, pra proses sinyal EEG menggunakan metode Independent Component Analysis (ICA), dimana tahapan-tahapan dapat dilihat pada Gambar 3.10.

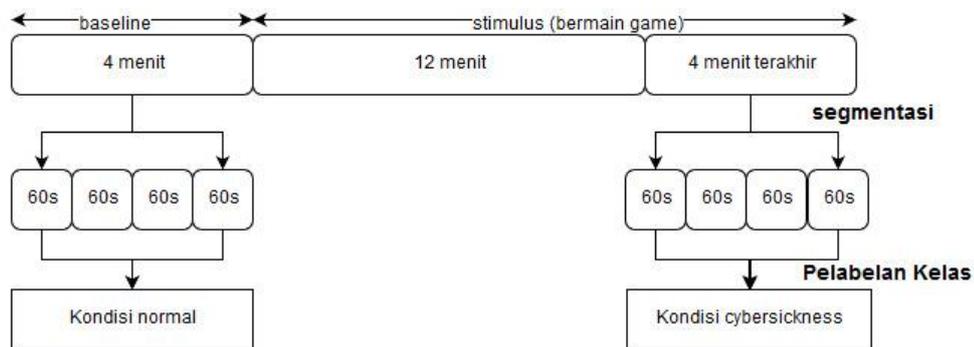


Gambar 3.10. Metode Pra proses sinyal EEG menggunakan ICA

Pada penelitian ini, pra proses data menggunakan EEGLAB toolbox untuk memisahkan data asli EEG dari noise removal. Pertama, data raw yang berupa matrix mixing  $s=[A]x$  akan diproses menggunakan ICA. Metode ICA bertujuan untuk mencari matrik  $W$  yang berisi sinyal asli tanpa adanya noise. Untuk pertama kalinya, sinyal hasil campuran (mixing matrix) mengalami pre-processing yang terdiri dari centering (pemusatan data) dan whitening. Kemudian hasil dari pra proses dilanjutkan dengan pembobotan pada matrix  $W$  menggunakan algoritma

infomax (default EEGLAB). Kemudian jika data berbentuk konvergen maka pemisahan sinyal asli dan sinyal tercampur telah selesai menghasilkan output  $[y]=[W]x$

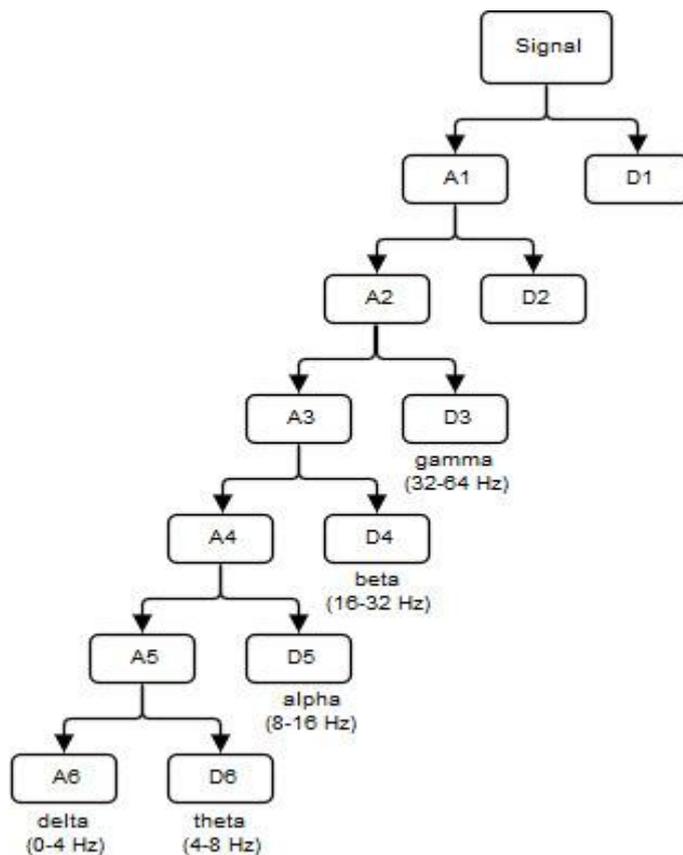
Setelah *artefact removal* berhasil dipisahkan terhadap data raw EEG, langkah selanjutnya adalah memecah data raw (segmentasi). Data sepanjang 20 menit disegmen setiap 4 menit. Namun data yang diproses selanjutnya hanya 4 segmentasi awal dan 4 segmentasi akhir. Kemudian dilakukan segmen kedua pada 4 menit pada segmen pertama dan segmen terakhir menjadi 60 s seperti terlihat pada Gambar 3.11. 4 menit pertama ditentukan sebagai label kondisi normal, sedangkan 4 menit terakhir ditentukan sebagai label kondisi *cybersickness*.



Gambar 3.11. Segmentasi data

#### 3.4.2.2 Dekomposisi sinyal EEG menggunakan Discrete Wavelet Transform (DWT)

Setelah mengalami proses segmentasi, setiap segmen didekomposisi menjadi band-band frekuensi menggunakan Discrete Wavelet Transform (DWT). Pada penelitian ini hanya 3 band frekuensi theta, alpha dan beta yang akan digunakan untuk mendeteksi terjadinya *cybersickness*. Untuk mendapat ketiga band frekuensi dilakukan dekomposisi hingga level ke-6. Hal ini dikarenakan, perekaman sinyal EEG menggunakan Emotiv epoch menggunakan frekuensi sampling 256 Hz. Band frekuensi yang digunakan adalah dari hasil dekomposisi adalah gelombang dari koefisien detail seperti yang terlihat pada Gambar 3.12.



Gambar 3.12 Dekomposisi level menggunakan DWT

Hasil dari dekomposisi sinyal menggunakan DWT didapatkan rentang frekuensi setiap gelombangnya seperti terlihat pada Tabel 3.1.

Tabel 3.1 Rentang frekuensi gelombang hasil dari Dekomposisi sinyal

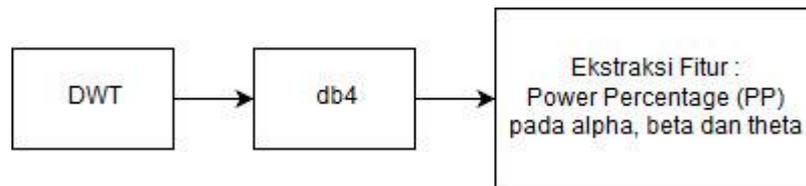
Nama Gelombang	Dekomposisi Level	Rentang Frekuensi
Delta ( $\delta$ )	A6	0-4 Hz
Theta ( $\theta$ )	D6	4-8 Hz
Alpha ( $\alpha$ )	D5	8-16 Hz
Beta ( $\beta$ )	D4	16-32 Hz
Gamma ( $\gamma$ )	D3	32-64 Hz

Pada penelitian ini kernel DWT yang digunakan adalah *daubechies* (db) tipe db4. Pemilihan rumpun db tersebut dikarenakan karakteristik dari skala yang

digunakan serupa dengan sinyal biomedis seperti *electrocardiograph* (ECG) maupun EEG.

### 3.4.2.3 Metode Ekstraksi Fitur dan Seleksi Kanal

Data yang telah mengalami proses persiapan pengolahan data selanjutnya akan dianalisa lebih lanjut pada tahap pengolahan data. Pada tahap ini ekstraksi fitur digunakan untuk mengolah data sinyal EEG. Metode pengolahan data dapat dilihat pada Gambar 3.13



Gambar 3.13 Metode Pengolahan Data

Fitur *Power percentage* (PP) digunakan untuk menentukan kondisi *cybersickness* partisipan. Adapun persamaan dari fitur dapat dilihat pada persamaan (3.2):

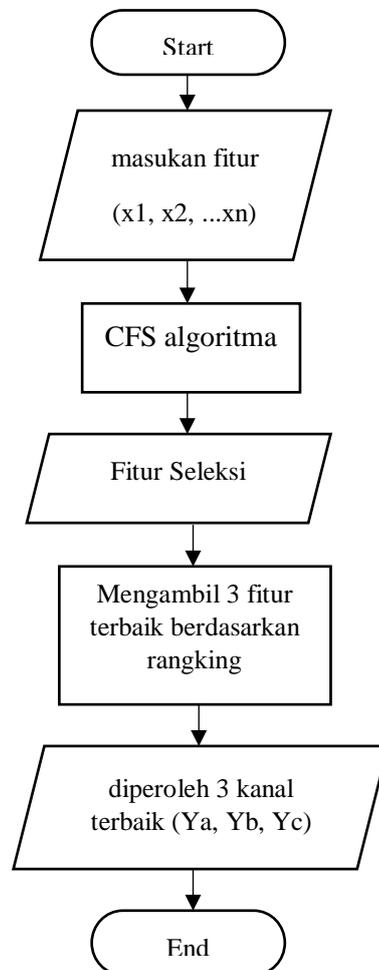
$$PP_{\alpha} = \frac{\sum_{f_{\alpha}} S(f)}{\sum_{f=f_1}^{f_2} S(f)}, f_{\alpha} \in [8,12] \quad (3.2)$$

### 3.4.2.4 Pelabelan dataset dan Seleksi Kanal

Pelabelan dataset merupakan proses dimana penggabungan dan rekapitulasi hasil dari ekstraksi fitur dalam sebuah table matriks, dimana kolom tabel terdiri dari fitur atau atribut yang digunakan dan label kelas, sedangkan baris tabel sebagai instance dari dataset. Pada penelitian ini label terdiri dari 2 kelas yaitu kondisi normal dan kondisi *cybersickness*. Label kelas kondisi normal diperoleh dari 4 menit pertama sebelum permainan dimulai (tahap pra-induksi), label kelas kondisi *cybersickness* diperoleh dari 4 menit terakhir permainan game “Mirror Edge” (tahap induksi), seperti yang terlihat pada Gambar 3.11. Penentuan label kelas berdasarkan hasil kuesioner Simulator Sickness Questionnaire (SSQ) yang telah diisi partisipan sebelum dan setelah bermain game.

### 3.4.2.5 Seleksi Kanal Menggunakan Metode Correlation Feature Selection (CFS)

Setelah dilakukan proses pelabelan, proses selanjutnya adalah melakukan seleksi kanal menggunakan metode Correlation Feature Selection (CFS). Adapun prosedur proses seleksi kanal dapat dilihat pada Gambar 3.14:



Gambar 3.14 Prosedur Seleksi Kanal Menggunakan Metode Correlation Feature Selection (CFS)

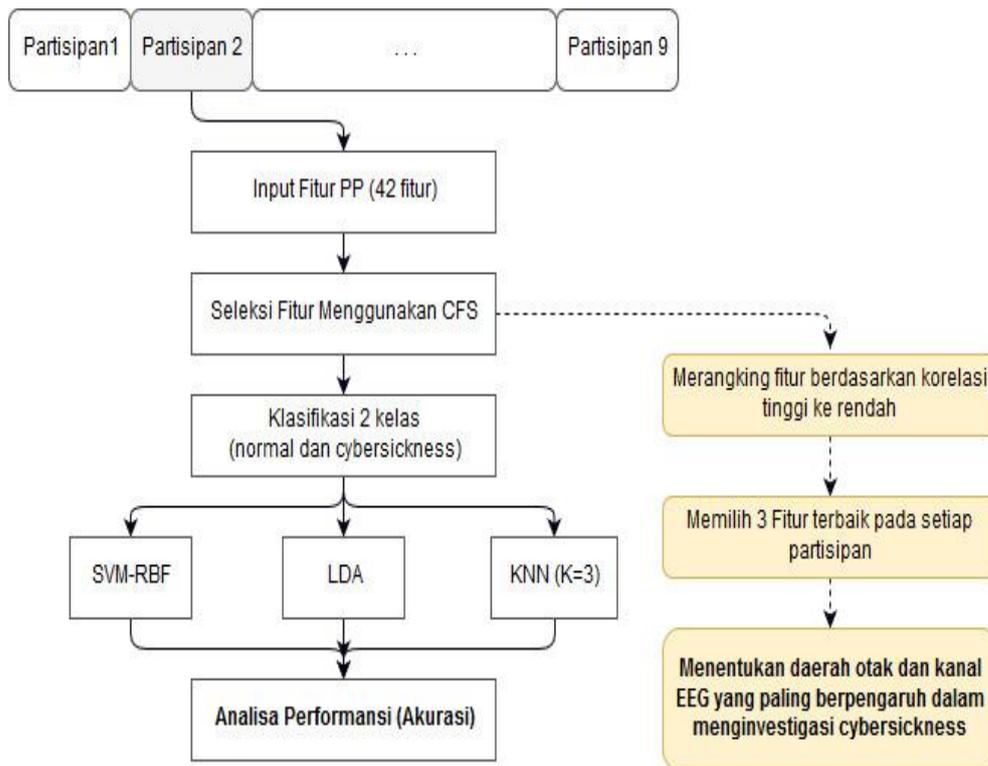
### 3.4.3 Evaluasi Performansi Seleksi Kanal

Pada tahap ini merupakan tahap evaluasi performansi. Metode klasifikasi menggunakan 3 klasifier yang berbeda yaitu LDA, SVM-RBF dan K-NN. Pada penelitian ini, performansi klasifikasi dilakukan pada setiap partisipan. Hal ini dikarenakan, setiap partisipan memiliki respon otak yang berbeda-beda meskipun stimulus yang digunakan sama.[27] Ada sebanyak 42 fitur yang terdiri dari 3 fitur *Power percentage* pada alpha, beta dan teta pada 14 kanal (3 PP x 14 kanal) yang

digunakan pada setiap partisipan. Proses training-testing yang dilakukan pada penelitian ini adalah menggunakan metode 5-folds cross validation. Berikut diagram alur proses klasifikasi pada penelitian ini dapat dilihat pada Gambar 3.15.

Di dalam sebuah komputasi, kompleksitas yang sangat rendah didalam sebuah algoritma sangat dibutuhkan agar saat aplikasi dijalankan secara realtime sebuah komputasi dapat mumpuni. Pada penelitian ini, setiap partisipan tidak mungkin untuk menggunakan semua kanal dalam menginvestigasi terjadinya *cybersickness*. Hal ini dapat meningkatkan kompleksitas dan membutuhkan waktu yang lama sebuah komputasi dalam *me-running system*. Oleh karena itu, metode *Correlation Feature Selection* (CFS) digunakan untuk memiliki fitur yang berkorelasi tinggi sehingga dapat meningkatkan performansi dari suatu akurasi.

Setiap partisipan akan dilatih menggunakan metode CFS untuk memilih fitur yang paling dominan pada sebuah data. Hasil dari seleksi fitur dapat menentukan kanal yang paling relevan terhadap kasus *cybersickness*, baik pada kondisi active game playing dan passive watching. Selanjutnya, akan dibandingkan hasil akurasi pada saat menggunakan semua kanal dan hasils seleksi kanal. Adapun prosedur evaluasi seleksi kanal menggunakan algoritma SVM-P, LDA dan KNN pada Gambar 3.15.



Gambar 3.15. Diagram Alir Proses Seleksi Fitur dan Klasifikasi

## **BAB 4**

### **HASIL DAN PEMBAHASAN**

Pada bab ini akan dijelaskan secara detail mengenai hasil penelitian dan analisa mengenai investigasi *cybersickness* pada partisipan menggunakan sinyal EEG dengan stimulus video *game*.

#### **4.1 Pemilihan Data Raw dan Pelabelan Partisipan**

Penelitian ini melibatkan 9 orang partisipan yang terdiri dari 7 orang pria dan 2 orang wanita untuk mengikuti serangkaian eskperimen dalam rangka menginvestigasi terjadinya *cybersickness*. Partisipan yang terpilih merupakan hasil dari kuesioner personal dimana semua partisipan telah memenuhi kriteria untuk mengikuti eksperimen pada penelitian ini. Proses pengambilan data membutuhkan waktu  $\pm 25$  menit dimana setiap partisipan menghasilkan 2 data raw yang terdiri dari 2 kondisi yang berbeda, yaitu: saat partisipan bermain *game* dengan aktif (*active game playing*) dan saat partisipan melihat video dari permainan *game* (*passive watching*). Namun dari ke-9 partisipan hanya 4 partisipan yang bersedia untuk melakukan eksperimen *cybersickness* pada kondisi *passive watching*. Pengambilan data pada 2 kondisi yang berbeda dilakukan secara berkelanjutan dari *baseline* ke induksi *cybersickness* dan terdiri dari label kelas fase normal dan fase *cybersickness*.

Pemilihan data raw juga didasarkan pada hasil pengukuran *cybersickness* secara subjektif menggunakan *Simulator Sickness Questionnaire* (SSQ). Dalam hal ini, semua partisipan mengalami peningkatan nilai SSQ yang diukur sebelum dan sesudah induksi *cybersickness*. Sehingga hal ini dapat dijadikan sebagai patokan awal bahwa partisipan mengalami gejala *cybersickness*. Pada Tabel 4.1 merupakan tabel daftar data partisipan beserta nama label yang ditentukan oleh penlulis. Penentuan label ini bertujuan untuk mempermudah dalam proses analisa berikutnya.

Tabel 4.1. Pelabelan data Partisipan

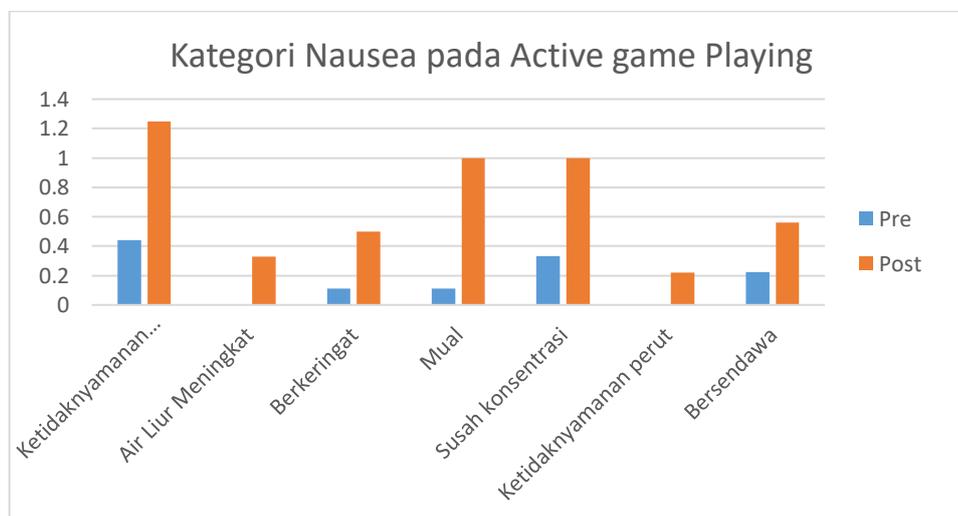
<b>Nama Partisipan</b>	<b>Kode Kondisi Aktif <i>Game</i> (Active game playing)</b>	<b>Kode Kondisi Pasif <i>Game</i> (Passive watching)</b>
Agnes	S01	
Alfi	S02	
Andi	S03	P03
Alan	S04	P04
Lutfi	S05	
Suhaeri	S06	P06
Prasetyo	S07	P07
Muhsin	S08	
Arief	S09	

#### 4.2 Pengukuran secara Subjektif

Pengukuran subjektif menggunakan kuesioner SSQ membantu penulis untuk mengetahui kondisi partisipan sebelum dan setelah dilakukan induksi *cybersickness* melalui 16 gejala yang dibagi menjadi 3 sub kategori yaitu Nausea, Oculomotor dan Disorientasi. Skala yang digunakan SSQ untuk menggambarkan kondisi partisipan *cybersickness* antara 0 sampai 3. Skala 0 mengindikasikan bahwa partisipan tidak merasakan gejala *cybersickness* saat induksi berlangsung, skala 3 mengindikasikan bahwa partisipan mengalami gejala *cybersickness* yang sangat parah atau tinggi. Pada penelitian sebelumnya yang dilakukan oleh [28], terdapat nilai ambang batas tertentu pada nilai SSQ yang dapat digunakan untuk menentukan level *cybersickness*, dimana jika nilai total SSQ antara 10-15 maka partisipan tersebut mengalami gejala *cybersickness* pada level normal (tidak terlalu parah), namun jika nilai total SSQ lebih dari 15 maka partisipan berada didalam kondisi *cybersickness* yang sangat tinggi. Nilai tersebut didapat dari nilai SSQ setelah induksi sehingga nilai tersebut digunakan untuk mengetahui kondisi akhir partisipan dan dapat ditentukan apakah partisipan mengalami kenaikan gejala *cybersickness* yang sangat tinggi atau rendah atas induksi yang telah diberikan.

Pada sub bab ini penulis akan menganalisa pengukuran subjektif SSQ setiap kategori. Analisis akan dilakukan pada nilai rata-rata pengukuran SSQ dari seluruh partisipan yang mengikuti penelitian pada 2 kondisi yang berbeda yaitu *active game playing* dan *passive watching*.

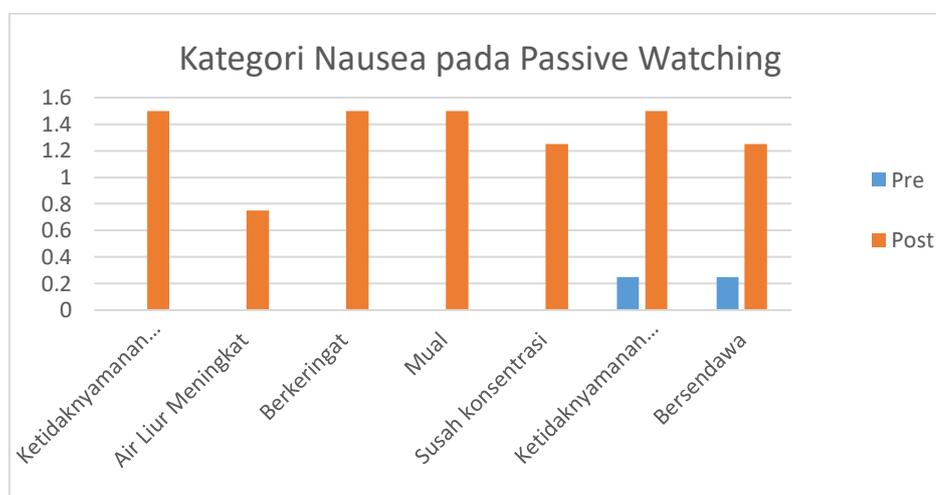
**Kategori pertama** adalah Nausea (Mual) yang terdiri dari 7 gejala dari 16 gejala SSQ diantaranya ketidaknyamanan secara umum, air liur meningkat, berkeringat, muntah, susah konsentrasi, ketidaknyamanan perut dan bersendawa. Kategori Nausea digunakan untuk menggambarkan kondisi *cybersickness* yang berhubungan dengan pencernaan. Dari kategori Nausea, ketujuh gejala mengalami tren peningkatan dari kondisi sebelum induksi ke kondisi setelah induksi baik pada saat partisipan bermain *game* dengan aktif dan menonton video dari sebuah permainan “Mirror Edge” seperti yang ditunjukkan pada grafik Gambar 4.1.



(a)

Pada Gambar 4.1 (a) dapat dianalisa bahwa diantara 7 gejala yang termasuk dalam kategori Nausea, gejala mual secara umum rata-rata mengalami peningkatan yang paling tinggi yaitu sekitar 0,889 poin dan gejala ketidaknyamanan perut mengalami peningkatan yang paling rendah yaitu sekitar 0,25 poin. Gejala mual dapat dikatakan sebagai gejala yang paling berpengaruh pada kategori Nausea. Hal ini dikarenakan tampilan dari *game* “Mirror Edge” yang berbasis 3D dan bersifat *first player person* sehingga membuat partisipan cenderung pusing dan mual serta mengalami perasaan *immersive* seolah-olah

berada pada lingkungan permainan tersebut. Selain itu, latar dari permainan “Mirror Edge” yang terdiri dari gedung-gedung bertingkat dapat meningkatkan gejala *cybersickness*. Hasil ini juga atas konfirmasi partisipan dimana mereka merasakan gejala mual saat bermain permainan ini.

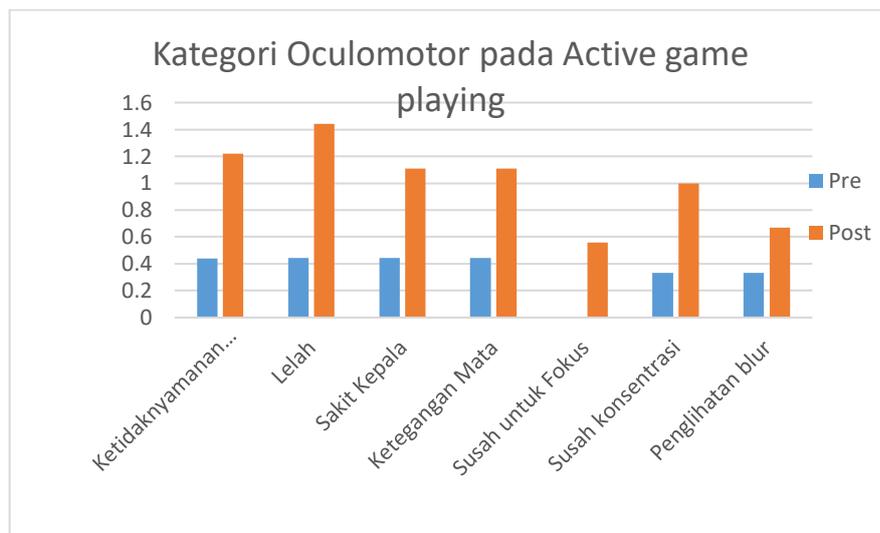


(b)

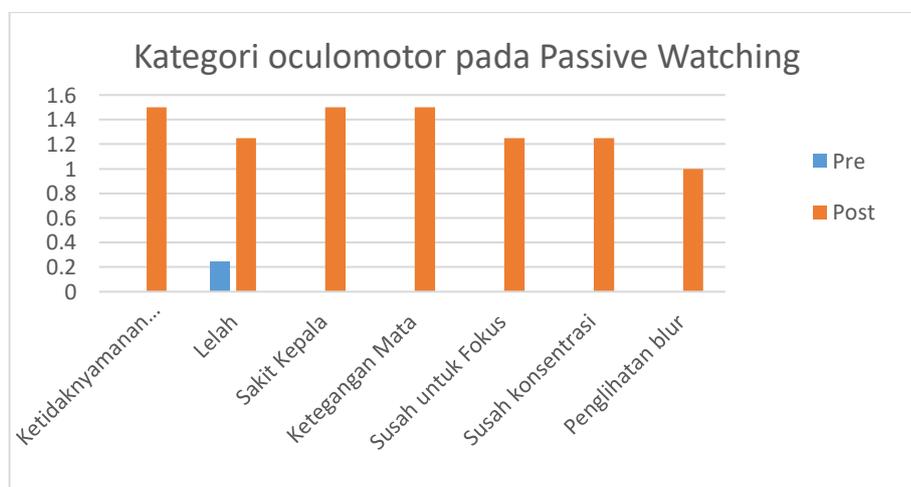
Gambar 4.1. Hasil SSQ pada Kategori Nausea pada (a) *Active game playing* (9 partisipan) dan (b) *Passive watching* (4 partisipan)

Pada Gambar 4.1 (b) terdapat 4 partisipan yang diukur saat induksi *passive watching*. Dari grafik dapat dianalisa bahwa gejala ketidaknyamanan secara umum, mual dan berkeringat mengalami tren kenaikan nilai yang paling tinggi dan sama yaitu sekitar 1,50 poin. Sedangkan gejala air liur meningkat memiliki tren kenaikan paling rendah yaitu sekitar 0.60 poin. Hasil dari konfirmasi 4 partisipan yang mengikuti induksi *passive watching*, menonton video dari permainan “Mirror Edge” lebih menyebabkan mual dan berkeringat dingin daripada saat bermain *game* secara aktif. Keadaan ini dapat diilustrasikan seperti saat naik kendaraan umum, dimana seorang sopir mengalami motion sickness yang lebih rendah daripada penumpang. Partisipan yang mengikuti induksi *passive watching* dianalogikan sebagai penumpang yang tidak mengetahui kapan sopir memberhentikan, belok kanan atau melaju cepat sehingga penumpang mengalami *sensory conflict* yaitu ketidakcocokan antara sistem visual dan vestibular sehingga dapat menyebabkan mual.

**Kategori kedua** adalah oculomotor yang terdiri dari gejala ketidaknyamanan secara umum, lelah, sakit kepala, ketegangan mata, susah untuk focus, susah konsentrasi dan penglihatan blur. Dari ketujuh gejala tersebut kategori oculomotor mengukur gejala *cybersickness* khususnya pada saraf yang mengatur gerakan bola mata. Akibat dari gejala oculomotor adalah sering terjadinya kelelahan mata. Pada Gambar 4.2 dapat dilihat bahwa dari semua gejala yang membangun kategori oculomotor mengalami tren kenaikan dari sebelum induksi dengan setelah induksi baik pada *active game playing* maupun *passive watching*.



(a)



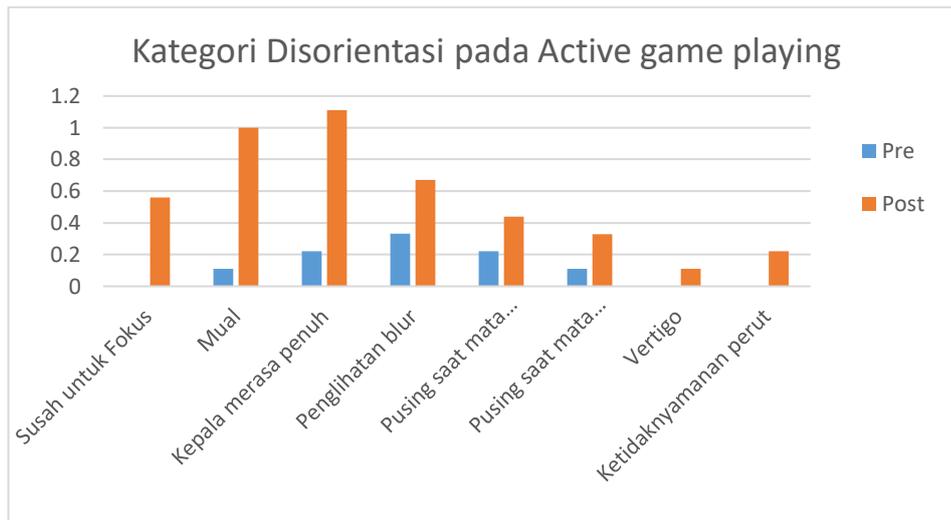
(b)

Gambar 4.2 Hasil SSQ pada Kategori Oculomotor pada (a) *Active game playing* (9 partisipan) dan (b) *Passive watching* (4 partisipan)

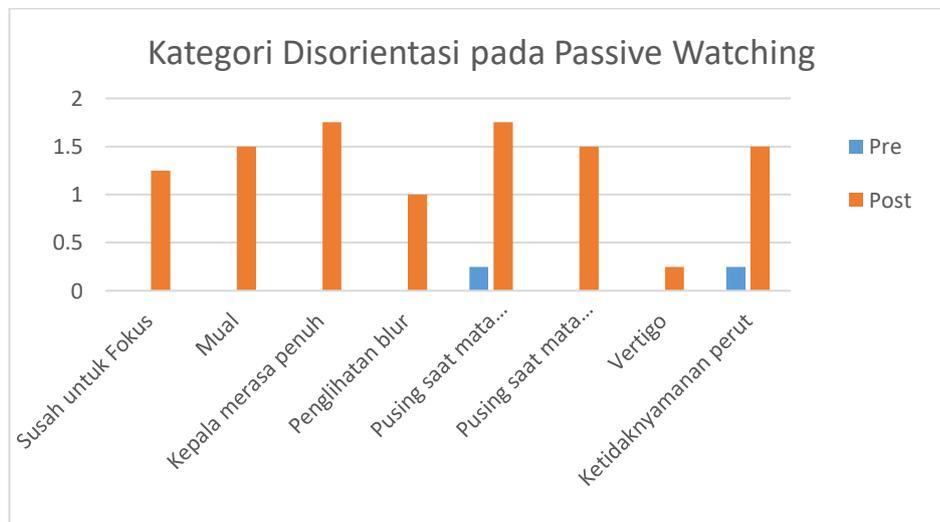
Kedua tren grafik merupakan rata-rata dari setiap gejala yang dialami oleh partisipan. Pada Gambar 4.2 (a), dapat dianalisa bahwa diantara 7 gejala yang termasuk dalam kategori Oculomotor, gejala lelah mengalami peningkatan yang paling tinggi dari kondisi sebelum diinduksi yaitu sekitar 0,996 poin dan gejala penglihatan blur mengalami peningkatan yang paling rendah yaitu sekitar 0,337 poin. Hal ini dikarenakan, kelelahan seseorang dapat dipicu dari gejala-gejala yang lain seperti ketegangan mata, sakit kepala dan penglihatan blur sehingga gejala lelah mengalami perubahan yang signifikan sebelum dan sesudah adanya induksi. Peningkatan kategori oculomotor pada setiap gejala juga dipengaruhi oleh Field of view (FOW) dari layar yang digunakan untuk menampilkan permainan “Mirror Edge”. Semakin besar layar yang digunakan maka aktivitas gerakan bola mata akan semakin tinggi untuk mengamati setiap sudut-sudut layar. Aktivitas gerakan bola mata yang tinggi ini juga memicu terjadinya ketegangan mata, lelah dan penglihatan blur.

Pada Gambar 4.2 (b), Dari grafik dapat dianalisa bahwa gejala ketidaknyamanan secara umum, sakit kepala dan ketegangan mata mengalami tren kenaikan nilai yang paling tinggi yaitu sekitar 1,50 poin. Sedangkan gejala lelah dan penglihatan blur memiliki tren kenaikan paling rendah yaitu sekitar 1,00 poin. Hampir sama dengan penjelasan sebelumnya dimana aktivitas gerakan bola mata dapat menyebabkan ketegangan mata dan hal tersebut akan menyebabkan sakit kepala sehingga partisipan merasa tidak nyaman secara umum.

**Kategori ketiga** adalah Disorientasi, yang terdiri dari gejala susah untuk focus, mual, kepala merasa penuh, penglihatan blur, pusing saat mata terbuka dan tertutup, vertigo dan ketidaknyamanan perut. Kategori disorientasi pada gejala *cybersickness* merupakan gejala terakhir yang terjadi saat partisipan diinduksi. Kategori ini menjelaskan tentang ketidakseimbangan tubuh yang dialami oleh partisipan akibat dari paparan 3D. Disorientasi terjadi saat dimana tubuh merasa gerak didalam lingkungan virtual padahal dalam kenyataannya tubuh diam/statis didunia nyata. Pada Gambar 4.3 dapat dilihat bahwa dari semua gejala yang membangun kategori oculomotor mengalami tren kenaikan dari sebelum induksi dengan setelah induksi baik pada *active game playing* maupun *passive watching*.



(a)



(b)

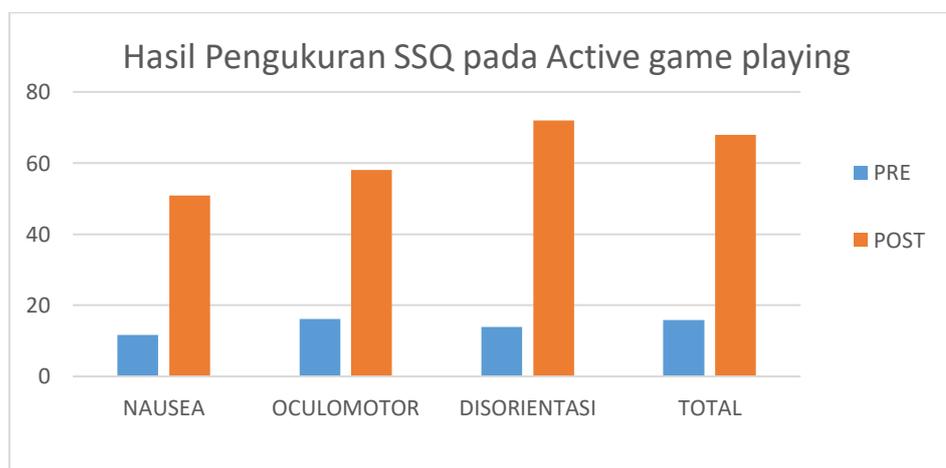
Gambar 4.3 Hasil SSQ pada Kategori Disorientasi pada (a) *Active game playing* (9 partisipan) dan (b) *Passive watching* (4 partisipan)

Pada Gambar 4.3 (a) dapat dianalisa bahwa diantara 8 gejala yang termasuk dalam kategori Disorientasi, gejala mual mengalami peningkatan yang paling tinggi dari kondisi sebelum diinduksi yaitu sekitar 0,996 poin dan gejala penglihatan blur mengalami peningkatan yang paling rendah yaitu sekitar 0,337 poin. Pada penelitian ini mual menjadi gejala yang paling berpengaruh pada kategori disorientasi. Hal ini dikarenakan, partisipan yang mengalami ketidakseimbangan tubuh akibat dari induksi video *game* 3D cenderung mengalami mual akibat ketidakcocokan antara sistem vestibular dan visual. Sedangkan pada

Gambar 4.3 (b) gejala yang memiliki tren paling tinggi adalah kepala merasa penuh yaitu sekitar 1.75 poin sedangkan kenaikan terendah terjadi pada gejala vertigo yaitu 0,25 poin. Hasil dari konfirmasi terhadap partisipan, semua partisipan merasa kehilangan keseimbangan akibat dari paparan 3D dengan gejala utamanya adalah kepala merasa penuh.

#### 4.2.1 Hasil Pengukuran Secara Subjektif pada *Active game playing*

Metode pengukuran secara subjektif adalah hasil dari self-report atau kuesioner dari partisipan. Secara validitas, pengukuran secara subjektif masih terbilang sangat lemah, Namun hal ini dapat membantu penulis dalam mengetahui identitas dan kondisi awal partisipan khususnya dalam rangka untuk menginvestigasi terjadinya gejala *cybersickness*. Metode SSQ yang terdiri dari 16 gejala *cybersickness* bisa memberikan informasi detail dari apa yang dirasakan oleh partisipan akibat induksi yang diberikan, informasi tersebut didasarkan pada nilai skala yang diberikan antara 0-3 yaitu kondisi tidak merasakan *cybersickness* (none) sampai merasakan *cybersickness* yang sangat parah (severe). Adapun hasil pengukuran rata-rata menggunakan SSQ pada kondisi *active game playing* dapat dilihat pada Gambar 4.4.

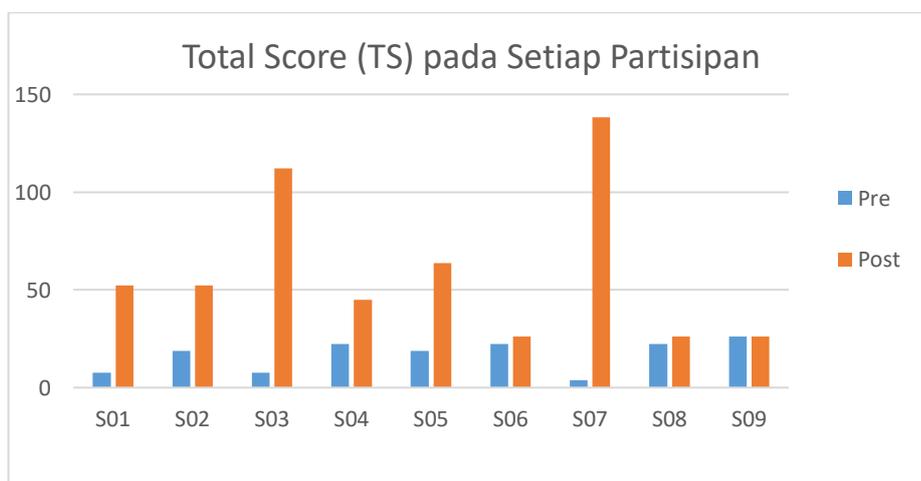


Gambar 4.4 Hasil Rata-rata Pengukuran SSQ pada kondisi *Active game playing* (Mean = 9 partisipan)

Dari hasil grafik dapat dianalisa bahwa ketiga kategori *cybersickness* mengalami tren peningkatan dari sebelum dan setelah induksi. Kategori Disorientasi menduduki peringkat pertama pada pengukuran SSQ dengan nilai rata-rata

kenaikan 58 point, kemudian diikuti oleh oculomotor 39,22 poin dan nausea yaitu 39,22 poin sehingga Total Score mengalami kenaikan sebesar 52,048 poin. Pada penelitian sebelumnya [11], kondisi *cybersickness* terjadi pada saat SSQ-Disorientasi > SSQ-Nausea > SSQ-Oculomotor (D>N>O). Namun, ketentuan tersebut tidak berlaku pada semua penelitian yang meneliti tentang *cybersickness*[3]. Begitu halnya pada penelitian ini, peringkat kategori SSQ berbeda dari penelitian sebelumnya dimana SSQ-D > SSQ-Oculomotor > SSQ-Nausea. Hasil tersebut juga berpengaruh pada kondisi partisipan yang mengikuti eksperimen, dari hasil wawancara, partisipan yang bermain *game* secara aktif cenderung lebih cepat lelah mata daripada mual akibat dari pergerakan avatar pada permainan “Mirror Edge” pada layar TV LED yang lebar.

Kondisi *cybersickness* juga dapat diketahui dari masing-masing nilai kategori SSQ, dimana jika nilai dari masing-masing kategori berkisar antara 10-15 maka kondisi masih dianggap normal. Pada Gambar 4.4, terlihat bahwa nilai dari masing-masing kategori melebihi batas atas dari kondisi normal sehingga secara rata-rata semua partisipan dapat dikatakan mengalami *cybersickness* setelah menerima induksi.



Gambar 4.5 Total Score SSQ pada setiap partisipan saat induksi *active game playing*

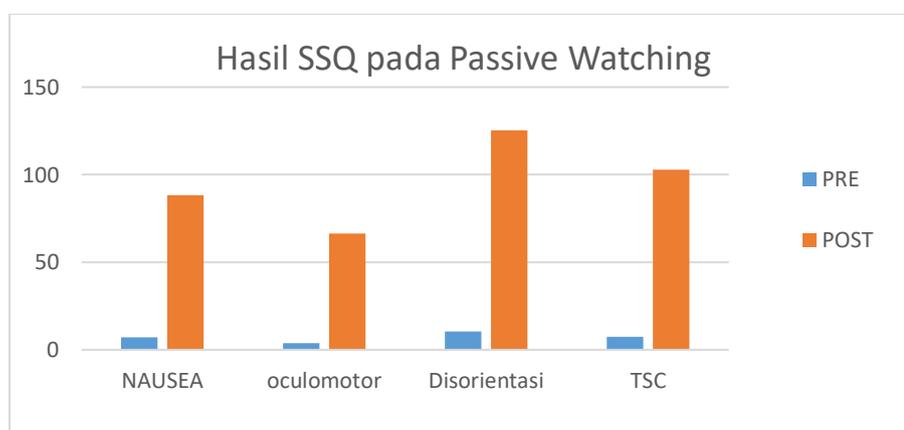
Pada Gambar 4.5 akan dianalisa hasil dari *Total Score* pada setiap partisipan. Dari hasil grafik tersebut dapat disimpulkan bahwa semua partisipan mengalami tren peningkatan dari sebelum induksi dengan setelah induksi, kecuali

pada partisipan S09. Nilai pra-TS pada partisipan S09 memiliki nilai yang sama dengan pro-TS (pra-TS = pro-TS), hal ini dikarenakan partisipan S09 adalah seorang *gamers* yang setiap harinya bermain *game online* maupun *game 3D* kurang lebih 3 jam sehingga tingkat *cybersickness* sangat kecil terjadi meskipun nilai dari masing-masing kategori N, O, D lebih dari 15 poin. Selain itu, partisipan S09 dapat dikatakan mempunyai kontrol permainan yang baik sehingga dapat meminimalisir terjadinya *cybersickness*.

Partisipan S03 dan S07 mengalami tren kenaikan TS paling tinggi yaitu sekitar 104,72 poin dan 134,64 poin. Hal ini dapat disimpulkan bahwa kedua partisipan mengalami gejala *cybersickness* yang sangat tinggi. Kenaikan nilai yang tinggi tersebut juga divalidasi dengan hasil rekaman video saat kedua partisipan bermain *game* “Mirror Edge”, dimana keduanya sering bersendawa dan mual yang sangat parah diakhir permainan. Selain itu, berdasarkan self-repot, partisipan S03 dan S07 merupakan partisipan yang mudah mengalami mabuk perjalanan (*motion sickness*) saat menggunakan alat transportasi seperti mobil, bus maupun kapal. Sehingga dapat ditarik kesimpulan bahwa seseorang yang cenderung mudah mengalami mabuk perjalanan maka akan mudah mengalami peningkatan gejala *cybersickness*.

#### 4.2.2 Hasil Pengukuran Secara Subjektif pada *Passive watching*

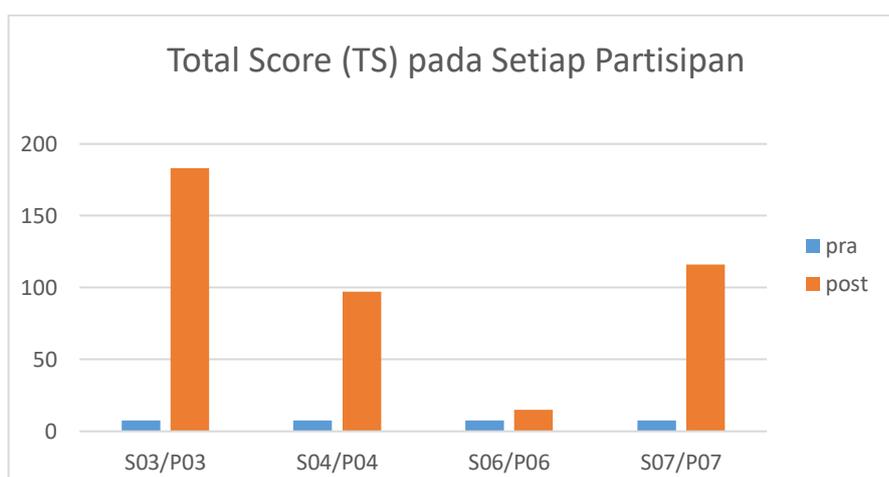
Pada kondisi *passive watching* yang diikuti oleh 4 partisipan juga diukur menggunakan SSQ setelah mendapatkan induksi. Adapun hasil dari pengukuran SSQ pada *passive watching* dapat dilihat pada Gambar 4.6.



Gambar 4.6 Hasil Rata-rata Pengukuran SSQ pada *Passive watching* (Mean = 4 partisipan)

Sama halnya dengan hasil pengukuran SSQ pada *active game playing*, pengukuran pada *passive watching* juga mengalami tren kenaikan antara sebelum dan setelah induksi didapatkan. Hal ini dapat dikatakan bahwa semua partisipan mengalami *cybersickness* terlihat dari semua gejala mengalami kenaikan nilai skala dari kondisi sebelum induksi. Nilai SSQ pada kategori Disorientasi menduduki peringkat tinggi yaitu mengalami kenaikan sebesar 114,84 point, kemudian diikuti oleh Nausea sebesar 81,09 dan Oculomotor sebesar 62,53 poin sehingga didapatkan nilai rata Total Score mengalami kenaikan sebesar 95,37 poin. Dari hasil pengukuran pada *passive watching*, peringkat nilai antar kategori sesuai dengan penelitian yang dilakukan oleh [11], dimana  $SSQ-D > SSQ-N > SSQ-O$  hal ini sesuai dengan karakteristik dari munculnya kondisi *cybersickness*.

Pada subbab ini juga akan ditampilkan nilai *Total Score* (TS) saat induksi *passive watching* yang diikuti oleh 4 partisipan, hasil grafik dapat dilihat pada Gambar 4.7.



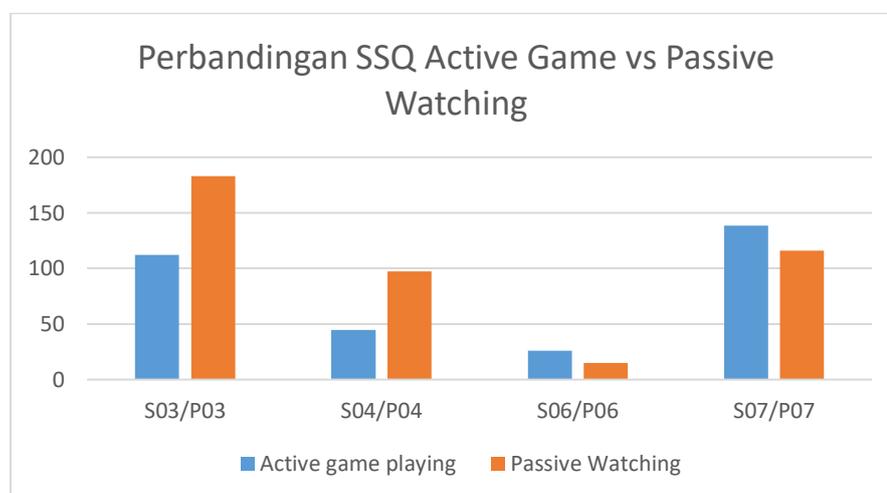
Gambar 4.7 Total Score SSQ pada setiap partisipan saat induksi *passive watching*

Dari grafik tersebut dapat dianalisa bahwa semua partisipan mengalami tren peningkatan gejala *cybersickness* dari sebelum induksi sampai setelah induksi terjadi. Kenaikan TS yang paling tinggi terjadi pada partisipan P03 dan P07 dengan nilai kenaikan sebesar 175,78 poin dan 108,46 poin. Kedua partisipan ini juga memiliki nilai peningkatan paling tinggi pada induksi *active game playing*. sehingga dapat disimpulkan bahwa partisipan yang mengalami gejala *cybersickness* tinggi pada induksi *active game playing* juga akan mengalami gejala *cybersickness*

tinggi pada induksi *passive watching*. Partisipan P06 mengalami peningkatan tren yang paling rendah yaitu sekitar 7,48 poin. Hal ini dikarenakan, P06 merupakan seorang *gamers* yang selalu bermain *game* selama 3 jam setiap harinya sehingga partisipan tersebut memiliki control yang baik terhadap permainan.

#### 4.2.3 Perbandingan Hasil SSQ antara *Active game playing* dan *Passive watching*

Setelah dianalisa secara detail mengenai hasil pengukuran pada induksi *active game playing* dan *passive watching*, baik pada setiap kategori maupun setiap partisipan. Pada subbab ini, akan dijelaskan mengenai perbandingan hasil SSQ antara *active game playing* dan *passive watching*. Dalam hal ini, penulis hanya membandingkan 4 partisipan saja yang mengikuti kedua induksi (*active game playing* dan *passive watching*) pada penelitian ini. Adapun hasil dari pengukuran kedua induksi akan ditampilkan pada Gambar 4.8.



Gambar 4.8. Nilai hasil perbandingan SSQ antara *Active game playing* dan *Passive watching* (total partisipan 4 orang)

Pada partisipan S03 dan S04, hasil SSQ pada induksi *passive watching* memiliki nilai lebih besar daripada *active game playing* yaitu dengan tren kenaikan 71,06 poin dan 52,36 poin. Hasil ini sesuai dengan teori pengemudi dan penumpang, dimana partisipan dengan induksi *passive watching* (penumpang) mengalami *cybersickness* lebih tinggi daripada partisipan dengan induksi *active game playing* (pengemudi).[6] Seseorang yang bermain *game* secara aktif berarti mengontrol avatar sesuai dengan keinginan pemain sehingga seorang pemain *game* mengetahui kapan avatar harus bergerak, berbelok arah dan berhenti berlari

sehingga pemain akan tau apa yang akan terjadi, sistem visual dan vestibular tidak begitu mengalami kontradiksi. Sedangkan pada *passive watching*, partisipan tidak menggerakkan avatar didalam permainan secara langsung, partisipan hanya melihat permainan dalam bentuk *video* sehingga partisipan tidak mengetahui kapan avatar berlari cepat, berbelok arah dan melompat tinggi. Adanya gerakan tiba-tiba dari *video game* 3D menyebabkan terjadi *sensory conflict* dimana antara sistem visual dan vestibular tidak sinkron sehingga menyebabkan gejala *cybersickness* yang tinggi. Jika partisipan tidak memiliki control yang baik pada kondisi *passive watching* maka dapat disimpulkan bahwa partisipan tersebut cenderung cepat mengalami *cybersickness*.

Pada partisipan S06 dan S07, nilai SSQ pada *passive watching* lebih rendah daripada *active game playing*. Hal ini dikarenakan, video permainan yang dimainkan adalah rekaman video saat S06 bermain pada induksi *active game playing* sehingga partisipan telah mengetahui gerakan avatar dalam permainan tersebut sehingga pada saat induksi *passive watching* berlangsung, S06 tidak begitu mengalami gejala *cybersickness*. Sama halnya dengan partisipan S07, nilai SSQ *passive watching* < SSQ *active game playing*. Meskipun secara hasil *self-report*, S07 mengalami gejala *cybersickness* yang tinggi yaitu lebih banyak bersendawa dan mual saat menonton *video game* namun S07 merasa gejala *cybersickness* lebih parah dirasakan saat induksi *active game playing*.

#### **4.3 Hasil Pengolahan Sinyal EEG**

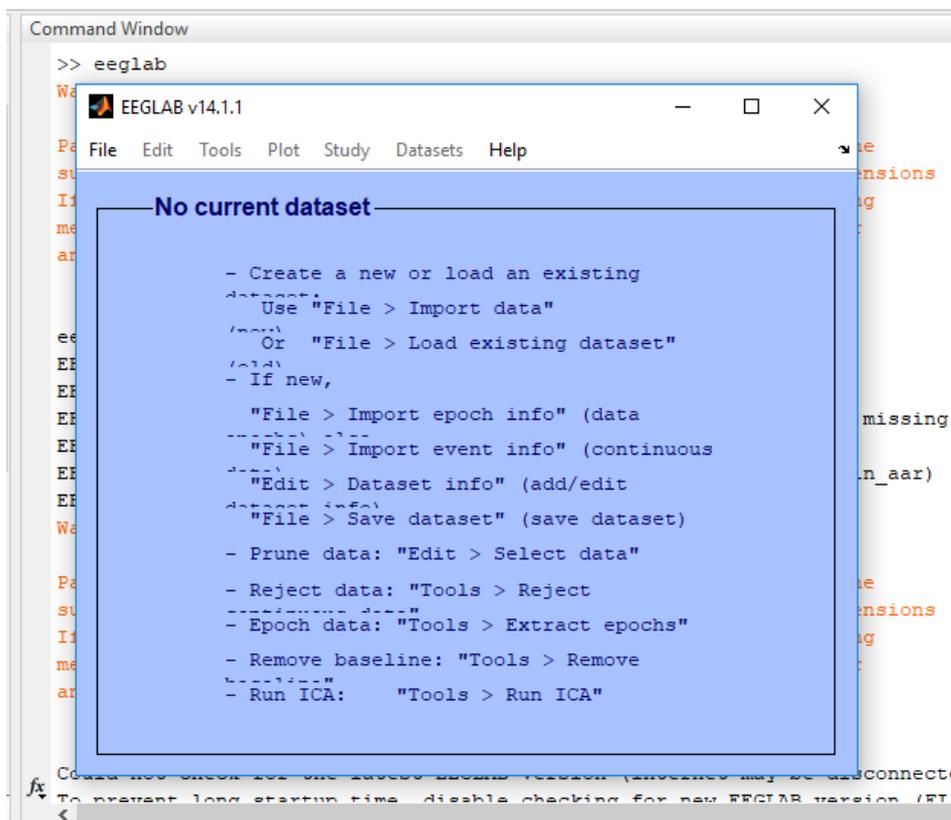
Pada subbab sebelumnya, telah dianalisa mengenai hasil dari pengukuran subjektif menggunakan SSQ. Secara umum, terjadi peningkatan pada gejala *cybersickness* saat partisipan diinduksi menggunakan permainan *game* “Mirror Edge”. Namun, hasil pengukuran secara subjektif tidak memiliki validasi yang tinggi dikarenakan hasil pengukuran berdasarkan *self-report*. Oleh karena itu, penulis menggunakan EEG sebagai alat ukur objektif untuk menanggulangi masalah tersebut. EEG telah banyak digunakan untuk mengukur terjadinya *cybersickness* pada seseorang [7][9]. Hal ini dikarenakan, EEG sangat sensitive terhadap aktivitas gelombang otak manusia, dimana otak berperan sebagai koordinasi dari semua aktivitas yang dilakukan oleh tubuh manusia. Analisa hasil

pengolahan sinyal EEG mulai dari pra pengolahan hingga tahap klasifikasi untuk menginvestigasi terjadinya *cybersickness* akan dijelaskan pada subbab ini.

#### 4.3.1 Hasil Tahap Awal (Pre-processing) pada Pengolahan Sinyal EEG

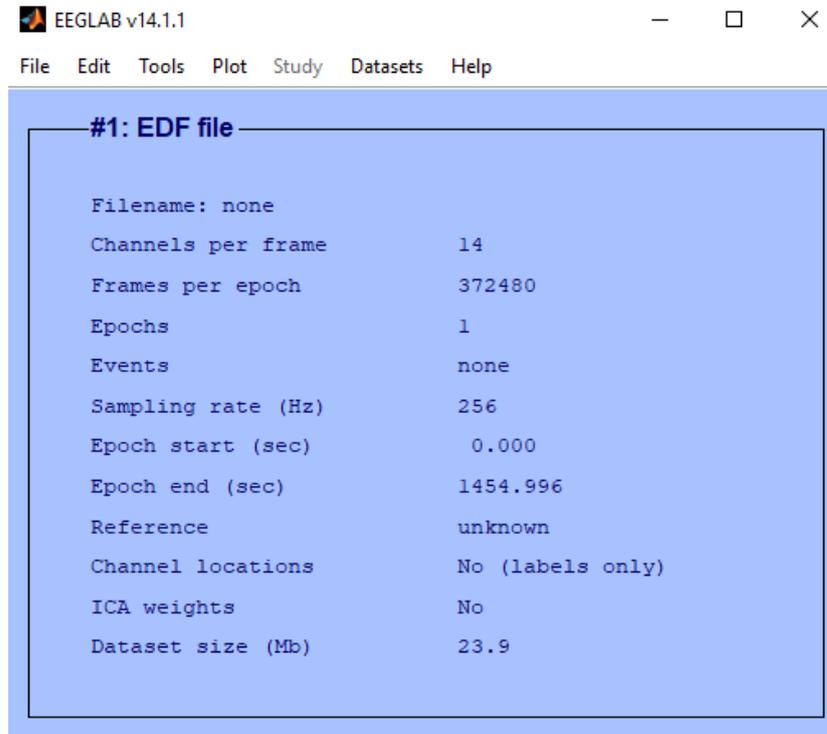
Tahap awal dari pengolahan sinyal EEG adalah menghapus segala jenis noise (Artefact) yang tercampur dengan data asli EEG. Ada beberapa macam noise yang sangat berpengaruh terhadap data raw EEG, diantaranya sinyal EOG, suara nafas, muscular artifact. Namun, noise yang paling mengganggu sinyal EEG adalah adanya sinyal EOG yang dihasilkan oleh kedipan mata. Sinyal EOG memiliki amplitudo yang sangat tinggi sehingga keberadaannya sangat mengganggu sehingga sinyal ini harus dipisahkan terhadap sinyal asli EEG. Pada penelitian ini, pemisahan sinyal EOG menggunakan toolbox EEGLAB. Adapun tahap demi tahap akan dijelaskan sebagai berikut:

1. Membuka EEGLAB v14.1.1 menggunakan MATLAB versi R2013a di lembar *command*



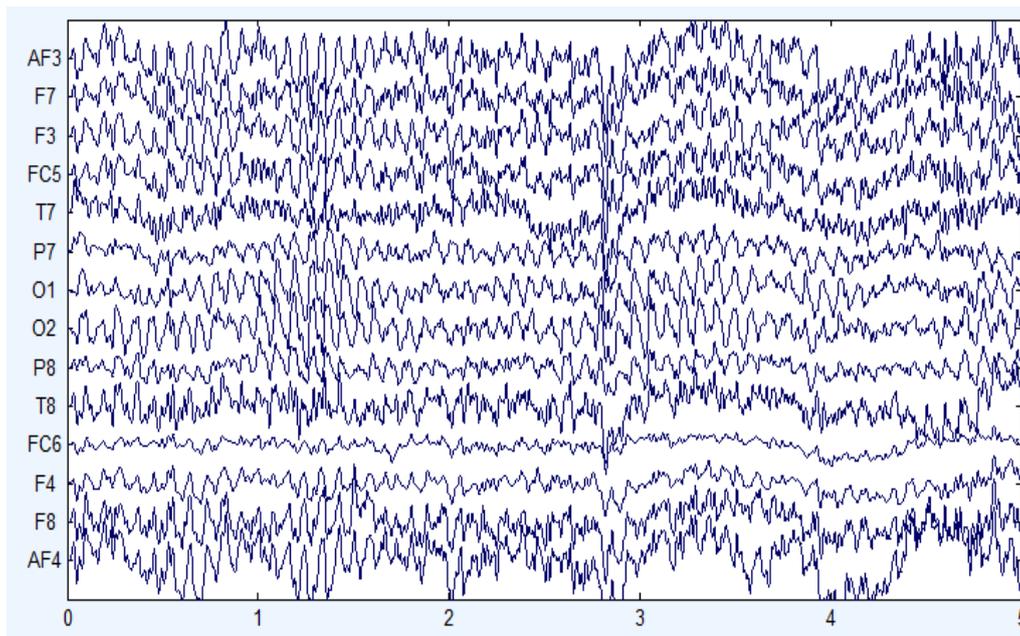
Gambar 4.9 Mulai menggunakan toolbox EEGLAB menggunakan MATLAB

2. Memasukan data partisipan hasil dari perekaman menggunakan EmotivePro dalam bentuk format (edf). Kemudian akan muncul tampilan seperti pada gambar dibawah ini, lengkap dengan informasi dari data partisipan yang terdiri dari panjang frame, jumlah kanal dan frekuensi sampling yang digunakan



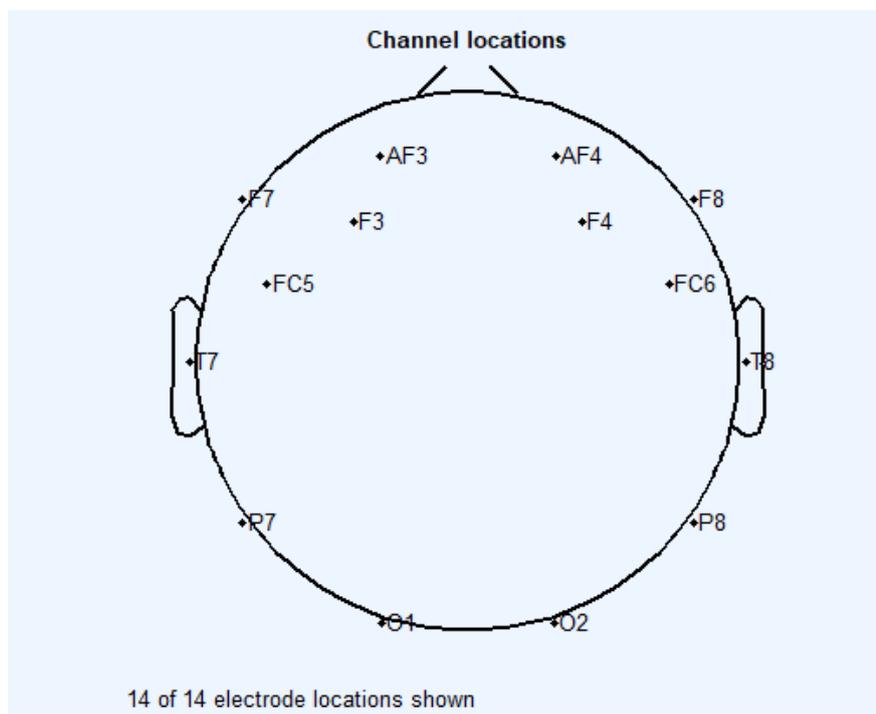
Gambar 4.10 Memasukan data raw di EEGLAB

3. Plot data partisipan sebelum dilakukan tahap pra-processing selanjutnya seperti pada gambar dibawah ini



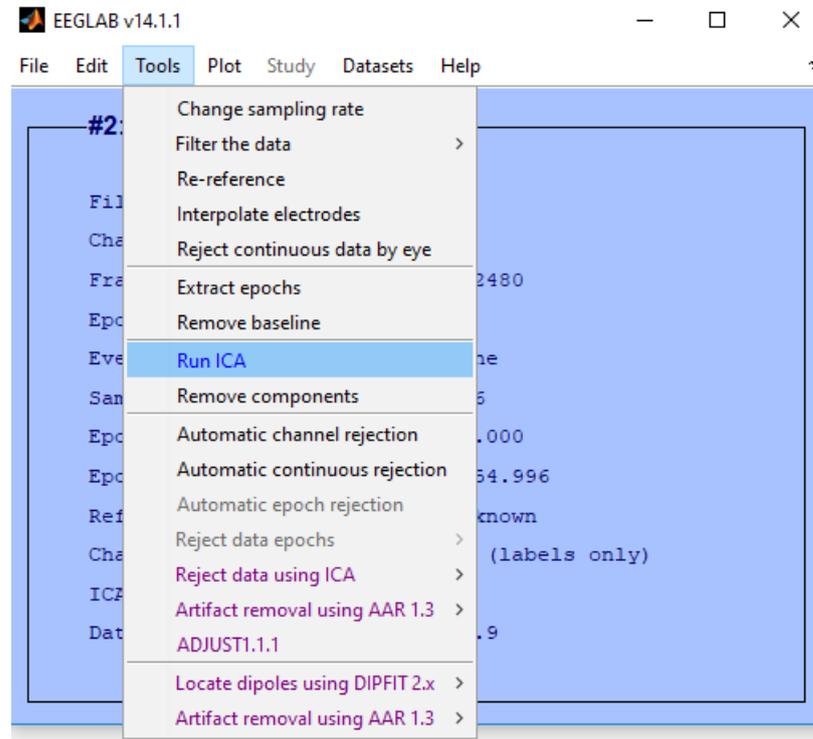
Gambar 4.11 Data Raw Partisipan Sebelum proses ICA

4. Proses filterisasi dilakukan menggunakan filter FIR Band Pass Filter (BPF) dengan frekuensi batas bawah 1 Hz dan batas atas 50 Hz. Kemudian tentukan terlebih dahulu lokasi kanal berdasarkan standart 10/20 sehingga didapatkan gambar seperti dibawah ini.



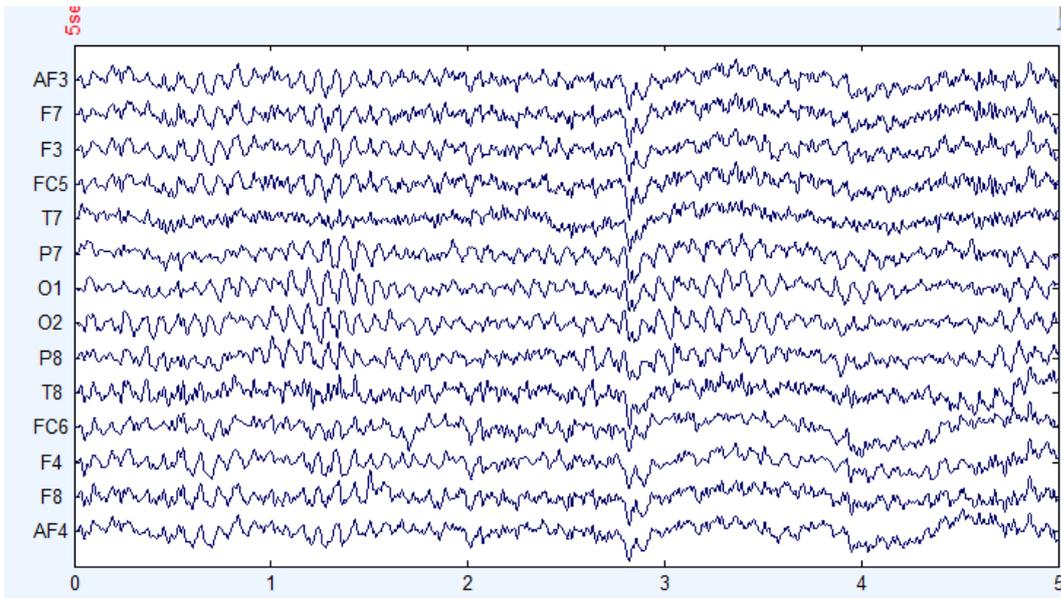
Gambar 4.12 Pengaturan lokasi 14 kanal pada EEGLAB

5. Setelah lokasi kanal ditentukan, maka proses Run ICA siap dilakukan. Proses ICA menghabiskan waktu yang agak lama tergantung dari panjang data yang diproses. Semakin panjang data, maka proses ICA akan berlangsung lama.



Gambar 4.13 Proses Run ICA berlangsung

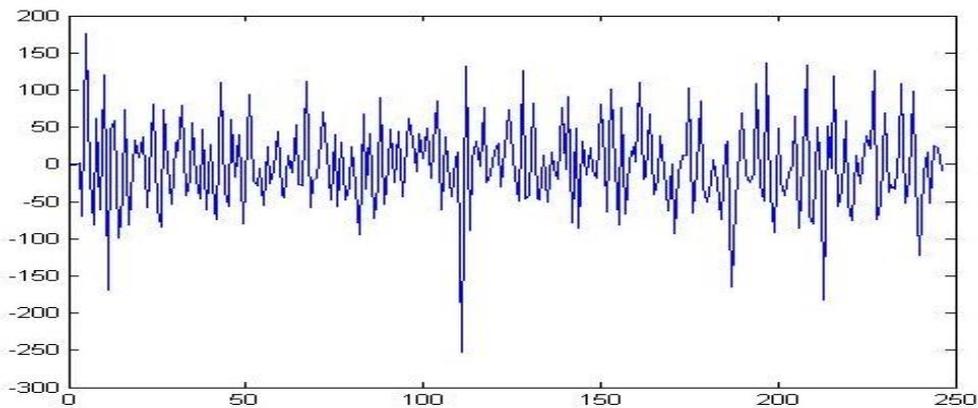
Setelah proses ICA selesai, langkah berikutnya adalah menghapus komponen-komponen yang mengandung noise (*remove bad channel*). Kemudian hasil akhir dari tahap persiapan dapat dilihat pada Gambar 4.14.



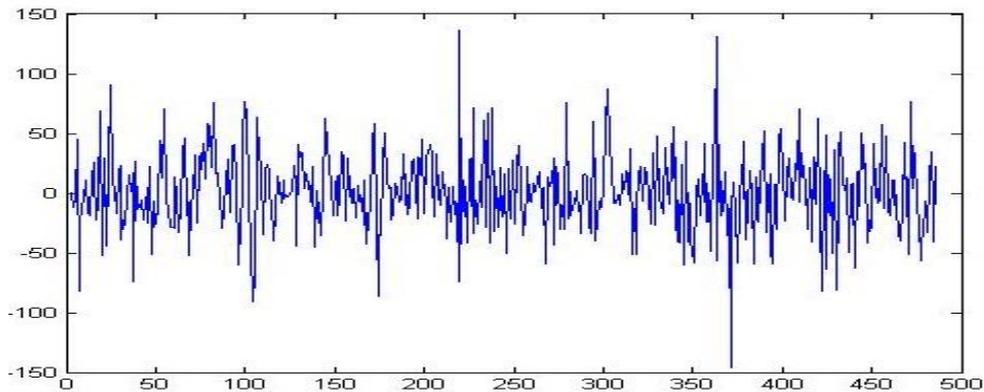
Gambar 4.14 Hasil Data Raw setelah Proses ICA

#### 4.3.2 Hasil Dekomposisi Sinyal Menggunakan DWT

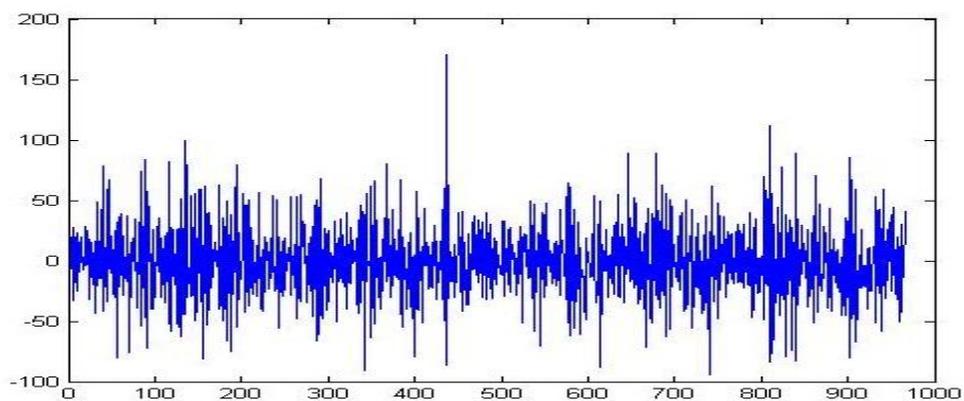
Setelah proses *pre-processing* menghilangkan *noise artefact*, setelah itu sinyal data raw akan dipecah sesuai dengan band frekuensi menggunakan dekomposisi DWT. DWT merupakan metode untuk menganalisa sinyal dalam domain waktu-frekuensi. Pada penelitian ini hanya gelombang detail yang digunakan sebagai acuan gelombang  $\theta$ ,  $\alpha$ ,  $\beta$ , dimana rentang frekuensi dan kernel yang digunakan telah dijelaskan pada Bab 3 subbab 3.4.2 tentang dekomposisi sinyal. Contoh hasil ekstraksi gelombang theta ( $\theta$ ), alpha ( $\alpha$ ) dan beta ( $\beta$ ) dengan menggunakan db4 dapat dilihat pada Gambar 4.15.



(a)



(b)



(c)

Gambar 4.15 Dekomposisi sinyal menggunakan db4 pada sinyal (a) teta, (b) alpha dan (c) beta

#### 4.4 Ekstraksi Fitur

Setelah pemisahan sinyal berdasarkan band frekuensi, proses selanjutnya adalah ekstraksi fitur. Pada penelitian ini, fitur *Power percentage* digunakan untuk menginvestigasi terjadinya kondisi *cybersickness*. Hasil dari perekaman 9 partisipan pada induksi *active game playing* dan 4 partisipan pada induksi *passive watching* dihasilkan 13 dataset. Setiap dataset disegmentasi sebesar 60 detik, sehingga setiap partisipan memiliki 20 segmen data. Label kondisi normal diambil pada 4 segmen pertama sedangkan kondisi *cybersickness* diambil pada 4 segmen terakhir. Sehingga setiap partisipan memiliki 4 label kondisi normal dan 4 label kondisi *cybersickness* (total 8 label/partisipan). Dataset induksi *active game playing* dan *passive watching* diproses secara terpisah. Dimana setiap partisipan terdiri dari

8 frame / 8 instance. Setiap instance terdiri dari 42 fitur yang terdiri dari *Power percentage* pada alpha, beta dan theta sebanyak 14 kanal. Dataset ekstraksi fitur dapat dilihat pada Lampiran 3

#### 4.5 Seleksi Fitur Menggunakan Metode *Correlation Feature Selection* (CFS)

Seleksi fitur bertujuan untuk memilih fitur-fitur yang paling optimal dan berpengaruh dalam menginvestigasi terjadinya *cybersickness*. Selain itu, seleksi fitur dapat mereduksi sebuah matriks menjadi lebih sederhana sehingga dapat mengurangi kompleksitas sebuah komputasi algoritma. Pada penelitian ini, metode seleksi fitur yang digunakan adalah *Correlation based Feature Selection* (CFS), dimana prinsip dari CFS adalah memilih fitur berdasarkan korelasi dengan kelas. Semakin tinggi korelasi fitur terhadap kelas maka fitur tersebut semakin optimal. Adapun hasil dari seleksi fitur akibat dari metode CFS yang diproses pada setiap partisipan, baik induksi *active game playing* dan *passive watching* dapat dilihat pada Tabel 4.2 dan Tabel 4.3.

Tabel 4.2 Hasil Seleksi Fitur Menggunakan Metode CFS pada setiap partisipan (*active game playing*)

Partisipan	Total Fitur	Seleksi Fitur (CFS)
S01	42	13
S02	42	9
S03	42	11
S04	42	11
S05	42	3
S06	42	2
S07	42	20
S08	42	1
S09	42	10

Tabel 4.3 Hasil Seleksi Fitur Menggunakan Metode CFS pada setiap partisipan (*passive watching*)

<b>Partisipan</b>	<b>Total Fitur</b>	<b>Seleksi Fitur (CFS)</b>
P03	42	16
P04	42	29
P06	42	28
P07	42	25

Pada Tabel 4.2 dan Tabel 4.3 dapat diambil kesimpulan bahwa setiap partisipan mengalami reduksi fitur yang berbeda-beda. Hal ini dikarenakan, setiap partisipan memiliki respon otak yang berbeda-beda sehingga hasil ekstraksi fitur juga akan menghasilkan nilai yang berbeda yang mengakibatkan nilai korelasi antar fitur terhadap kelas setiap partisipan juga tidak sama. Penentuan fitur seleksi berdasarkan dari rangking, jika nilai korelasi antara fitur terhadap kelas mendekati 1 maka korelasi yang dihasilkan sangat kuat sedangkan jika nilai korelasi mendekati 0 maka korelasi sangat rendah.

#### **4.6 Analisa Seleksi Fitur Pada Setiap Partisipan *Active Game Playing* dan *Passive Watching***

Perekaman sinyal EEG menggunakan EmotivePro terdiri dari 14 kanal yang terbagi menjadi 4 daerah otak yaitu frontal, temporal, parietal dan occipital. Setelah dilakukan seleksi fitur pada setiap partisipan, langkah selanjutnya adalah menganalisa seleksi pada setiap partisipan baik saat induksi *active game playing* dan *passive watching*. Kemudian pada masing-masing partisipan didapatkan 3 fitur yang paling baik dengan nilai korelasi paling tinggi yang dapat dilihat pada Tabel 4.4 dan Tabel 4.5.

Pada penelitian ini, cara menganalisa daerah otak yang paling dominan pada masing-masing partisipan dilakukan dengan cara mengambil 3 fitur dengan nilai korelasi tertinggi pada setiap partisipan (fitur dengan tanda \*). Pada Tabel 4.4 terlihat bahwa daerah otak bagian frontal dan parietal pada band frekuensi beta paling dominan dalam menduduki 3 fitur terbaik, sehingga dapat disimpulkan beta band pada kedua daerah otak ini dapat dijadikan sebagai indikator dalam mendeteksi *cybersickness* pada induksi *active game playing*.

Tabel 4.4 Hasil Seleksi Fitur *Power percentage* pada Partisipan saat Induksi *Active game playing*

Partisipan	BRAIN REGION											
	FRONTAL			TEMPORAL			PARIETAL			OCCIPITAL		
	$\beta$	$\theta$	$\alpha$	$\beta$	$\theta$	$\alpha$	$\beta$	$\theta$	$\alpha$	$\beta$	$\theta$	$\alpha$
S01	<b>FC6*</b> <b>F8*</b> F7 F4 AF3 F3 FC5 AF4			T8			<b>P8*</b>			O2 O1		
S02	F4 F3			T8	T7		P8	<b>P8*</b>	<b>P8*</b>	O1		<b>O1*</b>
S03	<b>AF4*</b> F8	FC5		<b>T8*</b> T7			<b>P8*</b> P7			O1 O2	O2	O1
S04	<b>F4*</b> F8 FC6			T8			<b>P8*</b> P7		<b>P7*</b>	O2		O1 O2
S05	<b>AF4*</b>			<b>T8*</b>			<b>P7*</b>					
S06	<b>FC6*</b>			<b>T8*</b>								
S07	<b>FC5*</b> F3 F7 AF3	F3 FC6	<b>F3*</b> FC5 AF3 F7	T7	T8	T7	P7	P8 P7	<b>P8*</b> P7	O1		O1
S08							<b>P8*</b>					
S09	<b>FC6*</b> <b>AF4*</b> F4 F3		FC6 AF4	<b>T8*</b>		T8			P8	O1		

note: \* = 3 fitur dengan nilai korelasi tertinggi

Tabel 4.5 Hasil Seleksi Fitur *Power percentage* pada Partisipan saat Induksi *Passive watching*

Partisipan	BRAIN REGION											
	FRONTAL			TEMPORAL			PARIETAL			OCCIPITAL		
	$\beta$	$\theta$	$\alpha$	$\beta$	$\theta$	$\alpha$	$\beta$	$\theta$	$\alpha$	$\beta$	$\theta$	$\alpha$
S01	<b>AF4*</b> <b>AF3*</b> <b>FC6*</b> F4 F3	FC5 F8	FC6	T8			P7 P8		P7	O2 O1	O1	O2
S02	<b>FC5*</b> F7 AF3 F3 F4 FC6 AF4 F8		<b>F7*</b> F4	<b>T7*</b> T8		T8	P7 P8		P7	O1 O2		O1
S03	<b>FC6*</b> <b>AF4*</b> FC5		AF3 AF4 F8	T8			P8 P7		<b>P8*</b> P7	O2 O1		O2 O1

	F8 F7 AF3 F3 F4		F3 F4 FC5 F7									
S04	<b>FC5*</b> F8 FC6 F4 AF3 F3 AF4 F7	<b>F8*</b> FC5	<b>F8*</b> F4 FC6	T8 T7			P8 P7	P8	P7	O1 O2	O1 O2	O1

note: \* = 3 fitur dengan nilai korelasi tertinggi

Sedangkan pada partisipan dengan induksi *passive watching*, bagian otak yang dominan adalah bagian frontal pada band frekuensi beta. Hal ini jelas sekali terlihat bahwa 3 fitur terbaik pada setiap partisipan banyak diperoleh pada bagian otak frontal.

Pada penjelasan diatas dapat disimpulkan bahwa induksi yang berbeda menghasilkan daerah dominan otak yang berbeda juga yang digunakan sebagai indikator dalam mendeteksi terjadinya *cybersickness*. Pada induksi *active game playing*, bagian otak *frontal* dan *parietal* pada frekuensi beta dapat dijadikan sebagai indikator dalam mendeteksi *cybersickness*. Hal ini dikarenakan, bagian otak frontal berhubungan dengan kemampuan manusia atau aktivitas yang dilakukan oleh manusia seperti kemampuan intelektual (proses berpikir, konsentrasi, penalaran) serta mengendalikan gerakan dan emosi, sedangkan bagian otak parietal berhubungan dengan pemahaman tentang bentuk dan arah serta mengendalikan sensasi seperti sentuhan, gerak tubuh dan tekanan. Kedua fungsi bagian otak ini sangat berpengaruh saat bermain *game*, dimana semua emosi, gerakan dan proses berpikir pada manusia dilakukan saat bagaimana partisipan menggerakkan seorang avatar pada “Mirror Edge”. Selain itu, Pergerakan antara tangan dengan otak juga harus sinkron pada saat bermain *game* dimana fungsi ini merupakan tugas dari *parietal lobe*.

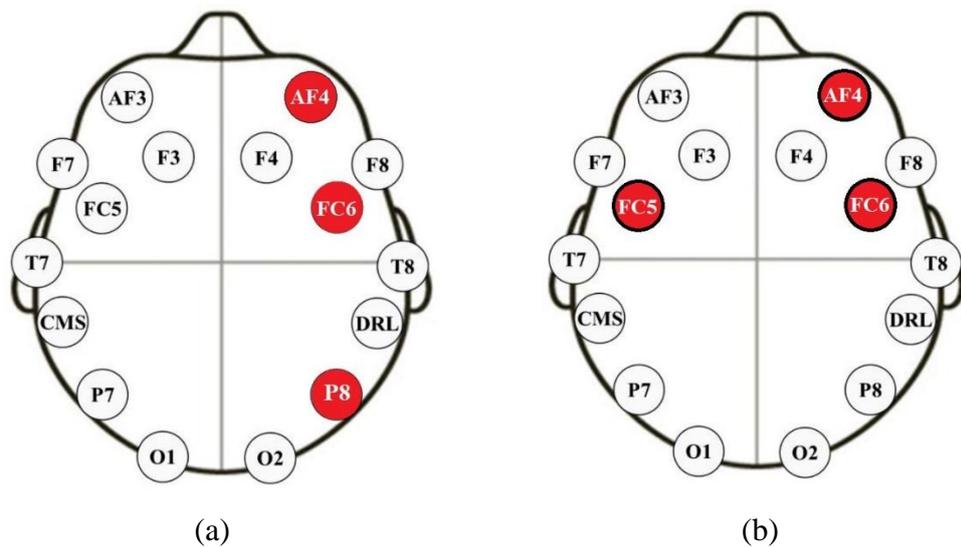
Sedangkan pada induksi *passive watching*, bagian otak yang paling dominan adalah bagian frontal. Hal ini dikarenakan, partisipan tidak melakukan pergerakan apapun dalam mengontrol avatar melainkan hanya menonton video dari permainan “Mirror Edge” sehingga hanya emosi dan konsentrasi yang paling

banyak dilakukan dalam aktivitasnya. Namun, dari kedua induksi yang dilakukan beta band frekuensi menjadi band frekuensi yang paling dominan diantara yang lain, hal ini dikarenakan beta band frekuensi mayoritas muncul ketika manusia melakukan aktivitas seperti berpikir dan berkonsentrasi sehingga pada penelitian ini beta band banyak digunakan sebagai indikator dalam mendeteksi terjadinya *cybersickness*.

#### **4.7 Seleksi Kanal pada EEG**

Metode CFS juga berguna dalam memilih kanal yang paling relevan pada pengukuran menggunakan EEG multikanal. Setelah seleksi fitur dilakukan, maka seleksi kanal dapat ditentukan. Seperti yang terlihat pada Tabel 4.4 dan Tabel 4.5 pada penelitian ini seleksi kanal ditentukan dari 3 fitur terbaik pada setiap partisipan yang kemudian fitur tersebut dikelompokkan berdasarkan kanal, kanal yang memiliki jumlah lebih dari 3 ditentukan sebagai kanal terbaik. Pada induksi *active game playing*, kanal P8, AF4 dan FC6 paling banyak didapatkan pada pengelompokan 3 fitur terbaik. Jika dilihat pada letak elektroda, kanal yang paling berpengaruh terhadap *cybersickness* adalah elektroda pada sebelah kanan atau otak bagian kanan. Dimana fungsi otak pada sebelah kanan adalah berhubungan dengan kemampuan intuitif, kemampuan merasakan, memadukan dan ekspresi tubuh. Otak kanan juga berhubungan erat dengan kreativitas yang dilakukan oleh manusia. Bermain game merupakan salah satu kegiatan yang memicu tingkat kreativitas seseorang, dimana seseorang yang memiliki intuisi dan kreativitas yang tinggi dapat mengontrol permainan dengan baik.

Sedangkan pada induksi *passive watching* kanal terbaik dihasilkan pada kanal FC5, FC6 dan AF4. Lokasi kanal terdapat pada otak sebelah kanan dan kiri. Hal ini berarti, pada kondisi *passive watching* partisipan mengalami proses berpikir yang seimbang antara otak kanan dan otak kiri pada bagian frontal. Pada Gambar 4.16 merupakan posisi dari seleksi kanal dari kedua induksi yang berbeda.

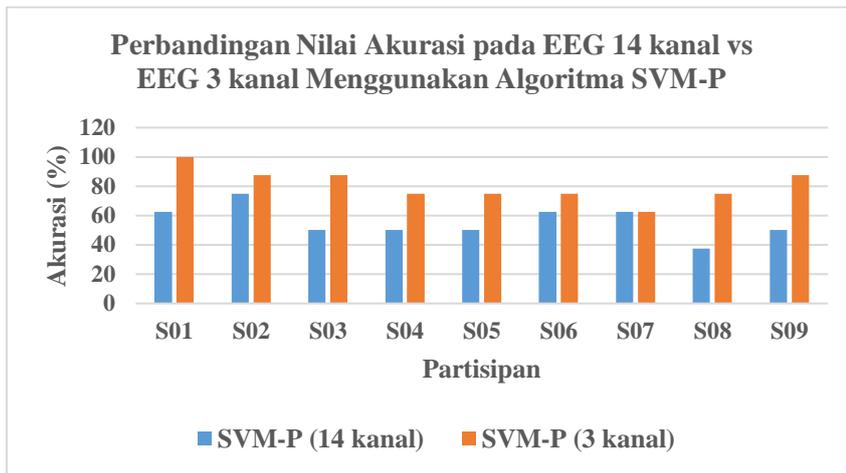


Gambar 4.16 Posisi dari Seleksi Kanal pada : (a) Induksi *active game playing* dan (b) Induksi *Passive watching*

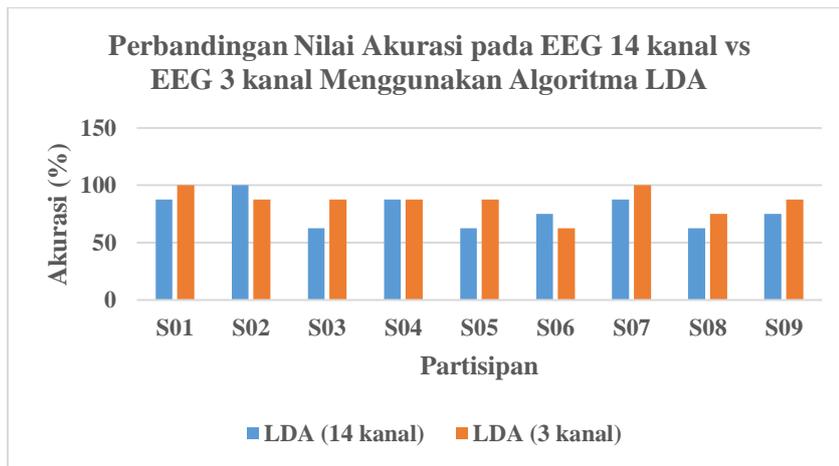
#### 4.8 Evaluasi Performansi pada Seleksi Kanal EEG

Tujuan utama dari seleksi kanal adalah untuk mencari kanal-kanal yang relevan sebagai tahap awal dalam mengidentifikasi fenomena *cybersickness*. Pada penelitian ini telah ditemukan bahwa kanal yang paling relevan pada kondisi *active game playing* dan *passive watching* dapat dilihat pada Gambar 4.16(a) dan (b). Selain itu, hasil dari seleksi kanal bertujuan untuk meningkatkan akurasi performansi data serta mengurangi kompleksitas algoritma. Oleh karena itu, pada sub bab ini akan dibandingkan hasil akurasi antara penggunaan 14 kanal dan 3 kanal hasil seleksi kanal menggunakan metode CFS dengan menggunakan algoritma SVM, KNN dan LDA pada Gambar 4.17 (k-fold cross validation, k=4).

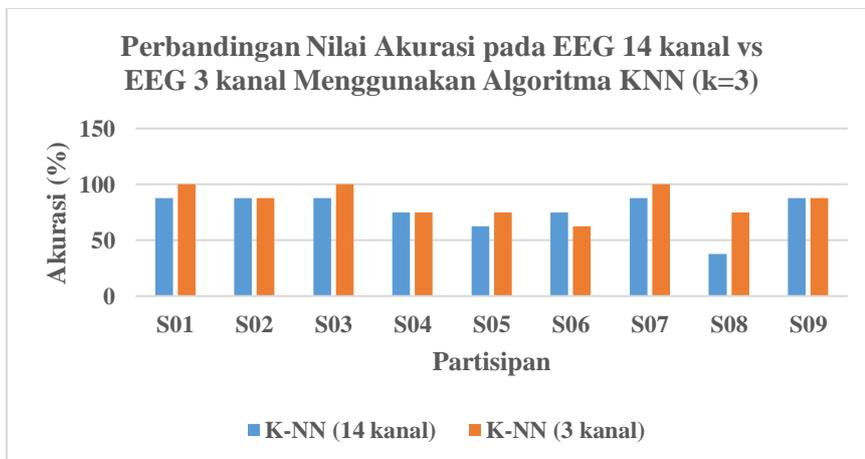
Pada Gambar 4.17, dapat dianalisa bahwa secara rata-rata nilai akurasi saat menggunakan 3 kanal lebih tinggi daripada menggunakan 14 kanal. Penggunaan SVM-P mengalami peningkatan akurasi sebesar 25 %, sedangkan penggunaan algoritma LDA dan KNN mengalami peningkatan akurasi sebesar 8,33%. Hasil perbandingan akurasi pada kondisi *active game playing* dapat disimpulkan bahwa penggunaan algoritma SVM-P memiliki peningkatan akurasi paling tinggi, hal ini terlihat dari masing-masing akurasi pada setiap partisipan mengalami tren peningkatan pada saat menggunakan 3 kanal.



(a)



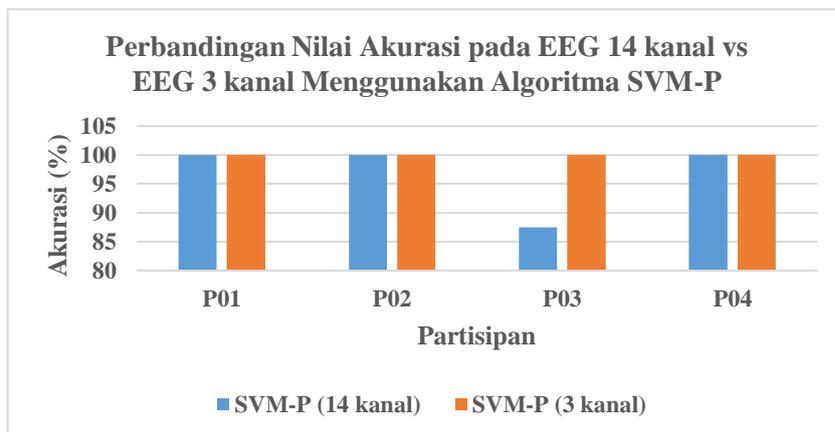
(b)



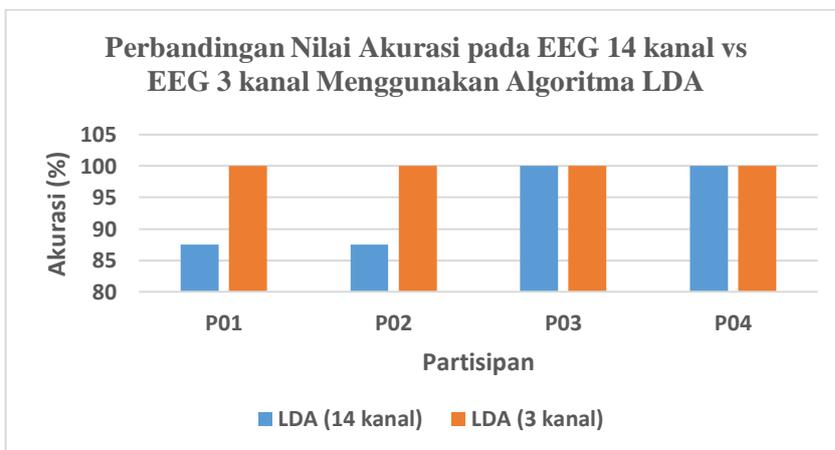
(c)

Gambar 4.17 Hasil Klasifikasi Data menggunakan algoritma : (a) SVM-P, (b) LDA dan (c) KNN pada Induksi *Active game playing*

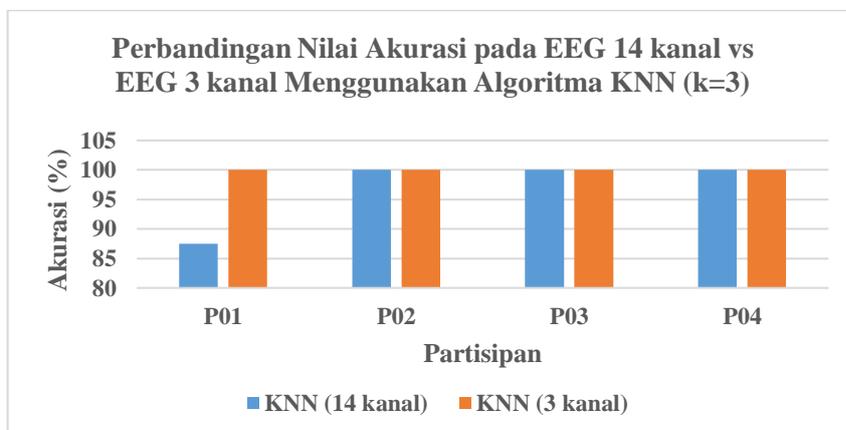
Sedangkan hasil akurasi pada induksi *passive watching* pada EEG 14 kanal dan EEG 3 kanal dapat dilihat pada Gambar 4.18.



(a)



(b)



(c)

Gambar 4.18 Hasil Klasifikasi Data menggunakan algoritma : (a) SVM-P, (b) LDA dan (c) KNN pada Induksi *Passive watching*

Pada Gambar 4.18, dapat dianalisa bahwa secara rata-rata nilai akurasi saat menggunakan 3 kanal lebih tinggi daripada menggunakan 14 kanal. Penggunaan SVM-P mengalami peningkatan akurasi sebesar 3,125 %, sedangkan penggunaan algoritma LDA meningkat sebesar 6,25 dan KNN mengalami peningkatan akurasi sebesar 3,125%. Hasil perbandingan akurasi pada kondisi *passive watching* dapat disimpulkan bahwa penggunaan algoritma SVM-P memiliki peningkatan akurasi paling tinggi, hal ini terlihat dari masing-masing akurasi pada setiap partisipan mengalami tren peningkatan pada saat menggunakan 3 kanal.

#### **4.9 Analisa Hasil Secara Keseluruhan**

Pengukuran *cybersickness* menggunakan *Simulator Sickness Questionnaire* (SSQ) dan sinyal EEG merupakan kombinasi yang sangat tepat untuk menginvestigasi terjadinya *cybersickness*. Kedua metode pengukuran tersebut mampu menghasilkan sebuah nilai yang informatif, yang digunakan penulis untuk menentukan level *cybersickness* pada setiap partisipan. Pengukuran EEG mampu menutupi bias dari hasil yang didapatkan dari *Simulator Sickness Questionnaire* (SSQ).

Berdasarkan hasil dari penelitian ini, gejala *cybersickness* merupakan fenomena yang harus diminimalisir kemunculannya karena gejala-gejala *cybersickness* sangat mengganggu kondisi fisik dan psikis partisipan setelah beberapa menit induksi selesai dilakukan. Hal ini terjadi baik pada kondisi *active game playing* maupun *passive watching*. Tujuan utama penulis menggunakan dua kondisi *cybersickness* yang berbeda adalah untuk membuktikan adanya teori *sensory conflict*, dimana *sensory conflict* disebabkan adanya ketidakcocokan bentuk sinyal antara kenyataan dan yang diharapkan. Salah satu contoh dari teori ini adalah membedakan tingkat *motion sickness* antara sopir taksi dan penumpang. Dimana seorang sopir mengalami *motion sickness* lebih rendah daripada penumpang.

Setelah dilakukan perekaman pada setiap partisipan dengan dua kondisi yang berbeda, ternyata hasil SSQ dan pengolahan EEG juga menghasilkan informasi yang berbeda. Berdasarkan hasil SSQ, kondisi *active game playing* dan *passive watching* masing-masing mengalami tren kenaikan nilai SSQ setelah dilakukan induksi melalui *video game* “Mirror Edge”. Nilai rata-rata SSQ setelah

induksi lebih tinggi daripada nilai SSQ sebelum induksi. Adapun hasil ini membuktikan bahwa ketika partisipan bermain *game* “Mirror Edge” selama kurang lebih 10 menit mampu menginduksi gejala *cybersickness*. Hasil ini juga didukung penelitian yang dilakukan oleh [3], dimana seseorang mengalami kenaikan gejala *cybersickness* setelah 10 menit terpapar dalam dunia virtual reality. Sehingga dari hasil tersebut maka pembaca disarankan untuk tidak bermain video game atau virtual reality lebih dari 10-20 menit.

Selain itu, faktor yang mempengaruhi kenaikan gejala *cybersickness* sebagian besar dipengaruhi oleh faktor pribadi. Pada penelitian ini didapatkan hasil bahwa partisipan S03 dan S07 baik pada kondisi *active game playing* maupun *passive watching* memiliki tingkat *cybersickness* paling tinggi dibandingkan partisipan lainnya. Hal ini dikarenakan, kedua partisipan tersebut memiliki kecenderungan mudah mengalami *motion sickness*/mabuk kendaraan saat berpergian. Sehingga dapat disimpulkan partisipan yang mudah mengalami mabuk kendaraan dapat juga mudah mengalami *cybersickness*. Faktor pribadi lain yang sangat berpengaruh pada penelitian ini adalah kemampuan mengontrol game. Partisipan yang gemar bermain game baik game *first person* maupun game *online* kecenderungan memiliki kontrol diri yang baik terhadap game jenis apapun. Pada penelitian ini, partisipan S06, S08 dan S09 mengalami tren kenaikan yang sangat sedikit sekali antara nilai SSQ sebelum dan sesudah induksi. Hal ini dikarenakan ketiga partisipan adalah gemar bermain jenis game sehingga mereka memiliki kontrol yang baik terhadap game meskipun partisipan tersebut belum pernah bermain “Mirror Edge” game sebelumnya.

Berdasarkan penelitian yang dilakukan oleh [6], nilai SSQ *passive watching* lebih tinggi daripada *active game playing*, hal ini berlaku pada setiap partisipan yang mengikuti eksperimen. Namun, pada penelitian ini tidak semua partisipan memiliki nilai SSQ *passive watching* lebih tinggi daripada *active game playing*. Terdapat dua partisipan (S06 dan S08) dimana nilai SSQ *passive watching* lebih rendah daripada *active game playing*.

Hasil Pengukuran sinyal EEG sangat membantu dalam menentukan dan membedakan antara kondisi normal (sebelum induksi) dan kondisi *cybersickness* (setelah induksi). Pada penelitian ini, klasifikasi dilakukan pada setiap partisipan.

Hal ini dikarenakan, setiap orang memiliki respon otak yang berbeda-beda meskipun induksi yang digunakan untuk membangkitkan *cybersickness* adalah sama sehingga dataset tidak bisa dijadikan satu dalam machine learning. Metode seleksi fitur menggunakan CFS pada setiap partisipan juga diaplikasikan untuk memilih fitur yang memiliki korelasi tinggi terhadap kelas.

Penggunaan CFS pada penelitian dilakukan dalam rangka menyeleksi kanal yang bertujuan untuk memilih kanal yang relevan sehingga dapat dijadikan sebagai referensi dalam mengidentifikasi terjadinya *cybersickness* serta untuk meningkatkan akurasi data. Hasil seleksi kanal pada dua induksi berbeda (active game playing dan passive watching) menghasilkan kanal yang berbeda. Pada active game playing dihasilkan 3 kanal yang paling relevan untuk mengidentifikasi *cybersickness* yaitu AF4, FC6 dan P8. Sedangkan pada passive watching dihasilkan 3 kanal yang paling relevan yaitu AF4, FC5 dan FC6.

Hasil akurasi setelah menggunakan 3 kanal relevan tersebut meningkat pada masing-masing algoritma SVM-P, KNN dan LDA. Pada kondisi active game playing, terjadi peningkatan rata-rata akurasi sebesar 25% pada SVM-P dan 8,33% pada algoritma LDA dan KNN. Sedangkan pada kondisi passive watching, terjadi peningkatan rata-rata akurasi sebesar 6,25% pada LDA dan 3,125% pada SVM-P dan KNN. Jika dilihat dari hasil akurasi tersebut algoritma SVM-P memiliki performansi terbaik daripada LDA dan KNN, hal ini dikarenakan akurasi dari masing-masing partisipan mengalami kenaikan saat menggunakan EEG 3 kanal dibandingkan dengan EEG 14 kanal.

## **BAB 5**

### **KESIMPULAN**

#### **5.1 Kesimpulan**

Adapun kesimpulan pada penelitian ini adalah sebagai berikut:

1. Hasil perhitungan dan analisa SSQ dapat membantu sebagai validasi data dalam menentukan label kelas yang terdiri dari kondisi baseline dan kondisi *cybersickness*.
2. Penggunaan metode *Correlation Feature Selection* (CFS) menghasilkan kanal-kanal yang relevan. Pada kondisi *active game playing* menghasilkan 3 kanal yaitu AF4, FC6 dan P8, sedangkan pada kondisi *passive watching* menghasilkan 3 kanal yaitu AF4, FC6 dan FC5. Seleksi kanal ini dapat digunakan sebagai langkah awal dalam mengidentifikasi lebih lanjut gejala *cybersickness*.
3. Nilai akurasi saat menggunakan EEG 3 kanal lebih baik daripada EEG 14 kanal. Pada kondisi *active game playing*, penggunaan algoritma SVM-P secara rata-rata mengalami kenaikan sebesar 25% sedangkan LDA dan KNN mengalami kenaikan sebesar 8,33%. Pada kondisi *passive watching*, penggunaan algoritma SVM-P dan KNN mengalami kenaikan sebesar 3,125% sedangkan pada algoritma LDA mengalami kenaikan sebesar 6,25%.

#### **5.2 Penelitian Selanjutnya**

1. Untuk pelabelan dataset, selain berdasarkan hasil *Simulator Sickness Questionnaire* (SSQ) juga dibutuhkan peran ahli kesehatan sehingga label data yang dihasilkan lebih akurat dan valid.
2. Pada penelitian ini hanya fokus pada band frekuensi alpha, beta dan theta. Untuk penelitian selanjutnya dapat menambahkan band frekuensi lainnya seperti delta, gamma, low beta dan high beta agar analisa lebih lengkap.
3. Penggunaan Teknik visualisi data juga sangat baik digunakan pada penelitian lanjutan untuk lebih mengetahui perubahan gejala *cybersickness* secara *time series* serta untuk mengetahui korelasi antar kanal.

*Halaman ini sengaja dikosongkan*

## DAFTAR PUSTAKA

- [1] U. Data, "ESSENTIAL," 2017.
- [2] J. J. L. Jr, "A Discussion of Cybersickness in Virtual Environments," vol. 32, no. 1, 2000.
- [3] S. V. G. Cobb and J. R. Wilson, "Virtual Reality-Induced Symptoms and Effects ( VRISE )."
- [4] S. Davis, K. Nesbitt, and E. Nalivaiko, "Comparing the onset of cybersickness using the Oculus Rift and two virtual roller coasters," no. January, pp. 27–30, 2015.
- [5] M. Bahit, S. Wibirama, H. A. Nugroho, T. Wijayanto, and M. N. Winadi, "Investigation of Visual Attention in Day-Night Driving Simulator during Cybersickness Occurrence," pp. 0–3, 2016.
- [6] C. T. Guo, C. W. Tsoi, Y. L. Wong, K. C. Yu, and R. H. Y. So, "COMPUTER GAME PLAYING," 2008.
- [7] Y. Y. Kim, J. U. Kim, N. A. M. Kim, D. Ko, and H. Taek, "Characteristic changes in the physiological components of cybersickness," vol. 42, pp. 616–625, 2005.
- [8] S. Wibirama and K. Hamamoto, "Investigation of Visually Induced Motion Sickness in Dynamic 3D Contents based on Subjective Judgment , Heart Rate Variability , and Depth Gaze Behavior," pp. 4803–4806, 2014.
- [9] S. Ali *et al.*, "EEG based time and frequency dynamics analysis of visually induced motion sickness ( VIMS )," *Australas. Phys. Eng. Sci. Med.*, no. October, 2015.
- [10] M. S. Dennison, "Running head: PHYSIOLOGICAL SIGNALS PREDICT CYBERSICKNESS 1 Use of physiological signals to predict cybersickness Mark S. Dennison," no. 562.
- [11] L. R. Rebenitsch, "No Title," 2015.
- [12] P. State and Y. Age, "Scoring the MSSQ- Short," pp. 2–3.
- [13] C. Internationale, "EEG Effects of Motion Sickness Induced in a Dynamic Virtual Reality Environment," no. 2, pp. 3872–3875, 2007.
- [14] R. S. Kennedy *et al.*, "Simulator Sickness Questionnaire : An Enhanced Method for Quantifying Simulator Sickness Simulator Sickness Questionnaire : An Enhanced Method for Quantifying Simulator Sickness," vol. 8414, no. December, 2016.
- [15] Y. Lin, Y. Chien, H. Wang, F. Lin, Y. Huang, and H. D. Shieh, "Cybersickness Assessment Using EEG for Virtual Reality."
- [16] E. Chang, I. Hwang, H. Jeon, Y. Chun, H. T. Kim, and C. Park, "Effects of Rest Frames on Cybersickness and Oscillatory Brain Activity," pp. 62–64, 2013.
- [17] V. Jurcak, D. Tsuzuki, and I. Dan, "10 / 20 , 10 / 10 , and 10 / 5 systems revisited : Their validity as relative head-surface-based positioning systems ☆," vol. 34, pp. 1600–1611, 2007.
- [18] "10 / 20 System Positioning."
- [19] H. Gandhi and K. Trivedi, "Analysis of EEG data Using ICA and Algorithm Development for Energy Comparison," vol. 1, no. 3, pp. 585–

- 588, 2013.
- [20] I. Rejer, G. Pawel, I. Rejer, and G. Pawel, “Independent Component Analysis for EEG Data Preprocessing - Algorithms Comparison To cite this version ;,” 2017.
  - [21] R. Jenke, S. Member, A. Peer, and M. Buss, “Feature Extraction and Selection for Emotion Recognition from EEG,” vol. 5, no. 3, 2014.
  - [22] F. Qiao, “Introduction to Wavelet,” 2005.
  - [23] L. February, “Chapter 1 Overview,” 2010.
  - [24] P. Li, W. Jiang, and F. Su, “Single-channel EEG-based Mental Fatigue Detection based on Deep Belief Network,” pp. 367–370, 2016.
  - [25] W. K. Härdle and L. Simar, *Applied Multivariate Statistical Analysis*. Berlin: Springer Berlin Heidelberg, 2015.
  - [26] and C.-J. L. Chih-Wei Hsu, Chih-Chung Chang, “A Practical Guide to Support Vector Classification,” *BJU Int.*, vol. 101, no. 1, pp. 1396–400, 2008.
  - [27] C. T. Lin, S. F. Tsai, H. C. Lee, H. L. Huang, S. Y. Ho, and L. W. Ko, “Motion sickness estimation system,” *Proc. Int. Jt. Conf. Neural Networks*, pp. 10–15, 2012.
  - [28] L. Rebenitsch and C. Owen, “Review on cybersickness in applications and visual displays,” *Virtual Real.*, vol. 20, no. 2, 2016.

## LAMPIRAN -LAMPIRAN

### LAMPIRAN 1 Kuesioner Partisipan

NAMA	
USIA	
PEKERJAAN	
PENDIDIKAN	
JENIS KELAMIN	
SUKU	

1. Apakah saat ini anda dalam keadaan sehat?  
 Ya  
 Tidak
2. Apakah anda sudah sarapan hari ini?  
 Ya  
 Tidak
3. Jam berapa anda tidur pada malam hari ?
4. Apakah anda pernah memiliki riwayat penyakit kronis?  
 Ya, Sebutkan:  
 Tidak
5. Apakah saat ini anda sedang mengkonsumsi atau ketergantungan dengan obat-obatan tertentu?  
 Ya  
 Tidak
6. Apakah anda memiliki gangguan pada mata?  
 Ya, Sebutkan:  
 Tidak
7. Berapa jam rata-rata anda bermain game setiap harinya?

TIDAK PERNAH	< 1 JAM	1 JAM-3 JAM	> 3 JAM
1	2	3	4

8. Apakah anda merasa pusing atau mual setelah bermain game?

TIDAK PERNAH	KADANG- KADANG	SERING	SELALU
1	2	3	4

## LAMPIRAN 2

### SIMULATOR SICKNESS QUESTIONNAIRE (SSQ)

Instruksi : Lingkari setiap gejala-gejala dibawah ini yang kamu rasakan saat ini

1.	Ketidaknyamanan secara umum	None	Sedikit	Sedang	Parah
2.	Lelah	None	Sedikit	Sedang	Parah
3.	Sakit kepala	None	Sedikit	Sedang	Parah
4.	Ketegangan mata	None	Sedikit	Sedang	Parah
5.	Susah untuk focus	None	Sedikit	Sedang	Parah
6.	Air liur meningkat	None	Sedikit	Sedang	Parah
7.	Berkeringat	None	Sedikit	Sedang	Parah
8.	Mual	None	Sedikit	Sedang	Parah
9.	Susah konsentrasi	None	Sedikit	Sedang	Parah
10.	Kepala merasa penuh	None	Sedikit	Sedang	Parah
11.	Penglihatan blur	None	Sedikit	Sedang	Parah
12.	Pusing saat mata terbuka	None	Sedikit	Sedang	Parah
13.	Pusing saat mata tertutup	None	Sedikit	Sedang	Parah
14.	Vertigo	None	Sedikit	Sedang	Parah
15.	Ketidaknyamanan perut	None	Sedikit	Sedang	Parah
16.	Bersendawa	None	Sedikit	Sedang	Parah

## **LAMPIRAN 3**



## BIOGRAFI PENULIS

Alfi Zuhriya Khoirunnisaa, mahasiswi Magister di Institut Teknologi Sepuluh November Surabaya, Fakultas Teknologi Elektro, Departemen Teknik Elektro, Bidang keahlian Telematika. Lahir di kota Probolinggo pada tanggal 24 Januari 1991. Penulis menggeluti bidang *Affective Computing* dan *Biomedical Engineering*. Penulis dapat dihubungi pada email: [alfi.khoirunnisaa@gmail.com](mailto:alfi.khoirunnisaa@gmail.com).



Adapun riwayat pendidikan penulis diantaranya:

1. TK Bhayangkari 16 (1995-1997)
2. SD Tisnonegaran 2 Probolinggo (1997-2003)
3. SMP Negeri 1 Probolinggo (2003-2006)
4. SMA Negeri 1 Probolinggo (2006-2009)
5. S1 Universitas Brawijaya-Jurusan Teknik Elektro (2009-2013)
6. S2 Institut Teknologi Sepuluh November, Bid.ahli Telematika (2016-2018)

*Halaman ini sengaja dikosongkan*